

Untersuchung des Patientenflussmanagements in komplexen interdependenten Krankenhäusern:

Entwicklung, Implementierung und Evaluation von Verfahren basierend auf Simulation, Optimierung und Data-Mining

Dissertation

zur Erlangung des Grades
Doktor der Wirtschaftswissenschaften (Dr. rer. pol.)

der **Juristischen und Wirtschaftswissenschaftlichen Fakultät**
der **Martin-Luther-Universität Halle-Wittenberg**

vorgelegt von
Thomas Albrecht, M.Sc.

Halle (Saale),
Januar 2023

Erstgutachter: Prof. Dr. Taïeb Mellouli
Zweitgutachter: Prof. Dr. Rolf Rogge
Tag der Verteidigung: 16.05.2023

Danksagung

Die Erstellung einer Dissertation ist ein langer und schwieriger Weg. Ohne die große Unterstützung einer Vielzahl an Personen wäre die Fertigstellung dieser Arbeit nicht möglich gewesen. Daher freue ich mich außerordentlich, diesen Menschen an dieser Stelle meinen tiefsten Dank auszusprechen.

Zuallererst möchte ich mich bei Herrn Prof. Dr. Mellouli für die langjährige und ausdauernde fachliche und persönliche Unterstützung als Mentor und Betreuer in den arbeitsreichen Jahren am Lehrstuhl für Wirtschaftsinformatik und Operations Research bedanken. In vielen wertvollen Diskussionen wurden die Grenzen dieser Arbeit immer weiter ausgelotet und vermeintlich unumstößliche Praxisgegebenheiten infrage gestellt. Diese Diskussionen haben meinen Blick auf die Praxiswelt nachhaltig verändert und machten diese Arbeit erst möglich.

Weiterhin möchte ich mich zutiefst bei Herrn Prof. Dr. Rogge bedanken. Vom ersten Tag an stand er mir mit hilfreichen methodischen und inhaltlichen Hinweisen zur Seite. Diese verstärkten meine Motivation, diese Arbeit fertigzustellen.

Sowohl bei Herrn Prof. Dr. Mellouli als auch bei Herrn Prof. Dr. Rogge möchte ich mich für das entgegengebrachte Vertrauen in der Lehre bedanken. Dies ermöglichte es mir, abseits der der Forschung wertvolle Erfahrungen und Kenntnisse für meine weitere Zukunft zu sammeln.

Ein besonderer Dank richtet sich an Herrn Dr. Karsten Schwarz, der mir seit meiner Bachelorarbeit mit fachlichem und persönlichem Rat zur Seite steht. Sein unbändiger Wille, die Komplexität eines Krankenhauses zu verstehen, ist auf mich abgefärbt und war einer der ausschlaggebenden Aspekte für die Wahl dieses Themenbereiches.

Auch möchte ich mich bei Herrn Dr. Malek Masmoudi für seine frischen Einblicke auf mein Forschungsgebiet bedanken. Sein ingenieurwissenschaftlicher Blick auf

Danksagung

die operativen Prozesse eines Krankenhauses hat die Qualität der Forschung noch weiter erhöht.

Desweiteren danke ich Prof. Dr. Römer, Markus Bozau, Prof. Dr. Walther, Prof. Dr. Wöhner, Hendrik Nieß, Sebastian Köhler und allen weiteren aktuellen und ehemaligen Kollegen für die stets freundliche und kollegiale Arbeitsatmosphäre, die unabdingbar ist, um eine Dissertation zu vollenden.

Außerdem gilt mein großer Dank Andrea Beckmann für die administrative Unterstützung und ihr offenes Ohr bei vielen kleineren und größeren Problemen.

Vor allem möchte ich aber Dr. Tobias Weirowski für die vielen Diskussionen abseits des Krankenhausmanagements danken. Gerade in schwierigen Phasen halfen diese Gespräche und einige Espressi dabei, wieder den Fokus auf die bevorstehende Arbeit zu lenken.

Ich danke meinen treuen Freunden Alexander und Bianca Hesse, Michaela Born, Sven Morgenstern, Lisa Reber, Stefan Ockert und Dr. Caroline Kaiser und allen Nachbarn im Harz für die Möglichkeit, den Alltag in der Promotionsphase auch mal hinter sich zu lassen und auf andere Gedanken zu kommen.

Weiterhin danke ich meiner Mutter Heidemarie Stoeck für ihre bedingungslose Unterstützung. Vor allem für die ausdauernde Überzeugungsarbeit, doch das Abitur abzulegen, bin ich zutiefst dankbar.

Meinen persönlich größten Dank möchte ich an meine Frau Katrin Albrecht und meine Tochter Sophie Martha Albrecht richten. Eure bedingungslose Liebe und Unterstützung hat mir immer wieder gezeigt, dass es im Leben wichtigere Dinge als die Arbeit gibt. Ohne euch wäre diese Dissertation nie möglich gewesen.

Zusammenfassung

Krankenhäuser sind ein entscheidender Faktor im deutschen Gesundheitssystem. 27,7 % der Gesamtkosten für die Gesundheitsversorgung der Bevölkerung entfallen auf sie. Damit sind sie kostenseitig der größte Akteur. Hohe Kosten und ein allgegenwärtiger Spardruck sorgen für eine wirtschaftlich angespannte Situation für Krankenhäuser. Nur diejenigen Einrichtungen, die ihre Prozesse an die neuen und zukünftigen Gegebenheiten anpassen, können langfristig am Markt bestehen. Innerhalb eines Krankenhauses lassen sich aufgrund der komplexen interdependenten Strukturen, Prozessverbesserungen und deren Evaluationen schwer umsetzen. Ein Krankenhaus besteht aus verschiedenen Organisationseinheiten, wie zum Beispiel Stationen, Laboren und Operationssälen. Sie stellen eine Vielzahl an Ressourcen, wie medizinisches Personal, Bettenkapazitäten und gemeinsam genutzte Ressourcen, bereit. Aus der Kombination von Organisationseinheiten und Ressourcen entsteht ein komplexes System mit dem Ziel der Wiederherstellung des Gesundheitszustandes der Bevölkerung. Dabei können die Patienten grundlegend in zwei verschiedene Arten eingeteilt werden. Elektive Patienten sind im Vorfeld ihrer Aufnahme bereits bekannt und ihre Eigenschaften können während der Planung der Behandlung berücksichtigt werden. Notfallpatienten sind dem Krankenhaus unbekannt. Dies bedeutet, dass sie spontan im Krankenhaus vorstellig werden und eine zeitnahe Behandlung benötigen. Zwischen diesen drei Gruppen, den Patienten, den Organisationseinheiten und den Ressourcen, bestehen vielfältige Interdependenzen, die eine weitreichende Planung im Patientenflussmanagement erschweren.

Gegenstand des Patientenflussmanagements ist Zuweisung und Koordinierung von Ressourcen, sodass für jeden Patienten das richtige Bett zur richtigen Zeit verfügbar ist. Durch die vorherrschende Unsicherheit des Patientenflusses, hervorgerufen durch unbekanntes Notfallpatienten, unsichere Länge der Verweildauern oder schwer vorhersagbare Behandlungsverläufe, kann es in einem Krankenhaus immer wieder zu kurzfristigen Kapazitätsengpässen kommen. Eine Erhöhung der

allgemeinen Kapazitäten ist oft nicht möglich oder erwünscht. Da die Nachfrage nach Krankenhausdienstleistungen nicht gleichmäßig verteilt ist, kann es zu einer unausgeglichene Kapazitätsnutzung kommen. Während eine Station keine freien Betten zur Behandlung ihrer Patienten hat, kann eine andere Abteilung über viele freie Kapazitäten verfügen. Die Grundprämisse dieser Arbeit zur flexiblen Kapazitätsnutzung im Patientenflussmanagement nutzt diesen Umstand. Flexibilität kann erreicht werden, wenn anderweitig ungenutzte Kapazität verwendet werden kann.

Somit werden in der vorliegenden Arbeit verschiedene Modelle und Verfahren zur Unterstützung eines krankenhausweiten Patientenflussmanagements aufgezeigt. Dabei werden individuelle Ansätze für die strategisch/taktische Managementebene, die operative Planungsebene und die operative Steuerungsebene entwickelt und evaluiert. Die vorgestellten Modelle und Methoden können in ein ganzheitliches Entscheidungsunterstützungssystem für das Patientenflussmanagement überführt werden.

In einem ersten Schritt werden die strategischen und taktischen Auswirkungen einer flexiblen Kapazitätsnutzung untersucht. Dazu wird ein krankenhausweites generisches Simulationsmodell entwickelt, welches den gesamten Patientenfluss eines Krankenhauses inklusive operativer Nebenbedingungen, wie die Geschlechtertrennung, darstellen kann. Mithilfe dieses Modells werden verschiedene Szenarien zur flexiblen Kapazitätsnutzung untersucht. Dabei zeigt vor allem die Einführung interdisziplinärer Stationscluster vielversprechende Ergebnisse. Bei gleichbleibender verfügbarer Kapazität können Wartezeiten und ungeplante Terminverschiebungen nahezu vermieden werden. Weiterhin zeigt sich, dass bei der flexiblen Nutzung der Ressourcen ungefähr ein Drittel der verfügbaren Betten abgebaut werden könnten, bis die gleichen Wartezeiten erreicht werden. Somit wird demonstriert, dass Flexibilität im Patientenflussmanagement generell in der Lage ist, Engpasssituationen im Krankenhaus aufzulösen.

Um diese Erkenntnisse im Betrieb eines Krankenhauses zu nutzen, müssen sie in neue Konzepte zur Planung und Steuerung des Patientenflusses integriert werden. Zur Evaluation und Anpassung eines initialen Terminplanes für elektive Patienten wird ein robustes lineares Optimierungsmodell auf Basis eines aus der Logistik bekannten Umladeproblems erstellt. Dabei wird der Patientenfluss als Fluss durch ein Netzwerk von Knoten und Kanten aufgefasst. Durch die Nutzung einer Netzwerkstruktur werden verschiedene operative Nebenbedingungen bereits implizit

von der Struktur vorgeschrieben. Weitere Restriktionen werden in das Optimierungsmodell integriert. Im Gegensatz zum aktuellen Stand der Forschung werden Notfallpatienten in diesem Modell bereits im Planungsprozess beachtet, um eine höhere Umsetzungsfähigkeit des Planes zu ermöglichen. Mit der Möglichkeit der Anpassung der Aufnahmetermine und der Verteilung der Patienten auf alternative Stationen ist ein Planungswerkzeug entstanden, welches die Termintreue eines Krankenhauses deutlich erhöhen kann. Dieses Werkzeug wird mithilfe des bereits vorgestellten Simulationsmodells evaluiert. Eine Termintreue von ca. 90 % in allen untersuchten Szenarien ist gleichbedeutend mit einer Verbesserung dieser Kennzahl um 10 %. Jedoch wird dabei auch gezeigt, dass unabhängig von der Qualität der Planung eines Krankenhauses nicht alle kapazitätsbasierten Engpässe verhindert werden können.

Aus diesem Grund werden im letzten Teil der Arbeit operative Handlungsrichtlinien entwickelt und evaluiert, die eine Entscheidungsunterstützung in der Steuerung des Patientenflusses ermöglichen sollen. Diese Unterstützung basiert auf aus Routinedaten gewonnenem Behandlungswissen. Dabei werden die klinischen Bedürfnisse und die organisatorischen Gegebenheiten zur Behandlung von Patienten im Gegensatz zur aktuellen Forschung klar separiert und einzeln gewonnen. Diese unterschiedlichen Erkenntnisse werden im operativen Betrieb patientenindividuell kombiniert, um alternative Stationen während Kapazitätsengpässen zu identifizieren. Eine Evaluation mit dem Simulationsmodell hat gezeigt, dass sich mit dieser Methode nahezu alle verbliebenen Kapazitätsengpässe schnell und mit einer hohen Behandlungsqualität auflösen lassen.

Die vorliegende Arbeit stellt somit für jede Stufe des Patientenflussmanagements Modelle und Verfahren zur Verfügung, die es dem Krankenhaus ermöglichen, schnell und qualitativ hochwertig zu reagieren.

Abstract

Hospitals are a decisive factor in the German healthcare system. They account for 27.7 % of the total cost of healthcare for the population. This makes them the biggest player in terms of costs. High costs and the omnipresent pressure to cut costs are creating a tense economic situation for hospitals. Only those institutions that adapt their processes to new and future conditions will be able to survive on the market in the long term. Within a hospital, process improvements and their evaluations are difficult to implement due to the complex interdependent structures. A complex hospital consists of different organizational units, such as wards, laboratories and operating rooms, and provides a variety of different resources, such as medical staff, bed capacities and shared resources. The combination of organizational units and resources creates a complex system with the goal of restoring the health of the population. Patients can be fundamentally divided into two different types. Elective patients are known in advance of their admission and their characteristics can be taken into account during treatment planning. Emergency patients are usually unknown to the hospital. This means that they reveal themselves spontaneously to the hospital and require prompt treatment. There are many interdependencies between these three groups, the patients, the organizational units and the resources, which make extensive planning in patient flow management difficult.

The objective of patient flow management is to allocate and coordinate resources so that the right bed is available for each patient at the right time. Due to the prevailing uncertainty of patient flow, caused by unknown emergency patients, uncertain length of stay or difficult to predict treatment courses, short-term capacity bottlenecks can occur in a hospital again and again. Increasing overall capacity is often not possible or desirable. Since the demand for hospital services is not evenly distributed, unbalanced capacity utilization may occur. While one ward may have no spare capacity to treat its patients, another ward may have plenty of spare capacity. The basic premise of this work on flexible capacity utilization

in patient flow management takes advantage of this circumstance. Flexibility in capacity utilization can be achieved if otherwise unused capacity is used.

Thus, this thesis develops various models to support hospital-wide patient flow management. Individual models are developed and evaluated for the strategic/tactical management level, the operational planning level and the operational control level. The presented models and methods can be transformed into a holistic decision support system for patient flow management.

In a first step, the strategic and tactical implications of flexible capacity utilization are investigated. For this purpose, a hospital-wide generic simulation model is developed that can represent the entire patient flow of a hospital including operational constraints such as gender separation. With the help of this model, different scenarios for flexible capacity utilization are investigated. In particular, the introduction of interdisciplinary ward clusters shows promising results. With constant available capacity, waiting times and unplanned postponements of appointments can almost be avoided. Furthermore, it is shown that with flexible use of capacity, almost a third of the available beds could be reduced until the same waiting times are achieved. This shows that flexibility in patient flow management is generally capable of resolving bottleneck situations in hospitals.

In order to use these findings in the operation of a hospital, they have to be integrated into new concepts for the planning and control of the patient flow. For the evaluation and adaptation of an initial schedule for elective patients, a robust linear optimization model is created based on a transshipment problem known from logistics. Here, the patient flow is conceived as a flow through a network of nodes and edges. By using a network structure, several operational constraints are already implicitly prescribed by the structure. Additional operational constraints are integrated into the optimization model. In contrast to the current state of research, emergency patients are already integrated in the planning process in this model to enable a higher implementation capability of the plan. With the ability to adjust admission dates and distribute patients to alternative wards, a planning tool has been created that can significantly increase a hospital's adherence to schedules. This planning tool is evaluated using the simulation model presented earlier. An adherence to schedules of approx. 90 % in all scenarios examined is equivalent to an improvement of this key performance indicator by 10 %. However, it is also shown that regardless of the quality of a hospital's planning, not all capacity-based bottlenecks can be prevented.

Abstract

For this reason, the final part of this work develops and evaluates operational policies to provide decision support in managing patient flow. This support is based on treatment knowledge obtained from routine data. In contrast to current research, clinical needs and organizational circumstances for treating patients are clearly separated and obtained individually. These different insights are combined on a patient-by-patient basis in operations to identify alternative wards during capacity bottlenecks. An evaluation with the simulation model has shown that almost all remaining capacity bottlenecks can be resolved quickly and with a high quality of treatment using this method.

This work thus provides models and procedures for each stage of patient flow management that enable hospitals to respond quickly and with high quality.

Inhaltsverzeichnis

Zusammenfassung	v
Abstract	ix
Abbildungsverzeichnis	xvii
Tabellenverzeichnis	xviii
Abkürzungsverzeichnis	xxi
1. Einleitung	1
2. Untersuchung interdependenter Krankenhausstrukturen	11
2.1. Aufbau und Kernprozesse eines Krankenhauses	11
2.2. Patientenarten und Ressourcen im Krankenhaus	13
2.3. Interependenzen eines Krankenhauses	17
3. Patientenflussmanagement in komplexen interdependenten Krankenhäusern	23
3.1. Klinische Pfade als Grundlage des Patientenflussmanagements	23
3.2. Krankenhausweite Modellierung des Patientenflusses	27
3.3. Ziele und Maßnahmen für ein flexibles Patientenflussmanagement während Kapazitätsengpässen	31
3.4. Kategorisierung der Problemstellungen im Patientenflussmanagement	37
4. Standardisierte Behandlungsdaten als Grundlage einer krankenshausweiten Betrachtung	43
4.1. G-DRG System als Treiber einer kontinuierlichen Datenlieferung	43
4.2. Routinedaten gemäß §21 KHEntG	45

4.3. Beispieldatensatz	46
5. Entwicklung taktischer Überlaufregeln für ein flexibles Patientenflussmanagement und Krankenhausweite Simulation als Evaluationsinstrument	47
5.1. Entwicklung flexibler Überlaufregeln	47
5.2. Simulation als Evaluationsrahmen des Patientenflussmanagements	51
5.2.1. Methodische Grundlagen zur ereignisdiskreten Simulation	51
5.2.2. Aktueller Stand der Forschungsliteratur	53
5.2.3. Simulationsmodell	55
5.2.4. Verifizierung und Validierung	62
5.3. Praxisorientierte Evaluation der Überlaufregeln	64
6. Operative Terminplanung elektiver Patienten unter Antizipation von Notfallpatienten mithilfe robuster Optimierung	69
6.1. Zielstellung der operativen Terminplanung	69
6.2. Aktueller Stand der Literatur und Formalisierung der operativen Terminplanung elektiver Patienten	71
6.3. Methodische Grundlagen der Netzwerkmodellierung und der robusten linearen Optimierung	74
6.4. Darstellung der Terminplanung elektiver Patienten als Netzwerkfluss-Problem	79
6.5. Lineares stochastisches Optimierungsmodell	83
6.5.1. Überlegungen zur robusten Optimierung	84
6.5.2. Definitionen	85
6.5.3. Mathematisches Modell	87
6.5.4. Flussdekomposition	91
6.6. Evaluation der Praxistauglichkeit	92
7. Operative wissensbasierte Handlungsrichtlinien für die Steuerung des Patientenflusses bei Kapazitätsengpässen	97
7.1. Beschreibung der Problemstellungen der Patientenflusssteuerung und des benötigten Wissens zur Entscheidungsunterstützung	97
7.2. Entwirrung der klinischen und organisatorischen Struktur zur Gewinnung operativen Wissens	100
7.3. Flexible, auf situationsabhängigen Richtlinien basierende Entscheidungsfindung	103

Inhaltsverzeichnis

7.4.	Datengetriebene Wissensgewinnung	106
7.4.1.	Data-Mining Verfahren zur Generierung der Behandlungspfade	106
7.4.2.	Datengetriebene Kompetenzberechnung für einzelne Behandlungsschritte	107
7.4.3.	Erstellung von Listen geeigneter Stationen	109
7.4.4.	Evaluation	110
7.5.	Fallstudie	112
7.5.1.	Szenarien und Kennzahlen	112
7.5.2.	Evaluation realer Daten mit verschiedenen Qualitätsniveaus	115
7.5.3.	Generelle Erhöhung der Patientenzahlen	118
7.5.4.	Sprunghafte Erhöhung der Patientenzahlen	119
8.	Fazit	123
	Literaturverzeichnis	127
	Anhang	149
A.	A Two-Dimensional Categorization Scheme for Simulation / Optimization-Based Decision Support in Hospitals Applied to Overall Bed Management in Interdependent Wards Under Flexibility	151
B.	AI/OR Synergies of Process Mining with Optimal Planning of Patient Pathways for Effective Hospital-Wide Decision Support . .	185
C.	Simulation stationsübergreifender Patientenflüsse zur Evaluation flexibler Bettenbelegungsszenarien aufgrund der Jahresdatenanalyse eines Universitätsklinikums	219
D.	A Generic Simulation-based DSS for Evaluating Flexible Ward Clusters in Hospital Occupancy Management	235
E.	Data-Driven Patient Flow Management via Mining Clinical and Operational Knowledge and Evaluation by Hospital-Wide Simulation	247

Abbildungsverzeichnis

1.1.	Generelle Planungsprobleme im Belegungsmanagement	2
1.2.	Forschungsmethodik des Operations Research	7
1.3.	Problemstellung der Arbeit und Gliederung im Kontext des Operations Research	9
2.1.	Aufbau eines Krankenhauses	12
2.2.	Kern- und Unterstützungsprozesse eines Krankenhauses	13
2.3.	Problembasierte Interdependenzen	20
2.4.	Funktionelle Interdependenzen	21
3.1.	Schematische Darstellung eines klinischen Pfades	25
3.2.	Schematische Darstellung des krankenhausesweiten Patientenflusses	29
3.3.	Gegenläufige Belastungsverläufe von Stationen	33
3.4.	Zwei-Dimensionales Klassifizierungsschema	39
4.1.	Datenstruktur gemäß §21 KHEntgG	45
5.1.	Einordnung der Simulationsmodelle	52
5.2.	Grundlegende Simulationslogik	55
5.3.	Belegungsheuristik	58
5.4.	Simulationsobjekte	59
5.5.	Einordnung des Simulationsmodells in einen datengetriebenen Simulator und dessen Nutzung	61
5.6.	Validierung der Verweildauern und der Ankunftszeiten	62
5.7.	Validierung der Verweildauern und der Behandlungsanzahl	63
5.8.	Veränderung der Wartezeit in S1	65
5.9.	Veränderungen der Wartezeiten in S2	66
5.10.	Nutzung virtueller Betten in den Clusterkonfigurationen von S3 . .	66
6.1.	Darstellung eines simplen Graphens und eines Umladeproblems .	75

Abbildungsverzeichnis

6.2. Netzwerkflussmodell für elektive Patienten und stationäre Notfallpatienten	80
6.3. Beispielhaftes Netzwerk für den Fluss im Krankenhaus	81
6.4. Gesamtdarstellung des Netzwerkflusses	82
6.5. Abweichungen der szenariooptimalen und gesamtoptimalen Lösungen	94
6.6. Patientenanteile nach der Optimierung	94
6.7. Simulationsergebnisse der ermittelten Terminpläne	96
7.1. Konzept der Wissensgenerierung und -Nutzung	101
7.2. Visualisierung der Handlungsrichtlinien	104
7.3. Operative Strategien zur Patientenbelegung	105
7.4. Data-Mining Algorithmus und Beispiel	106
7.5. Frequenzprofile von Behandlungen und darauf aufbauende Kompetenzbewertung	108
7.6. Beispiel einer Liste geeigneter Stationen	109
7.7. Statistische Auswertung der Behandlungspfade	110
7.8. Anzahl alternativer Stationen in verschiedenen Stadien der Behandlung	111
7.9. Entwicklung der Patientenzahlen	114
7.10. Grafische Evaluation der VF-Strategie	116
7.11. Evaluation der VF- und NU-Strategie	118
7.12. Entwicklung der Patientenzahlen während einer Pandemie	120
7.13. Anzahl aufgenommener und abgelehnter Patienten im Pandemieszenario	120
7.14. Anzahl aufgenommener und abgelehnter Patienten im Unfallszenario	121

Tabellenverzeichnis

1.1. Auflistung bereits publizierter oder vorbereiteter Arbeiten	9
2.1. Typen von Interdependenzen	18
3.1. Einordnung der Literatur in das Klassifizierungsschema	40
5.1. Zusammensetzung der Clusterkonfiguration 1 (CC-1)	49
5.2. Zusammensetzung der Clusterkonfiguration 2 (CC-2)	49
5.3. Zusammensetzung der Clusterkonfiguration 3 (CC-3)	50
5.4. Ankunftsverteilungen	56
5.5. Patientenverteilungen	57
5.6. Stationsverteilungen	57
6.1. Formalisierung der Terminplanung	73
6.2. Nebenbedingungen	74
6.3. Parameter des Optimierungsmodells	85
6.4. Mengen zur Konstruktion des Optimierungsmodells	85
6.5. Knotenmengen für elektive Patienten	86
6.6. Knotenmengen für stationäre Notfallpatienten	86
6.7. Kosten für Patientenbelegungen im Optimierungsmodell	92
7.1. Darstellung der Handlungsrichtlinien	104
7.2. Szenarien der Fallstudie	114
7.3. Kennzahlen zur Evaluation der Fallstudien	115
7.4. Evaluation der VF-Strategie	116
7.5. Evaluation der Umleitungen und Umlagerungen	117
7.6. Evaluation erhöhter Patientenzahlen	118

Abkürzungsverzeichnis

AI	artificial intelligence
CC-1	Clusterkonfiguration 1
CC-2	Clusterkonfiguration 2
CC-3	Clusterkonfiguration 3
DES	Ereignisdiskrete Simulation
DIMDI	Deutsches Institut für Medizinische Dokumentation und Information
DRG	Diagnosis Related Group
FAB	Fachabteilung
G-DRG	German Diagnosis Related Groups
HC	Harte Restriktion
ICD-10	International Statistical Classification of Diseases and Related Health Problems
IMC	Intermediate Care
InEk GmbH	Institut für das Entgeltsystem im Krankenhaus GmbH
ITS	Intensivstation
KHEntgG	Krankenhausentgeltgesetz
KPI	Key Performance Indicator
MQN	minimales Qualitätsniveau
NU	Nur Umleitungen
OPS	Operationen und Prozeduren
OR	Operations Research
PAS	Patient Admission Scheduling
SC	Weiche Nebenbedingung
VF	Volle Flexibilität
ZNA	Zentrale Notaufnahme

1. Einleitung

Die Gesundheit ist eines der wichtigsten Güter, die ein Mensch besitzen kann. Zur Aufrechterhaltung oder zur Wiederherstellung der Gesundheit sind in allen Ländern der Welt komplexe Systeme, bestehend aus niedergelassenen Ärzten, Apotheken, Krankenhäusern und Krankenkassen, entstanden. Mit 375,6 Milliarden Euro erreichten die Ausgaben für das deutsche Gesundheitswesen im Jahr 2017 einen Anteil von 11,5 % am Bruttoinlandsprodukt. Auf die Krankenhäuser entfallen dabei 103,5 Milliarden Euro. Dies entspricht 27,5 % der Gesamtausgaben für das Gesundheitssystem. Somit bilden Krankenhäuser kostenseitig einen der größten Akteure im deutschen Gesundheitswesen. Hohe Kosten in Verbindung mit einem geänderten Abrechnungssystem führen zu einer wirtschaftlich angespannten Situation. Laut einer Studie [15] erwirtschafteten im Jahr 2018 32 % der Krankenhäuser ein Defizit. Im Laufe der Zeit verschlimmert sich die Situation immer mehr. Im Jahr 2022 erwirtschafteten 49 % aller Kliniken Deutschlands ein Defizit [16]. Zusätzlich erwarten 72 % der Krankenhäuser mit mehr als 1.000 Betten eine weitere Verschlechterung ihrer wirtschaftlichen Situation. Dies erzeugt, ergänzend zur 2003 eingeführten DRG-basierten Abrechnung von Krankenhausleistungen, einen enormen wettbewerbsbedingten Reformdruck. Einrichtungen, die ihre Kosten- und Prozessstrukturen nicht den Bedingungen anpassen können, sind existenziell bedroht [116]. Prozessverbesserungen und die Evaluation ihrer Auswirkungen sind aufgrund der interdependenten Struktur eines Krankenhauses schwierig umzusetzen und bieten die Grundlage für folgendes Zitat von Drucker [50]:

"Healthcare is the most difficult, chaotic and complex industry to manage and the hospital is altogether the most complex human organization ever devised."

Für die Behandlungen von Patienten müssen ausreichend Bettenkapazitäten zur Verfügung stehen. Die Aufgabe eines krankenhausesweiten Belegungsmanagements besteht dabei darin, jedem Patienten zu jeder Zeit ein geeignetes Bett bereitzustellen. Dabei sind das Management und die Steuerung des Patientenflusses, also der

1. Einleitung

Bewegung der Patienten durch den gesamten Behandlungsprozess, im Kontext vom Belegungsmanagement von besonderer Bedeutung. Die vor allem in großen Krankenhäusern vorzufindende interdependente Struktur, bestehend aus einer Vielzahl an fachspezifischen und allgemeinen Stationen, zwingt die Krankenhäuser zur Nutzung von komplexeren und ausgereifteren Managementansätzen. Vor allem das isolierte Betrachten einzelner Krankenhausbereiche, wie in vielen wissenschaftlichen Arbeiten vorgeschlagen, ist nicht ausreichend, um den Patientenfluss im gesamten Krankenhaus effizienter zu gestalten. Ein System aus lokalen Optima stellt nicht zwangsläufig ein optimales Gesamtsystem dar [60]. Zum Beispiel zeigt eine quantitative Analyse des Patientenflusses in einem Krankenhaus, dass eine Prozessverbesserung in der Zentralen Notaufnahme (ZNA) nicht in einer Leistungsverbesserung des gesamten Klinikums endet [99]. Aus diesem Grund konzentriert sich diese Arbeit nicht auf lokale Verbesserungen in einzelnen Bereichen des Krankenhauses, sondern auf das Bereitstellen von krankenhausesweiten Ansätzen zum Patientenflussmanagement.

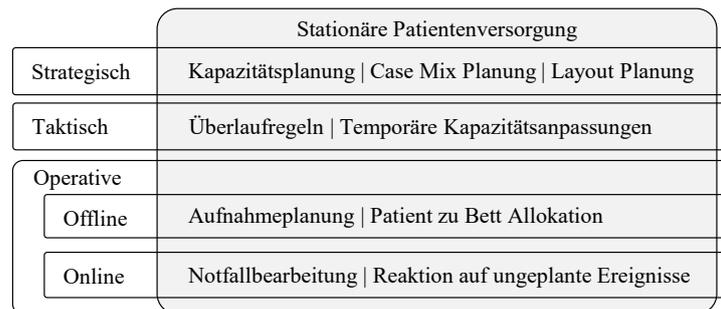


Abbildung 1.1.: Generelle Planungsprobleme im Belegungsmanagement (Quelle: [87])

Die Aufgabe des klinischen Patientenflussmanagements ist die Sicherstellung, dass jeder Patient zur richtigen Zeit im richtigen Bett liegt [171]. Somit werden alle geplanten und ungeplanten Aufnahmen gesteuert. In der Regel werden dazu in den Krankenhäusern die Positionen des Belegungsmanagers oder des Casemanagers geschaffen. Zu deren Aufgaben gehört die strategische Steuerung der Belegung durch Festlegungen von Kapazitäten und Belegungsstrategien, die Moderation von abteilungsübergreifenden Abstimmungsprozessen und das Konfliktmanagement und die Entscheidungsfindung bei Kapazitätsengpässen auf den Stationen [141]. Diese Aufgabe verbindet das Patientenflussmanagement direkt mit den in Abbildung 1.1 dargestellten Planungsproblemen des Kapazitätsmanagements.

1. Einleitung

Die Entscheidungs- und Planungsprobleme können in verschiedene Detailstufen eingeteilt werden: strategisch, taktisch, offline operativ und online operativ. In der Regel beschreiben strategische Planungsprobleme strukturelle Entscheidungsprobleme, wie zum Beispiel das Festlegen von Behandlungskapazitäten. Auf taktischer Ebene steht die Organisation des Betriebs im Vordergrund. Dabei werden vorwiegend Strategien zur Kapazitätsnutzung entwickelt und evaluiert. Die operative Ebene ist in zwei Teilbereiche gegliedert. Die Offline-Ebene beschreibt die detaillierte Planung des Betriebes, während die Online-Ebene die tatsächliche Steuerung und die Reaktion auf unvorhergesehene Ereignisse darstellt [87].

Auf strategischer Ebene erfolgen eine langfristige Planung der Betten- und Behandlungskapazitäten und die allgemeine Gestaltung des Patientenmixes. Auf taktischer Ebene werden verschiedene Überlaufregeln implementiert und evaluiert. Zusätzlich können auf dieser Ebene temporäre Kapazitätsänderungen vorgenommen werden. Zum Beispiel können im Winter mehr Kapazitäten für Knochenbrüche vorgehalten werden als im Sommer. Die operative Planung beschäftigt sich mit der eigentlichen Aufnahmeplanung auf Patientenebene und deren Zuordnung zu Betten. Im operativen Betrieb der stationären Patientenversorgung erfolgt die Eingliederung von Notfallpatienten und wenn notwendig, eine Reaktion auf kurzfristig auftretende Kapazitätsengpässe. All diese Aufgaben dienen einem übergeordneten Ziel im Krankenhaus: Sicherstellung eines effizienten und reibungslosen Patientenflusses, um den allgemeinen Gesundheitszustand der Bevölkerung zu erhalten oder zu verbessern.

Im Allgemeinen beschreibt der Patientenfluss die Bewegung aller Patienten durch das Krankenhaus. Laut [41] kann dieser in zwei Perspektiven unterteilt werden. Die klinische Sicht beschreibt das Voranschreiten des Gesundheitszustandes eines Patienten, also die Veränderung von einem kritischen in einen weniger bedenklichen Zustand bis hin zur vollständigen Gesundheit. Die andere Seite charakterisiert die operative Perspektive des Patientenflusses. Dabei wird die Bewegung der Patienten durch eine Menge von physischen Organisationseinheiten im Krankenhaus beschrieben. Generell wird der Patientenfluss auf strategischer Ebene genutzt, um das generelle Systemverhalten eines Krankenhauses abzubilden. Dies wird für strategische Entscheidungen im Belegungsmanagement verwendet. Laut [18] kann dieser Patientenfluss als Warteschlangennetzwerk dargestellt werden. Grundlegend wird diese Art der Patientenflussmodellierung zur Kapazitätsdimensionierung im Krankenhaus verwendet.

Eine ausführliche Literauranalyse [87] zeigt das große Interesse an diesem Forschungsgebiet. Das Hauptziel ist dabei, die Auslastung einer einzelnen Organisationseinheit eines Krankenhauses unter Einhaltung spezifischer Qualitätsnormen zu maximieren. Dabei wird deutlich, dass die Krankenhäuser häufig einfache deterministische Tabellenkalkulationen nutzen, die zu einer Unterschätzung der benötigten Kapazität führen. Auffällig ist dabei, dass die in der Literatur vorgestellten Ansätze [61, 127, 128, 139] vorwiegend dazu verwendet werden, um die Kapazität für einzelne Organisationseinheiten festzulegen. Jedoch gilt die Kernaussage, dass größere Bereiche besser auf die Variabilität des Patientenflusses reagieren können und das Kapazitätsentscheidungen in einzelnen Abteilungen einen Effekt auf die Leistung anderer Organisationseinheiten haben [87]. Der Einfluss flexibler Kapazitätsnutzungen für die Kapazitätsplanung wird in der betrachteten Literatur nicht angesprochen.

Dies hat einen grundlegenden Einfluss auf die Entscheidungen auf der taktischen Ebene. Hier werden vor allem Überlaufregeln und temporäre Kapazitätsanpassungen durchgeführt [87]. Auf dieser Ebene muss der abstrakte Patientenfluss detaillierter betrachtet werden. Dabei wird die allgemeine Struktur beibehalten und auf Basis verschiedener Diagnosen in unterschiedliche Flusstypen aufgeteilt. Jeder Flusstyp erhält dabei eigene Ankunfts-, Transfer- und Verweildauerverteilungen. In der Literatur werden die temporären Kapazitätsanpassungen häufig mit einer Reduzierung der Kapazitäten aufgrund von Personalmangel gleichgesetzt [122]. Da die Bettenkapazität direkt von der Anzahl verfügbarer Mitarbeiter abhängt, kann durch eine angepasste Personalplanung die Menge der Betten in bestimmten Perioden reduziert werden, um damit die Auslastung zu erhöhen [72, 74]. Ist eine Änderung der disponiblen Kapazität nicht möglich, kann das Krankenhaus sogenannte Überlaufregeln nutzen. Dabei werden Patienten in andere Organisationseinheiten umgeleitet, um eine Aufnahme zu ermöglichen. Die Regeln spezifizieren dabei, in welche Organisationseinheiten diese Patienten verlegt werden können. Die wissenschaftliche Literatur konzentriert sich dabei auf die Untersuchung der Auswirkungen solcher Strategien [62, 71, 81, 122, 152].

Auf der detaillierten operativen Ebene besteht der Patientenfluss aus individuellen Patienten mit allen Eigenschaften, um patientenzentrierte Entscheidungen zu treffen. Hier wird vorwiegend eine Aufnahmeplanung mit der gleichzeitigen Zuordnung eines geeigneten Bettes durchgeführt [31, 45]. Dies erfolgt ein paar Tage vor der eigentlichen Aufnahme für elektive Patienten. In der wissenschaftlichen Fachliteratur wird das als operative Offline-Planung bezeichnet. Aufgrund der

Komplexität der verwendeten Entscheidungsmodelle erfolgt die Planung in der Regel für eine Organisationseinheit. Somit werden wenige flexible Ressourcenallokationen untersucht. Im operativen Tagesbetrieb muss ein Krankenhaus, basierend auf seinem aktuellen Status entscheiden, ob geplante elektive Aufnahmen durchgeführt werden können oder verschoben werden müssen. Im gleichen Atemzug müssen hier ungeplante Notfallaufnahmen betrachtet werden. Diese werden mithilfe von Ad-hoc Entscheidungen auf freie Kapazitäten verteilt [87]. Die Forschung in diesem Bereich steht noch in der Anfangsphase, daher existieren nur wenige Artikel, die eine Entscheidungsunterstützung für das klinische Fachpersonal bieten. Vorwiegend konzentriert sich die Forschung dabei auf das automatisierte Generieren von Patientenfäden, ohne den Fokus auf die Anwendbarkeit dieser Ergebnisse zu legen [57, 93, 142].

Diese Dissertation schließt diese Lücke, indem sie grundlegende Fragestellungen im Patientenflussmanagement im krankenhausweiten Kontext modelliert und löst. Da sich der Patientenfluss in verschiedenen Organisationseinheiten deutlich in Bezug auf den Patientenmix und der Nachfrage unterscheiden kann, können sich besondere Situationen ergeben. In einem Beispiel mit zwei Stationen kann sich eine Station in einer Engpasssituation befinden, während die andere freie Kapazitäten zur Verfügung hat. Durch die variable Natur des Patientenflusses kann sich diese Situation sehr schnell ins Gegenteil umkehren, sodass die zweite Station einen Kapazitätsengpass hat und die erste Station freie Kapazitäten zur Verfügung hat. Eine einfache Kapazitätserhöhung löst dieses Problem nur, wenn auf beiden Stationen die Kapazität massiv erhöht wird. Wenn sich die einzelnen Stationen nicht dauerhaft in einer Engpasssituation befinden, geht dieser Ansatz zulasten einer hohen Auslastung der Stationen. Richtlinien und Verfahren für das Patientenflussmanagement auf planerischer und operativer Ebene sollten daher verschiedene Arten und Grade von Flexibilität bieten, um mögliche Engpasssituationen auflösen zu können, ohne in zusätzliche Kapazitäten zu investieren. Das ist auf das Bestreben des Krankenhauses zurückzuführen, seine Auslastung zu maximieren. Tendenziell benötigt die Maximierung der Auslastung folgende zwei Komponenten:

1. Erhöhung des elektiven Patientenflusses durch die Nutzung flexibler Planungswerkzeuge
2. Nutzung operativer Richtlinien zum Auflösen unvermeidbarer, durch (1) hervorgerufenen, Engpässen

In dieser Arbeit wird gezeigt, dass eine Maximierung der Auslastung ohne Verschlechterung der Reaktionsfähigkeit auf Kapazitätsengpässe möglich ist. Dies wird durch den Einsatz intelligenter datengetriebener Ansätze, die das benötigte Wissen aus historischen Daten extrahieren, ermöglicht. Während Stresssituationen treffen Experten Ad-hoc Entscheidungen, um Kapazitätsengpässe zu vermeiden. Diese sind tendenziell unstrukturiert und undokumentiert. Aus diesem Grund ist es für Entscheidungsträger und Krankenhäuser von entscheidender Bedeutung, operative Richtlinien und Planungsverfahren zu besitzen, die die Entscheidungsfindung strukturieren können. Sie ermöglichen schnelle und qualitativ hochwertige Entscheidungen.

Daraus ergeben sich die grundlegenden Zielstellungen dieser Arbeit. Das übergeordnete Ziel ist es, die Effizienz und die wirtschaftliche Leistungsfähigkeit eines Krankenhauses ohne große Infrastrukturinvestitionen zu erhöhen. Um dies zu erreichen, erfolgt eine ganzheitliche, auf Patientenflüssen basierende Unterstützung des krankenhausesweiten Belegungsmanagements auf strategischer, taktischer und operativer Ebene. Zur Evaluation komplexer Systeme bietet sich die Nutzung von Simulationsmodellen an. Um nicht für jede Fragestellung ein eigenes Modell zu entwickeln, wird im Rahmen dieser Arbeit ein generisches krankenhausesweites anpassbares Simulationsmodell erstellt, das für die verschiedenen Problemstellungen genutzt werden kann. Zusätzlich sind viele der gezeigten Ansätze auf spezielle Krankenhäuser zugeschnitten. Der Anspruch dieser Arbeit ist es, die vorgestellten Ansätze ohne aufwendige Anpassungen in verschiedenen Krankenhäusern einzusetzen. Aus diesem Grund basieren alle Entscheidungs- und Evaluationsverfahren in dieser Arbeit auf standardisierten Routinedaten, die jedes Krankenhaus in Deutschland aufnehmen und melden muss [91].

Zusammengefasst ergeben sich folgende Ziele und Unterziele:

1. Erhöhung der Effizienz und wirtschaftlichen Leistungsfähigkeit durch flexible Kapazitätsnutzung ohne zusätzliche Investitionen

durch

2. Entwicklung von Modellen zur ganzheitlichen krankenhausesweiten Unterstützung des Patientenflussmanagements mit
 - a) Überlaufregeln auf taktischer Ebene
 - b) Terminplanung elektiver Patienten auf operativer Ebene
 - c) Datengetriebenes operatives Patientenflussmanagement

1. Einleitung

evaluiert mit

3. krankenhausweiten generischen Simulationsmodellen mit
 - a) allen relevanten Prozessen des Belegungsmanagements
 - b) Erfassung aller relevanten Organisationseinheiten eines Krankenhauses
 - c) einfacher Anpassbarkeit auf verschiedene Problemstellungen

ermöglicht durch

4. datengetriebene Wissensakquirierung für
 - a) medizinisches Wissen
 - b) organisatorisches Wissen
 - c) operatives Wissen

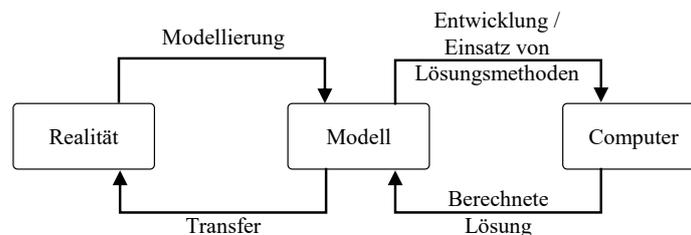


Abbildung 1.2.: Forschungsmethodik des Operations Research (Quelle: [158])

Grundlegend lässt sich diese Arbeit in die Forschungsdisziplin des Operations Research einordnen, welche definiert ist als die Wissenschaft der Entwicklung und Anwendung fortgeschrittener analytischer Methoden zur Entscheidungsunterstützung [158]. Dabei besteht die Hauptaufgabe in der Entwicklung und Verbesserung von Modellen, Algorithmen, Methoden und Software [115]. Eine aussagekräftige Darstellung des Aufgabengebietes des Operation Research ist in Abbildung 1.2 gegeben. Dabei wird die vorhandene Realität über Modellierungstechniken in ein formales Modell überführt, um es anschließend mithilfe von Lösungsmodellen am Computer zu berechnen. Diese Lösungen werden in das formale Modell übertragen und schlussendlich in die Realität zur Entscheidungsunterstützung transferiert. Somit lässt sich diese Dissertation in den Bereich der Design Science einordnen. Dabei werden, ausgehend von einer Problemstellung, Artefakte erstellt und evaluiert, die Entscheidungsträger in ihrer Arbeit unterstützen sollen [82]. Dieses grundlegende Vorgehensmodell des Operations Research wird verwendet,

um diese Arbeit zu gliedern. Ein schematischer Überblick über die Gliederung ist in Abbildung 1.3 gegeben. Basierend auf dieser Darstellung ist diese Dissertation folgendermaßen strukturiert: Im folgenden zweiten Kapitel wird das Krankenhaus mit seinen Kernprozessen und den grundlegenden Ressourcenarten charakterisiert und definiert. Die komplexen Wechselwirkungen zwischen einzelnen Prozessen und Ressourcen führen zu vielfältigen Abhängigkeiten, die im Management der Patientenflüsse berücksichtigt werden müssen. Aus diesem Grund schließt dieses Kapitel mit der Definition und Kategorisierung dieser Interdependenzen. Das dritte Kapitel widmet sich dem Patientenflussmanagement. Dabei wird eine generelle krankenhausesweite Modellierung des Patientenflusses vorgestellt, um anschließend die klinischen Behandlungspfade als Grundlage für das operative Patientenflussmanagement einzuführen. Diese Diskussionen liefern die Grundlage für ein flexibles Patientenflussmanagement, welches anschließend in Kombination mit einer Klassifizierung der einzelnen Entscheidungsprobleme eingeführt wird. Im vierten Kapitel wird die Datengrundlage dieser Arbeit vorgestellt und der Beispieldatensatz näher erläutert. Im fünften Kapitel werden verschiedene Überlaufstrategien diskutiert und ihr Einfluss auf strategische Kapazitätsentscheidungen und taktische Organisationsentscheidungen gezeigt. Das darauf aufbauende sechste Kapitel zeigt einen Ansatz zur operativen Planung von Patientenaufnahmen unter Berücksichtigung der eingeführten Überlaufregeln. Im siebten Kapitel werden die Ergebnisse verwendet, um einen Ansatz zur operativen Entscheidungsunterstützung für medizinisches Fachpersonal vorzustellen. Dabei werden auf Basis von aus den Daten gelernten Behandlungspfaden Entscheidungen über mögliche alternative Stationen getroffen, um verbleibende operative Engpasssituationen schnell aufzulösen.

Im Rahmen der Forschung in diesem Themengebiet wurden Teilaspekte dieser Arbeit bereits veröffentlicht. Auszüge aus der Diskussion zu den Interdependenzen und der Kategorisierung von Entscheidungsproblematiken in Krankenhäusern wurden in [157] und [123] publiziert. Das im Rahmen dieser Arbeit verwendete Simulationsmodell wurde in [77] und [79] veröffentlicht. In denselben Publikationen wurden die Überlaufregeln diskutiert und evaluiert. Die Verfahren und Ergebnisse zur operativen Planung des Patientenflusses sind für eine weitere Veröffentlichung in wissenschaftlichen Fachzeitschriften vorgesehen. Die Erkenntnisse und Methoden der operativen Patientenflussteuerung basieren auf einer jahrelangen Forschungskollaboration des Lehrstuhls für Wirtschaftsinformatik und Operations Research der Martin-Luther-Universität Halle-Wittenberg, vertreten durch den Autor und Herrn Prof. Dr. T. Mellouli, und der Faculty of Sciences and

1. Einleitung

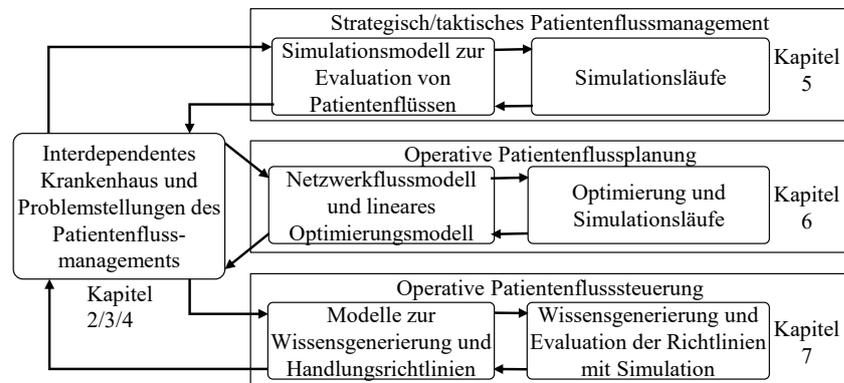


Abbildung 1.3.: Problemstellung der Arbeit und Gliederung im Kontext des Operations Research (Quelle: Eigene Darstellung in Anlehnung an [158])

Techniques der Universität Jean Monnet Saint Etienne, vertreten durch Herrn PD Dr. Malek Masmoudi. Auszüge der Ergebnisse dieser Kooperation befinden sich derzeit im Veröffentlichungsprozess. Eine Auflistung bereits erschienener Artikel und zur Publikation vorgesehener Arbeitspapiere sind in inhaltlicher Reihenfolge der Promotionsschrift in Tabelle 1.1 gegeben und die vollständigen Texte befinden sich in den Anhängen A bis E.

Tabelle 1.1.: Auflistung bereits publizierter oder vorbereiteter Arbeiten (Quelle: Eigene Darstellung)

Publikation	Inhalt
Stoeck, T und Mellouli, T (2021) A Two-Dimensional Categorization Scheme for Simulation /Optimization-Based Decision Support in Hospitals Applied to Overall Bed Management in Interdependent Wards Under Flexibility In: M. Masmoudi, B. Jarboui, P. Siarry (eds.) Operations Research and Simulation in Healthcare, 1 edn. Springer International Publishing (2021)	Definition der Interdependenzen Klassifikation von Problemstellungen im Patientenfluss- management Anhang A

1. Einleitung

Tabelle 1.1.: Auflistung bereits publizierter oder vorbereiteter Arbeiten Fortsetzung (Quelle: Eigene Darstellung)

Publikation	Inhalt
Mellouli, T und Stoeck, T (2021) AI/OR Synergies of Process Mining with Optimal Planning of Patient Pathways for Effective Hospital-Wide Decision Support In: M. Masmoudi, B. Jarboui, P. Siarry (eds.) Artificial Intelligence and Data Mining in Healthcare, 1 edn. Springer International Publishing (2021)	Diskussion der Einflüsse von Interdependenzen auf Planungsprobleme Diskussion der Synergien zwischen AI und OR Anhang B
Helbig, K, Mellouli, T, Stoeck, T, Gragert, M und Jahn, P (2014) Simulation stationsübergreifender Patientenflüsse zur Evaluation flexibler Bettenbelegungsszenarien aufgrund der Jahresdatenanalyse eines Universitätsklinikums In: Tagungsband der Multikonferenz Wirtschaftsinformatik 2014, pp. 749–762. Paderborn (2014)	Erste Iterationsstufe des Simulationsmodells Untersuchung von Szenarien im Patientenflussmanagement Anhang C
Helbig, K, Stoeck, T und Mellouli, T, (2015) A Generic Simulation-based DSS for Evaluating Flexible Ward Clusters in Hospital Occupancy Management In: Proceedings of the 48th Annual Hawaii International Conference on System Sciences, pp. 2923–2932. IEEE (2015)	Zweite Iterationsstufe des Simulationsmodells Diskussion interdisziplinärer Stationscluster Anhang D
Albrecht, T, Mellouli, T, Masmoudi, M (2022) Data-Driven Patient Flow Management via Mining Clinical and Operational Knowledge and Evaluation by Hospital-Wide Simulation In: Working Paper (2022)	Datengetriebene Wissensgewinnung zur Entscheidungsunterstützung Evaluation verschiedener Qualitätsniveaus Anhang E

2. Untersuchung interdependenter Krankenhausstrukturen

Aufgrund ihrer Größe und Komplexität nehmen Krankenhäuser eine Sonderstellung im deutschen Gesundheitswesen ein. Zur detaillierteren Betrachtung des Krankenhauses erfolgt in diesem Kapitel eine Vorstellung des grundlegenden Aufbaus eines Krankenhauses. Anschließend werden die verschiedenen Patientenarten definiert und die vom Krankenhaus zur Verfügung gestellten Ressourcen diskutiert. Das Kapitel wird von einer Klassifikation und Diskussion der Interdependenzen eines Krankenhauses abgeschlossen.

2.1. Aufbau und Kernprozesse eines Krankenhauses

Ein Krankenhaus nimmt eine besondere Stellung im Gesundheitswesen in Deutschland ein. Die Aufgabe eines Krankenhauses ist es, den Gesundheitsstatus eines Patienten wieder herzustellen. In Deutschland wird der überwiegende Teil der Behandlungen von niedergelassenen Ärzten oder Ambulanzen behandelt. Für langwierigere oder schwerere Krankheiten werden die Patienten stationär im Krankenhaus aufgenommen. Um diese Behandlungen zu gewährleisten, werden Ressourcen in Form von Betten, Mitarbeitern und medizinischem Gerät bereit gestellt. Aufgrund ihrer Größe sind die Krankenhäuser in unterschiedliche Fachbereiche unterteilt. Im Allgemeinen teilen sich alle Kliniken den gleichen schematischen Aufbau, der in Abbildung 2.1 dargestellt ist.

2. Untersuchung interdependenter Krankenhausstrukturen

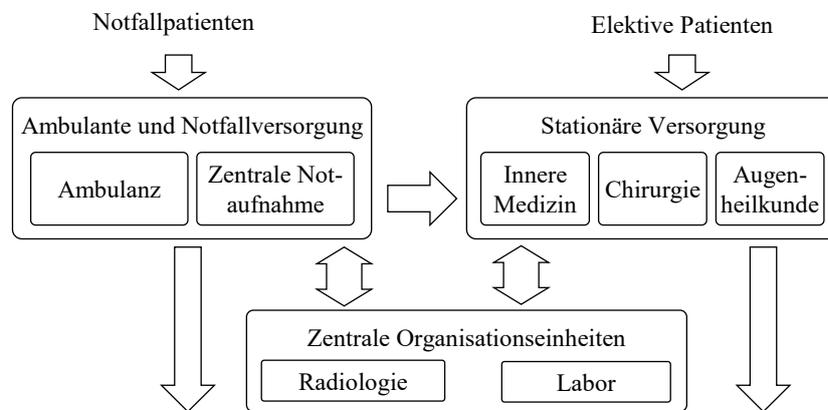


Abbildung 2.1.: Aufbau eines Krankenhauses (Quelle: eigene Darstellung)

Das Krankenhaus lässt sich in drei zentrale Bereiche gliedern. In der ambulanten Versorgung befinden sich je nach Größe des Krankenhauses für verschiedene Fachrichtungen Ambulanzen und eine Zentrale Notaufnahme (ZNA). Eine Charakteristik dieser Bereiche ist, dass sie keine Betten für stationäre Aufnahmen vorhalten und die Patienten nach der Behandlung das Krankenhaus direkt wieder verlassen. Während ihrer Behandlung können sie jedoch die Ressourcen der zentralen Organisationseinheiten, zum Beispiel Radiologie oder Labor, nutzen. Schwerwiegende Fälle können entweder direkt in der stationären Versorgung aufgenommen oder von der ZNA verlegt werden. Für die stationäre Behandlung hat sich eine Organisationsform etabliert, die sich in verschiedene Spezialisierungen, wie zum Beispiel Innere Medizin, Chirurgie oder Augenheilkunde, unterteilt. Innerhalb einer Fachabteilung (FAB) existieren verschiedene Stationen, die Bettenkapazitäten zur Aufnahme der Patienten bereitstellen. Zusätzlich können Behandlungsressourcen der zentralen Organisationseinrichtungen genutzt werden.

Aus prozessorientierter Sicht lässt sich das Krankenhaus in verschiedene Bereiche einteilen. Es werden im Krankenhaus Steuerungs-, Kern- und Unterstützungsprozesse unterschieden (Abb. 2.2). Die Steuerungsprozesse stellen die klassischen unternehmerischen Prozesse der Strategiefindung, des Marketings und des Controllings dar. Die Kernprozesse eines Krankenhauses beschreiben vorwiegend die medizinische Versorgung der Bevölkerung. Diese sind in den eigentlichen Behandlungsprozess, unterteilt in Aufnahme, Diagnose, Behandlung und Entlassung, und den pflegerischen Prozessen zur Patientenversorgung geteilt. Diese Kernpro-

2. Untersuchung interdependenter Krankenhausstrukturen

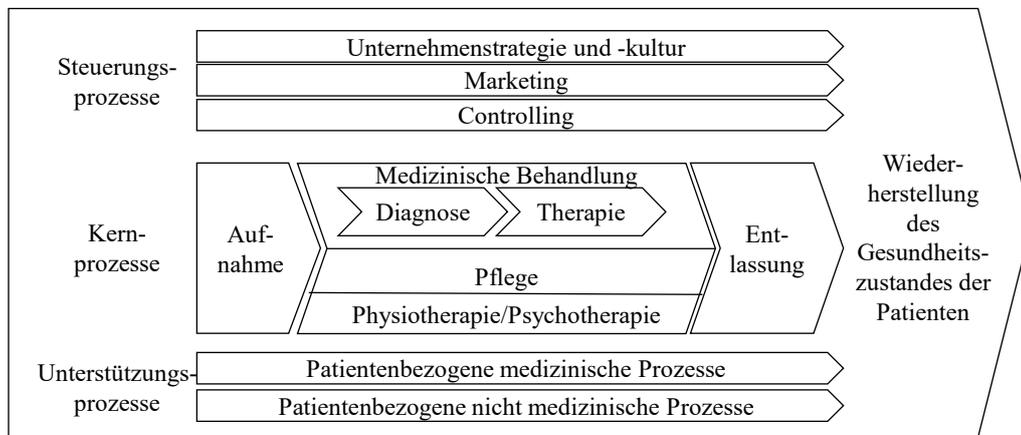


Abbildung 2.2.: Kern- und Unterstützungsprozesse eines Krankenhauses (Quelle: [150])

zesse werden von patientenbezogenen medizinischen und nicht-medizinischen Unterstützungsprozessen begleitet.

2.2. Patientenarten und Ressourcen im Krankenhaus

In einem Krankenhaus werden grundlegend zwei Typen von Patienten behandelt. Eine Unterscheidung erfolgt in elektive Patienten und Notfallpatienten, wobei der erste Typ im Vorfeld der Aufnahme bekannt ist. Dies bedeutet, dass bereits eine initiale Diagnose, eine Behandlung und eine Verweildauer festgelegt werden können. Zusätzlich betritt diese Art der Patienten das Krankenhaus direkt auf der für sie vorgesehenen Station. Diese Eigenschaften bewirken, dass diese Patienten planbar sind, ihre Behandlungen, Aufnahmetermine und in gewissem Maße die Verweildauern an die Situation in der Klinik und auf der Station angepasst werden können. Der zweite Typ ist im Gegenzug nicht planbar. Notfallpatienten erscheinen nach persönlichem Bedarf ohne Voranmeldung in der Notfallversorgung. In Ausnahmefällen, zum Beispiel bei einer spontanen Einweisung durch einen niedergelassenen Mediziner, können diese Patienten aber auch direkt auf der gewünschten Station aufgenommen werden. Notfallpatienten besitzen im Allgemeinen nur eine grobe Vorabdiagnose (bei Notfalleinweisung durch einen Arzt)

oder eine Menge von Symptomen ohne Diagnose (bei selbstständiger Anreise zur zentralen Notfallaufnahme (ZNA)). Aus diesem Grund lässt sich die Behandlung und Verweildauer im Vorfeld nicht abschätzen. Somit erzeugt diese Patientengruppe Unsicherheiten im Planungsprozess eines Krankenhauses. Dies erschwert eine verlässliche Planung über einen längeren Zeitraum. Dennoch ist es die Aufgabe eines Krankenhauses, möglichst viele Patienten unabhängig von ihrem Status mit den vorhandenen Ressourcen zu behandeln.

Zur Behandlung von Patienten stellt das Krankenhaus eine Reihe von Ressourcen zur Verfügung, Allen voran Betten. Sie bilden die maximale Behandlungskapazität ab, da jeder Patient ein Bett für seinen stationären Aufenthalt und seine Behandlung benötigt. In der Regel sind alle Betten eines Krankenhauses gleich ausgestattet. Sie, oder genauer gesagt, die Stellplätze innerhalb der Zimmer haben Anschlüsse für verschiedene medizinische Geräte zum Überwachen und Stabilisieren des Gesundheitszustandes eines Patienten. Aufstellorte von Patientenbetten werden als Patientenzimmer bezeichnet und eine Station eines Krankenhauses besteht aus einer baulich bedingten Menge an Räumen mit einer fest definierten Anzahl an Bettenstellplätzen. Hierbei ist besonders hervorzuheben, dass in deutschen Krankenhäusern eine strenge Geschlechtertrennung gilt. Die Anzahl der Bettenstellplätze muss dabei nicht zwangsläufig mit der verfügbaren Anzahl an Betten übereinstimmen. Die Menge der verfügbaren Betten ist von verschiedenen Faktoren abhängig. Die maximale Kapazität eines Krankenhauses wird durch den Bettenplan bestimmt, welcher von den Bundesländern in Deutschland auf Basis einer Bedarfsschätzung festgelegt wird [143]. Die Verteilung obliegt der Krankenhausplanung und kann unter Umständen an eine Detailprognose der Nachfrage angepasst werden. Dabei wird zusätzlich zwischen kalkulatorischen und planerisch verfügbaren Betten unterschieden. Die kalkulatorischen Betten stellen die Maximalkapazität dar. Damit ein Patient in einem Bett behandelt werden kann, muss entsprechendes Personal vorhanden sein. Erst mit einer ausreichend gesicherten Personalplanung kann ein Bett planerisch für die Behandlung von Patienten berücksichtigt werden. In dieser Arbeit wird davon ausgegangen, dass jedes verfügbare Bett auch mit dem entsprechenden Personal ausgestattet ist.

Die Belegschaft einer Station kann in verschiedene Kategorien eingeteilt werden. Zum einen das ärztliche und zum anderen das pflegerische Personal. Zusätzlich ist im Krankenhaus noch weiteres Hilfspersonal für die unterstützenden Prozesse, wie zum Beispiel den Transport von Patienten, angestellt. Die verschiedenen Mitarbeitergruppen sind nach Qualifizierungen unterteilt. Aus ärztlicher Sicht

2. Untersuchung interdependenter Krankenhausstrukturen

wird in Assistenzärzte, Fachärzte, Oberärzte und Chefärzte unterschieden. Diese unterscheiden sich hinsichtlich ihrer Qualifizierung und Befugnisse. Ähnlich verhält es sich beim pflegerischen Personal, hier werden Krankenschwestern, Fachkrankenschwestern und Oberkrankenschwestern unterschieden. Innerhalb dieser Hierarchieebenen können sich die Mitarbeiter auch in den speziellen Fähigkeiten unterscheiden. Um einen Patienten erfolgreich zu behandeln, sind unterschiedliche Kenntnisse des pflegerischen und ärztlichen Personals notwendig. Somit ist eine Behandlung oft nur möglich, wenn verschiedene Mitarbeiter zusammen arbeiten.

Die letzte von Krankenhäusern bereitgestellte Ressourcenart sind die gemeinsam genutzten Kapazitäten in zentralen Organisationseinheiten. Sie werden im Rahmen der Behandlung von Patienten benötigt, aber nicht dauerhaft allokiert. Dabei kann es sich zum Beispiel um Kapazitäten in der bildgebenden Diagnostik oder in Operationssälen handeln. Eine Besonderheit dieser Ressourcen ist, dass hier eine oft stunden- oder minutengenaue Terminplanung erfolgen muss. Dies bildet eine eigene Forschungsrichtung, die ausgiebig in der Forschungsliteratur betrachtet wird. Zur feineren Untersuchung dieser Problemstellung seien verschiedene Übersichtsarbeiten empfohlen [28, 117, 118].

Besonders auffallend ist dabei, dass alle Ressourcen, die für die Versorgung eines Patienten benötigt werden, von den Betten subsumiert werden. Das bedeutet, ohne sie ist keine weitergehende Behandlung möglich. Zusätzlich ist aufgrund der Annahme, dass jedes nutzbare Bett mit ausreichend Personal ausgestattet ist, eine Personalplanung im Rahmen dieser Arbeit nicht notwendig. Daher ist der Schluss nahe, dass die kapazitätsbasierte Planung und Steuerung des Patientenflusses der Input für alle folgenden Planungsentscheidungen für gemeinsam genutzte Ressourcen und Mitarbeiter darstellt.

Die Bettenkapazitäten können im Detail noch weiter aufgeteilt werden. In der Regel teilt ein Krankenhaus seine verfügbare Kapazität in zwei Gruppen ein. Zum einen in planbare und zum anderen in reservierte Betten für Ad-hoc Entscheidungen. In der Regel ist diese Aufteilung fix und die Literatur schlägt ein Verhältnis von 85 % zu 15 % vor [23]. Die Planung erfolgt über eine Terminvergabe für elektive Patienten. Aus betriebswirtschaftlicher Sicht stellt dies die maximal planbare Kapazität dar. Ein Krankenhaus versucht, diesen Teil so gut wie möglich auszulasten. Die Planung kann durch systemische Engpässe erschwert werden. Ist die Kapazität so gewählt, dass die langfristig bekannte Nachfrage nach Behandlungen nicht bedient

2. Untersuchung interdependenter Krankenhausstrukturen

werden kann, kommt es zu Ablehnungen von Patienten, langen Wartezeiten und einem Verlust von Umsatz. Die reservierten Anteile werden im Tagesbetrieb mit im Vorfeld unbekanntem Notfallpatienten belegt. Sie verursachen kurzfristige Belastungsspitzen, wenn die realisierte Nachfrage höher ist als die antizipierte.

Aufgabe des strategischen Betten- und Belegungsmanagements als Grundlage des Patientenflussmanagements ist es, die Aufteilung der planbaren und der Ad-hoc Kapazitäten festzulegen. Dabei muss eine Abwägungsentscheidung zwischen einer hohen planbaren Anzahl an Betten und daraus resultierend weniger Puffer für operative Notfälle oder einem großen Puffer für ungeplante Patienten zum Preis einer gesunkenen kalkulierbaren Auslastung erfolgen. Um wirtschaftlich überlebensfähig zu bleiben, sollte das Krankenhaus die planbare Kapazität so hoch wie möglich ansetzen. Dabei kommt es aber unweigerlich zu operativen Engpässen, die durch ein flexibles Patientenflussmanagement behandelt werden müssen. Explizit stellt diese Arbeit ein ganzheitliches Planungsverfahren dar, das nicht auf fixen Kapazitätsgruppen basiert, sondern die Verteilung der Kapazitäten dynamisiert. Dabei antizipieren die einzelnen Stufen der Planung die Nachfrage der Notfallpatienten. Auf taktischer Ebene werden verschiedene Überlaufstrategien evaluiert. Zusätzlich wird diese Planungsstufe verwendet, um strategisch zu untersuchen, inwieweit die Kapazitäten, also die Anzahl der verfügbaren Betten, geändert werden müssen, um eine festgelegte Auslastung zu erreichen. Im Bereich der operativen Planung werden die evaluierten Strategien in ein Planungsverfahren integriert, um proaktiv mögliche Engpasssituationen zu verhindern. Jedoch lassen sich durch die stochastische Natur der Notfallpatienten nicht alle Engpässe vermeiden. Aus diesem Grund stellt diese Arbeit weiterhin datengetriebene operative Handlungsrichtlinien vor, um diese Situationen aufzulösen.

Die Planung und Steuerung des Patientenflusses basiert dabei auf der Tatsache, dass in komplexen Krankenhäusern Interdependenzen zwischen den einzelnen Organisationseinheiten, Prozessen und Ressourcen bestehen. Diese Komplexitäten bewirken verschieden starke Wechselwirkungen, die im folgenden Abschnitt detaillierter definiert und diskutiert werden.

2.3. Interependenzen eines Krankenhauses

Interdependente Strukturen im Krankenhaus stellen Manager, Planer und Entscheider vor immer neue Herausforderungen. Um die Einflüsse der Wechselwirkungen zu verstehen und zu klassifizieren, werden im folgenden Kapitel verschiedene Typen von Interdependenzen diskutiert. Teile der Inhalte und Diskussionen in diesem Abschnitt wurden bereits in [157] und [123] veröffentlicht. Interdependenzen beschreiben die Interaktionen, Wechselwirkungen und Abhängigkeiten von mindestens zwei Akteuren, Prozessen oder Problemstellungen. In der aktuellen Forschungsliteratur zur Entscheidungsunterstützung im Krankenhaus werden diese wichtigen Eigenschaften eines komplexen zusammengesetzten Systems nicht im Detail untersucht oder klassifiziert. Die wenigen Arbeiten, die sich mit der Problemstellung beschäftigen, konzentrieren sich auf eine Art der Interdependenzen oder treffen Annahmen, um mit ihnen umzugehen. Eine detailliertere Beschreibung, Klassifikation und Diskussion der Interdependenzen ist notwendig, um deren Einfluss auf die Planungsprobleme eines Krankenhauses genauer zu verstehen. Zusätzlich können in verschiedenen Situationen Interdependenzen ausgenutzt werden, um den Entscheidungsträger im Krankenhaus mit dem benötigten Grad an Flexibilität auszustatten, um unvorhergesehene Probleme zu lösen. Das Level der Abstraktion des Entscheidungsproblems ändert die Natur und den Einfluss von Interdependenzen. Grundlegend haben sie eine große Wirkung auf die Modellierung von Entscheidungsproblemen. Je mehr Interdependenzen betrachtet werden, umso komplexer wird das Entscheidungsproblem.

Im Folgenden werden sechs Kategorien von Interdependenzen vorgeschlagen, die in zwei Haupttypen unterschieden werden können, die in Tabelle 2.1 dargestellt sind. Der erste Haupttyp ist dadurch charakterisiert, dass sich diese Interdependenzen auf Kosten einer gestiegenen Komplexität in Planungsprobleme integrieren. Dadurch ergeben sich in der Regel detailliertere Planungsmodelle, deren Ergebnisse einfacher in den operativen Betrieb überführt werden können. Der erste Haupttyp unterteilt sich in kapazitäts-, mitarbeiter- und problembasierte Interdependenzen. Der zweite Haupttyp, zusammengesetzt aus prozess-, funktional- und patientenbasierte Interdependenzen, sind in der Modellierung sehr komplex und lassen sich daher nur schwer in klassische Planungsprobleme überführen. Um eine krankenhausweite Entscheidungsunterstützung zu gewährleisten, ist es von entscheidender Bedeutung, diese Art der Interdependenzen in ihrem Verhalten zu verstehen. Sie beziehen sich in der Regel auf organisatorische Strukturen und Fra-

2. Untersuchung interdependenter Krankenhausstrukturen

Tabelle 2.1.: Typen von Interdependenzen (Quelle: Eigene Darstellung)

Name	Eigenschaften
kapazitätsbasierte	Wettbewerb um geteilte Ressourcen
mitarbeiterbasierte	Mitarbeiterspezialisierungen und Hierarchieebenen
problembasierte	Beziehung zwischen Planungsproblemen
prozessbasierte	Effekte lokaler Optimierungen auf das System
funktionalbasierte	Anbieten verschiedener Behandlungen
patientenbasierte	Beziehungen zwischen Patientengruppen

gestellungen. Eine Integration in klassische Problemstellungen des Krankenhauses ergibt somit eine Erweiterung des Planungsfokusses auf die organisatorischen Beziehungen zwischen den Organisationseinheiten eines Krankenhauses.

Kapazitätsbasierte Interdependenzen beziehen sich auf den Wettbewerb um Ressourcen im Krankenhaus. Hierbei kann es sich um zentrale gemeinsam genutzte Einrichtungen eines Krankenhauses, wie zum Beispiel der Radiologie, oder um begrenzte Kapazitäten einer Station handeln. Auf einer Station haben verschiedenen Patienten unterschiedliche Bedarfe an Ressourcen [10, 63], in diesem Fall Betten. Dabei werden zwei Arten unterschieden. Zum einen existiert in deutschen Krankenhäusern eine strenge Geschlechtertrennung. Dies bewirkt, dass bei Mehrbettzimmern auf einer Station die tatsächlich nutzbare Menge von Betten von der Gesamtkapazität abweicht und von der aktuellen Geschlechterbelegung abhängig ist. Als zweiter Fall können Isolationspatienten, das heißt Patienten mit einem multiresistenten Keim oder einer stark ansteckenden Krankheit, die verfügbare Kapazität drastisch reduzieren. Diese Patientengruppe muss zwingend alleine in einem Zimmer behandelt werden. Somit wird jeder Raum, welcher mit einem Isolationspatienten belegt ist, unabhängig von der initialen Kapazität zu einem Einzelzimmer. Auch Organisationseinheiten übergreifend kommt es zu Wechselwirkungen beim Wettbewerb um Ressourcen. Eine optimale Kapazitätsnutzung auf einer Station kann zu einem Kapazitätsengpass auf einer weiteren Station führen [63]. Zum Beispiel erzeugt eine volle Station deutlich mehr Nachfrage in der Radiologie, die diesen erhöhten Bedarf nicht abdecken kann. Somit führt dies zu Wartezeiten auf interne Termine und einer verlängerten Verweildauer.

Verschiedene Spezialisierungen und Hierarchieebenen der Belegschaft charakterisieren die Kategorie der mitarbeiterbasierten Interdependenzen. Engpässe im Behandlungsprozess entstehen, wenn Mitarbeiter auf die Fertigstellung einer anderen Aufgabe warten müssen. Falls kein Personal mit der entsprechenden Qualifikation verfügbar ist, führt dies zu weiteren Verzögerungen in der medizinischen Versorgung [63]. Die Beachtung dieser Interdependenzen resultiert in einer besseren Planung mitarbeiterabhängiger Fragestellungen im Behandlungsprozess [25, 26, 140].

Problembasierte Interdependenzen beschreiben die Beziehung zwischen scheinbar unabhängigen Entscheidungsproblemen. Für ein spezielles Entscheidungsproblem sollten die verbundenen vorgelagerten und nachgelagerten Probleme berücksichtigt werden, um die Ergebnisse realitätsnäher zu betrachten. Jedoch ist die Identifizierung und Abgrenzung dieser Entscheidungen schwierig. In den meisten Fällen existieren vielfältige Interdependenzen zu weiteren Entscheidungsproblemen, die wiederum in Beziehung zu anderen Problemstellungen stehen. In Abbildung 2.3 sind verschiedene Abhängigkeiten zwischen den klassischen Problemen des Kapazitätsmanagements gezeigt. Auf strategischer Ebene besteht eine Beziehung zwischen der Betten-, Mitarbeiter- und Behandlungskapazitätsplanung. Bei Veränderung oder Umplanung einer der Kapazitätsarten sollte eine Anpassung der anderen Kapazitäten erfolgen, um eventuelle weitere Engpässe zu vermeiden. Zum Beispiel muss bei einer Erhöhung der Bettenkapazität simultan auch eine Erweiterung der Behandlungskapazität in Betracht gezogen werden. Wird dies nicht beachtet, führt eine erhöhte Auslastung auf einer Station zu Engpässen im Behandlungsprozess und somit zu einer verlängerten Verweildauer der Patienten. Weiterhin sind hier hierarchische Abhängigkeiten erkennbar. Zum Beispiel beeinflusst die Bettenkapazitätsplanung direkt die operative Aufnahmeplanung. Ist die geplante Kapazität hoch, müssen weniger Konflikte um Betten gelöst werden. Jedoch kann es hier zu einer deutlichen Erhöhung ungenutzter Ressourcen kommen. Entgegengesetzt führt eine verminderte Kapazität zu einer Komplexitätserhöhung der Aufnahmeplanung.

Tendenziell lässt sich der soeben vorgestellte Typ von Interdependenzen in die Planungsprobleme integrieren. Dies erhöht jedoch deutlich die Komplexität der Fragestellung. Die zweite vorgestellte Hauptgruppe unterteilt sich in prozess-, funktional- und patienten-basierte Interdependenzen.

2. Untersuchung interdependenter Krankenhausstrukturen

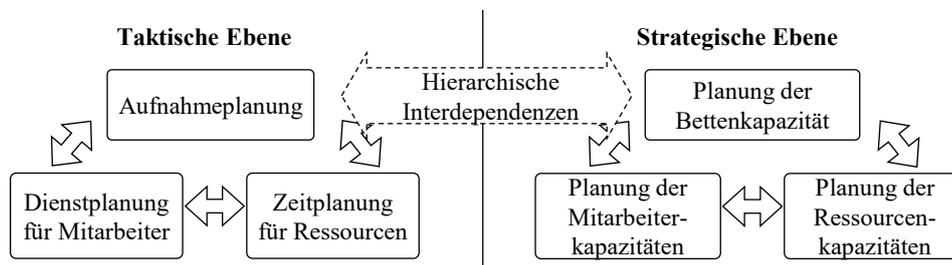


Abbildung 2.3.: Problembasierte Interdependenzen (Quelle: Eigene Darstellung)

Prozessbasierte Interdependenzen beschreiben die Wechselwirkungen von Prozessverbesserungen in einem komplexen System. Generell lässt sich das Krankenhaus als ein Downstream-System verstehen [99]. In einem solchen System bewegt sich der Patientenfluss vorwiegend in eine Richtung. Zum Beispiel betreten Patienten das Krankenhaus über die ZNA, werden anschließend auf einer spezialisierten Station behandelt, um abschließend auf einer allgemeinen Station bis zur Entlassung weiter versorgt zu werden. Eine Charakteristik solcher Systeme ist die Tatsache, dass eine isolierte Betrachtung einzelner Bereiche einen negativen Einfluss auf nachfolgende Abteilungen oder die gesamte Organisation haben. Zum Beispiel führt eine Verbesserung der Prozesse einer Notaufnahme zu einem erhöhten Patientenfluss in die spezialisierten Fachbereiche. Dadurch können auf diesen Stationen Kapazitätsengpässe entstehen, die zu längeren Wartezeiten der Patienten führen können. Aus diesem Grund sollten bei Prozessverbesserungen die Implikationen für benachbarte und nachgelagerte Bereiche mit einbezogen werden [99].

Funktionelle Interdependenzen können in zwei verschiedene Richtungen gedeutet werden. Zum einen beschreiben sie die funktionalen Einflüsse auf die Behandlungsplanung innerhalb einer Station, dargestellt in Abbildung 2.4. Die Variabilität und Menge der behandelten Diagnosen beeinflusst die Komplexität der stationsinternen Planung. Steigt die Anzahl, steigt auch die Komplexität. Bei wenigen stark strukturierten Diagnosen können Standardprozesse für die Versorgung verwendet werden. Je individueller die Behandlungen werden, desto spezieller werden die Prozesse und die Komplexität der Planung steigt [102]. Eine zweite Variante dieser Interdependenzen ist die Möglichkeit, dass mehrere Stationen ähnliche oder gleiche Behandlungen anbieten. Somit sind sie funktionell ähnlich ausgerichtet, können dieselben Patienten behandeln und können dem Entscheidungsträger verschiedene Freiheitsgrade in der Entscheidungsfindung ermöglichen.

2. Untersuchung interdependenter Krankenhausstrukturen



Abbildung 2.4.: Funktionelle Interdependenzen (Quelle: [102])

Innerhalb der patienten-basierten Interdependenzen werden Beziehungen und Abhängigkeiten zwischen verschiedenen Patientengruppen betrachtet. Als Beispiel wird hier die Interaktion zwischen elektiven und stationären Notfallpatienten genutzt. Die verfügbaren Ressourcen für elektive Patienten sind abhängig von der Qualität der Prognose der stationären Notfallpatienten, auf deren Grundlage wird die benötigte Anzahl der Betten für diese Patientengruppe reserviert. Wenn die Vorhersage höher ist als die realisierte Nachfrage, bleiben Kapazitäten ungenutzt. Im entgegengesetzten Fall entstehen Kapazitätsengpässe, die zu Wartezeiten und Abweisungen bei elektiven Patienten führen. Krankenhäuser antizipieren diese Interdependenzen im Allgemeinen über fixierte Kapazitätsanteile. Dabei werden oft 15 % der Kapazität für Notfälle reserviert [23]. Über einen langen Zeitraum gleichen sich so Über- und Unterlastungen aus. Jedoch könnte eine flexible Anpassung dieser Grenzen zu einer verbesserten Auslastung des Krankenhauses führen und kurzfristige Belastungsspitzen abbauen.

Im Gegensatz zum ersten Haupttyp lässt sich diese Gruppe der Abhängigkeiten nur schwer direkt in die Planungsprobleme integrieren. Jedoch helfen beide Typen von Interdependenzen bei der Gruppierung und Klassifizierung von Entscheidungsproblemen im Patientenflussbasiertem Belegungsmanagement. Dabei ist zu beachten, dass, je mehr Interdependenzen betrachtet werden, desto komplexer werden die Planungsprobleme im Krankenhaus [8]. Eines der zentralen Aufgaben eines Krankenhauses ist das Patientenflussmanagement, welches im folgenden Kapitel im Kontext eines interdependenten Krankenhauses diskutiert wird.

3. Patientenflussmanagement in komplexen interdependenten Krankenhäusern

Das Patientenflussmanagement ist eines der entscheidenden Elemente der Planung und Steuerung des Krankenhausbetriebes. Zur besseren Einordnung der später vorgestellten Planungs- und Steuerungsansätze wird in diesem Kapitel das Patientenflussmanagement genauer betrachtet. Es erfolgt eine Diskussion und Definition der klinischen Pfade als Grundlage des Patientenflussmanagements. Anschließend wird eine krankenhaushausweite Modellierung des Flusses gezeigt. Hier wird vor allem die Einbindung der klinischen Pfade in die Modellierung untersucht. Darauf aufbauend werden verschiedene Methoden und Verfahren des Patientenflussmanagements in Engpasssituationen dargestellt. Abschließend werden die gängigsten Entscheidungsproblematiken in einem Krankenhaus in einem neuartigen zweidimensionalen Klassifizierungsschema untersucht.

3.1. Klinische Pfade als Grundlage des Patientenflussmanagements

In der wissenschaftlichen Literatur existieren vielfältige Definitionen eines klinischen Pfades, auch bezeichnet als klinischer Behandlungspfad. Je nach Anwendungszweck variiert die Begriffsbestimmung [12]. Aus den verschiedenen Definitionen lassen sich jedoch die Charakteristiken eines klinischen Pfades extrahieren. Im Allgemeinen kann ein klinischer Pfad als ein verständlicher, diagnoseorientierter interdisziplinärer Behandlungsplan für eine wohldefinierte Gruppe von Patienten verstanden werden. Dieser Pfad hat zwei Hauptziele[83, 84]: qualitative

3. Patientenflussmanagement in komplexen interdependenten Krankenhäusern

medizinische Ziele und ökonomische effizienzorientierte Ziele. Diese zwei Ziele stehen in einem Konflikt zueinander. Als Grundlage für ein effizientes Kostenmanagement und damit der Sicherstellung des Fortbestehens des Krankenhauses muss in der Planung und Steuerung der klinischen Pfade eine Kompromisslösung gefunden werden [169]. Trotz allem kann eine angemessene gute Planung der Pfade unnötige Wartezeiten für Patienten vermeiden [75]. Im Rahmen dieser Vorüberlegung bewegt sich die Begriffsdefinition eines klinischen Pfades. In [76] wird aus verschiedenen Quellen eine Definition eines klinischen Behandlungspfades synthetisiert, die im Folgenden als Grundlage für die weitere Betrachtung dienen soll. Dabei wird ein klinischer Pfad folgendermaßen definiert:

„Eine vollständige interdisziplinäre Abbildung des stationären Behandlungsablaufes für homogene Patientengruppen. Dabei umfasst der Behandlungsablauf sämtliche planungsrelevanten Diagnose- und Behandlungsprozeduren, alle nötigen Stationsaufenthalte sowie mögliche Reihenfolgebeziehungen zwischen den einzelnen Elementen [76]“

Die Erstellung klinischer Pfade ist aufgrund der hohen Anzahl beteiligter Akteure, Krankheitsbilder und Ressourcen ein sehr aufwendiger Prozess. In der Regel ist dies nur vertretbar für wenige stark strukturierte und standardisierte Behandlungsprozesse. Dabei werden von Expertenkommissionen deutschlandweite medizinische Richtlinien an die individuellen Gegebenheiten eines Krankenhauses angepasst [12]. Aus der vorliegenden Definition klinischer Behandlungspfade lassen sich die speziellen Eigenheiten dieser Pfade herausarbeiten. Sie beziehen sich im Allgemeinen auf homogene Patientengruppen, die auf Basis ihrer Diagnose klassifiziert werden. Somit existiert ein Behandlungspfad pro Diagnose. Weiterhin sind in der Definition die Diagnose- und Behandlungsprozeduren von den Stationsaufenthalten abgegrenzt. Hier kann im Gegensatz zur vorherrschenden Meinung in eine medizinische und organisatorische Ansicht unterschieden werden. Die klinische Perspektive bezieht sich dabei auf den Behandlungspfad, während die organisatorische Perspektive den Stationspfad beschreibt.

In der Abbildung 3.1 ist eine klare Trennung zwischen der medizinischen und organisatorischen Sichtweise auf die Pfade erkennbar. Im Beispiel startet die initiale Behandlung auf Station 1. Anschließend erfolgt hier eine Weiterbehandlung oder eine Verlegung auf Station 2. Der letzte Teil der Behandlung findet auf Station 5 statt. Dieser Pfad durch die einzelnen Stationen spiegelt die organisatorische Sichtweise wider. Auch in der Versorgung eines Patienten kann es zu Variationen

3. Patientenflussmanagement in komplexen interdependenten Krankenhäusern

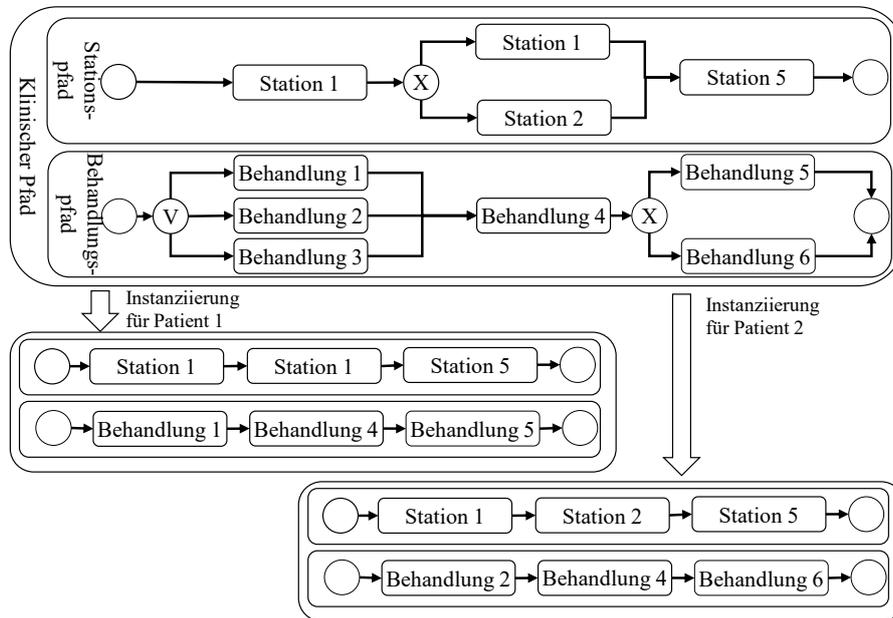


Abbildung 3.1.: Schematische Darstellung eines klinischen Pfades (Quelle: eigene Darstellung)

kommen. Im ersten Schritt kann eine Kombination aus den Behandlungsschritten 1, 2 und 3 gewählt werden. Anschließend wird Behandlung 4 durchgeführt. Zum Abschluss des Prozesses kann entweder Behandlung 5 oder 6 durchgeführt werden. Diese Sichtweise auf die klinischen Patiententpfade wird im Allgemeinen mithilfe von Process Mining generiert, wenn die Pfade automatisiert erstellt werden. Dabei zeigt sich schon in diesem einfachen Beispiel die Komplexität. Die generelle Kritik am automatisierten Erstellen der klinischen Patiententpfade zielt in diese Richtung ab. Durch die hohe Variabilität in der Behandlungszusammensetzung und -sequenz produzieren klassische Process Mining Algorithmen spaghettiartige Strukturen, die sich nur bedingt zur Entscheidungsunterstützung eignen [86, 156]. Auf planerischer Ebene verhindert diese Komplexität die Nutzung der klinischen Pfade als Entscheidungsgrundlage. Auf operativer Ebene kann und muss dieser klinische Patiententpfad für jeden Patienten individuell instanziiert werden.

Die Erstellung der Instanzen erfolgt normalerweise nach dem Prinzip Symptom-Diagnose-Behandlung ($S \rightarrow D \rightarrow B$). Dies bedeutet, dass aus einer Menge von Symptomen eine Diagnose geschlossen wird, welche das Ergebnis einer initialen medizinischen Begutachtung durch einen Arzt ist. Darauf aufbauend wird

3. Patientenflussmanagement in komplexen interdependenten Krankenhäusern

festgelegt, welche Behandlung durchgeführt werden muss. Zum besseren Verständnis kann dieser Schritt in zwei separate Entscheidungen unterteilt werden. Zum einen muss entschieden werden, welche Behandlungsschritte durchgeführt werden müssen und auf welcher Station die geplante Behandlung erfolgt. Somit wird die typische $S \rightarrow D \rightarrow B$ Assoziation zu $S \rightarrow D \rightarrow B_m \rightarrow B_o$ erweitert. Dabei spiegelt B_k die medizinische Perspektive wider. Hier wird entschieden, welche Behandlung durchgeführt werden soll. In der Regel basiert diese Entscheidung auf medizinischen Leitlinien, die unabhängig vom Krankenhaus existieren. Typischerweise entscheiden Expertenkommissionen über Behandlungsverläufe, die im Endeffekt die medizinische Best Practice darstellen. Dabei können auch verschiedene Behandlungssequenzen für gleiche Diagnosen möglich sein. Je nach Eigenschaften eines Patienten kann einer der verfügbaren Behandlungsabläufe ausgewählt werden. Beispielsweise kann bei einer Knieverletzung eine konservative oder eine operative Behandlungsvariante gewählt werden. Auf Basis der ausgewählten Behandlungsmethode erfolgt eine organisatorische Entscheidung, auf welcher Station die Behandlung durchgeführt wird. Diese ist bedeutend, da die Wahl eines Behandlungsablaufes eine bestimmte Nachfrage nach Ressourcen, Personal und Funktionen der Station erzeugt. Die ausgewählte Abteilung muss diese Nachfrage befriedigen. Normalerweise legt ein Krankenhaus im Vorfeld fest, welche Stationen welche Behandlungsschritte durchführen sollen, was die organisatorische Best Practice darstellt. In der medizinischen Praxis sind die Assoziationen zwischen einer Diagnose, den Behandlungssequenzen und der Behandlungsorte von vornherein festgelegt, ohne viel Raum für Flexibilität im operativen Alltag zu lassen. Sollten für bestimmte Behandlungsfolgen nicht genügend Kapazitäten vorhanden sein, müssen diese Patienten auf eine Aufnahme im Krankenhaus und somit auf ihre Versorgung warten. Die grundlegende Aufgabe des Patientenflussmanagements ist dabei, eine Vielzahl an Patienten mit ihren klinischen Behandlungspfaden so zu synchronisieren, dass eine möglichst schnelle individuelle Behandlung unter Beachtung der Kapazitätsrestriktionen des Krankenhauses möglich ist. Um die vielfältigen Ansätze des Patientenflussmanagements auf den verschiedenen Ebenen zu diskutieren, erfolgt im nächsten Unterkapitel eine Definition und Modellierung des krankenhausesweiten Patientenflusses.

3.2. Krankenhausweite Modellierung des Patientenflusses

In der wissenschaftlichen Literatur existiert keine einheitliche oder allgemeingültige Definition des Patientenflusses. Im Allgemeinen bezeichnet der Patientenfluss die Anzahl der Patienten, die im Krankenhaus behandelt werden. Um die vorgeschlagenen flexiblen Planungsmethoden im Patientenflussmanagement genauer diskutieren zu können, wird eine detailliertere Betrachtung des Patientenflusses notwendig. Es existieren zwei Perspektiven dieses Flusses [41], wobei die klinische das Voranschreiten des Gesundheitszustandes der Patienten beschreibt. Diese Art der Modellierung des Patientenflusses wird für epidemiologische Studien verwendet. Die operative Perspektive beschreibt die Bewegung der Patienten durch das Krankenhaus. Ein optimierter operativer Fluss kann zu kürzeren Wartezeiten führen [69]. Im Gegenteil bedeutet dies jedoch, dass ein schlecht oder gar nicht organisierter Patientenfluss zu Verzögerungen und Auslastungsfluktuationen führen kann. Um den Patientenfluss zu organisieren, sind die Eigenschaften des Flusses von besonderer Bedeutung. Aus operativer Perspektive ist der Patientenfluss durch das Zusammentreffen von Kapazitäten und Patienten charakterisiert. Genauer gesagt, müssen die Instanzen der klinischen Behandlungspfade mit den zur Verfügung stehenden Ressourcen synchronisiert werden.

In einer Untersuchung des Patientenflusses in einer zentralen Notaufnahme erfolgt eine Differenzierung in drei verschiedene Bestandteile: der Fluss in die Notaufnahme, der Fluss innerhalb der Notaufnahme und der Fluss aus der Notaufnahme [152]. Dieses Konzept lässt sich auf das gesamte Krankenhaus erweitern. Hier teilt sich der Fluss in verschiedene Bestandteile auf, die separat modelliert werden müssen. Der Fluss in das Krankenhaus besteht aus einer Ankunftsverteilung, einer Stationsentscheidung und einer Aufnahmeentscheidung. Die Ankunftsverteilungen werden je nach Fokus der Modellierung oft mithilfe statistischer Verteilungen generiert. Da einzelne Ankünfte voneinander unabhängig sind, werden sie auf strategischer Ebene durch Poisson-Verteilungen approximiert [42, 61, 170]. Untersuchungen, die einen taktischen oder operativen Fokus haben, nutzen auch reale Terminpläne für elektive Patienten und Poisson-Verteilungen für Notfallpatienten. In Forschungsarbeiten, die sich auf einzelne Organisationseinheiten konzentrieren, fällt die Entscheidung, auf welcher Station ein Patient initial aufgenommen werden soll, weg. Die Entscheidungen für die zu nutzenden Stationen in einem kranken-

3. Patientenflussmanagement in komplexen interdependenten Krankenhäusern

hausweiten Ansatz ist direkt vom klinischen Pfad eines Patienten abhängig. Da dieser mithilfe des Stationspfades festlegt, auf welchen Stationen und in welcher Reihenfolge ein Patient behandelt wird. Dies ist bezogen auf das Krankenhaus eine endogene Entscheidung, die von den Entscheidungsträgern in gewissem Maße beeinflusst werden kann. Auf strategischer Ebene wird der Stationspfad mithilfe von Übergangswahrscheinlichkeiten zwischen den Stationen modelliert. Je nach Qualität und Umfang der verwendeten Datengrundlage werden hier verschiedene statistische Verteilungen verwendet [4, 95, 124]. Auf taktischer Ebene werden diese Verteilungen verfeinert und auf der operativen Ebene können explizite Realisationen des Stationspfades verwendet werden. Ein wichtiger Teil des Flusses ins Krankenhaus ist die eigentliche Aufnahmeentscheidung, da eine Aufnahme nur möglich ist, wenn genügend freie Ressourcen zur Verfügung stehen. Auf strategischer Ebene ist eine Betrachtung von aggregierten Kapazitäten weit verbreitet. Dabei werden die verfügbaren Betten aller Zimmer einer Station summiert und die Entscheidung, ob ein Patient aufgenommen werden kann, wird auf einen simplen Kapazitätsabgleich heruntergebrochen [18]. In taktischer und operativen Untersuchungen werden die Kapazitäten oft auf Basis der Zimmer betrachtet und die Aufnahmeentscheidung ist ein essenzieller Bestandteil der Analyse. Der Fluss innerhalb des Krankenhauses ist grundlegend durch die Modellierung der Verweildauer der Patienten charakterisiert. Diese approximiert den Behandlungspfad eines Patienten. Die Summe der Zeitdauern der einzelnen Behandlungsschritte ergibt die Gesamtverweildauer auf einer Station. Da einzelne Behandlungsdauern variieren können, werden sie auf strategischer Ebene zusammengefasst und durch statistische Verteilungen beschrieben. Auf taktischer und operativer Ebene werden die Verweildauern entweder durch detaillierte Verteilungen oder durch explizite Werte für jeden Behandlungsschritt angegeben [2, 24]. Eine genaue Schätzung der LOS ist ein entscheidender Faktor. Viele Studien versuchen, für bekannte Patienten bei Aufnahme die Verweildauer zu schätzen [104, 108, 113, 160, 168]. Dabei werden sehr viele Daten benötigt, die oft erst nach der Aufnahme zur Verfügung stehen, um die Aufenthaltsdauer genau zu bestimmen. Somit können diese Ansätze nur bedingt für eine vorausschauende patientenübergreifende Planung verwendet werden. Wenn einzelne Organisationseinheiten untersucht werden, verlassen die Patienten das Krankenhaus, wenn ihre Verweildauer beendet ist. Bei einer krankenhausesweiten oder organisationseinheitenübergreifenden Betrachtung kommen weitere Elemente zur Modellierung des Patientenflusses zum Tragen. Für die Patienten muss entschieden werden, auf welchen nachfolgenden Abteilungen sie behandelt werden müssen und ob diese Station genügend freie Kapazitäten

3. Patientenflussmanagement in komplexen interdependenten Krankenhäusern

zur Aufnahme zur Verfügung hat. Wenn die Behandlung beendet ist, verlassen sie die Klinik. Dies wird als Fluss aus dem Krankenhaus bezeichnet und die Untersuchung dieses Bestandteiles ist das Forschungsgebiet des Entlassungsmanagements. Im Bereich des Patientenflussmanagements wird dieser Teil nicht modelliert. Bei genauerer Betrachtung des Patientenflusses fällt auf, dass das Krankenhaus im Rahmen des Patientenflussmanagements nicht jeden Bestandteil des Flusses beeinflussen kann. Die Patientenankünfte, die benötigten Stationen und die Verweildauer der Patienten sind extern vorgegeben. Lediglich auf die Aufnahme- oder Verlegungsentscheidungen hat das Patientenflussmanagement einen Einfluss. Auf Basis dieser Diskussionen lässt sich der Patientenfluss wie in Abb. 3.2 dargestellt, modellieren.

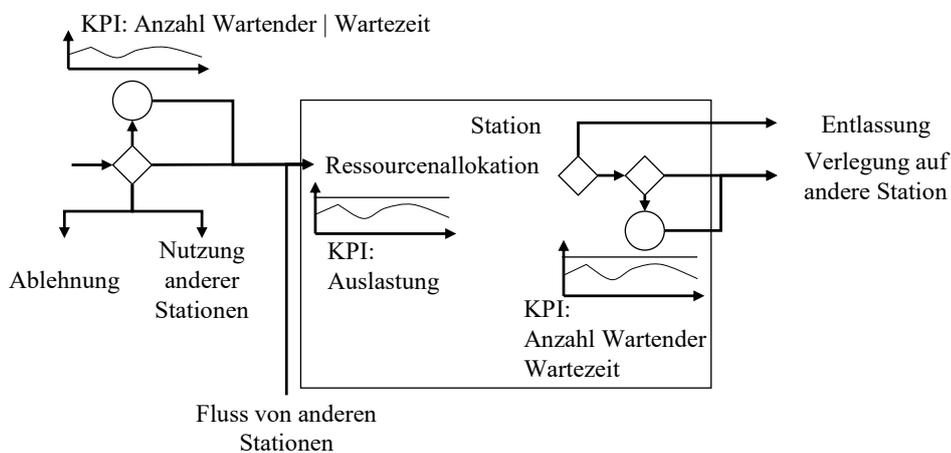


Abbildung 3.2.: Schematische Darstellung des krankenhausesweiten Patientenflusses (Quelle: eigene Darstellung)

In einem komplexen interdependenten Krankenhaus können Patienten eine bis mehrere Stationen besuchen. Dies ergibt vielfältige Eintrittspunkte eines Patienten auf einer Station. Der Standardfall ist die Aufnahme neuer Patienten, welche als externe Nachfrage nach Ressourcen modelliert sind. Sobald sie dem System bekannt sind, wird für sie individuell entschieden, ob eine Belegung auf der gewünschten Station möglich ist. Sollte dies der Fall sein, werden entsprechend ihrer Bedürfnisse Ressourcen allokiert. Sollten nicht ausreichend Kapazitäten vorhanden sein, muss der Entscheidungsträger eine Ad-hoc Entscheidung treffen, wie mit dem Patienten verfahren wird. Dieser kann in einer Warteschlange auf ein freies Bett warten, bei länger anhaltenden Engpässen einen neuen Termin bekommen

3. Patientenflussmanagement in komplexen interdependenten Krankenhäusern

oder, ermöglicht durch die krankenhaushausweite Betrachtung, Kapazitäten anderer Stationen nutzen. Sollten alle Versuche einer Aufnahme fehlschlagen, wird der Patient abgelehnt. Ein weiterer Eintrittspunkt auf die Station ist durch die Ankünfte von Patienten anderer Stationen, geplant oder ungeplant, charakterisiert. Für sie ist eine Aufnahmeentscheidung bereits getroffen und es werden direkt die benötigten Ressourcen belegt. Nachdem ein Patient seine Verweildauer beendet hat, wird entschieden, ob eine Entlassung stattfindet oder ob eine Weiterbehandlung auf einer anderen Station notwendig ist. Bei einer Entlassung wird die Ressource wieder freigegeben und der Patient verlässt das System. Sollte eine Weiterbehandlung auf einer anderen Station notwendig sein, muss erneut geprüft werden, ob eine Aufnahme möglich ist. Im Gegensatz zur initialen Entscheidung gibt es hier eine Besonderheit. Der Patient belegt bereits Ressourcen, die erst bei erfolgreicher Verlegung wieder freigegeben werden. Weiterhin sind Terminverschiebungen und Ablehnungen nicht mehr möglich. Somit sind während der Wartezeit auf eine Verlegung weitere Ressourcen belegt und das Krankenhaus sollte bestrebt sein, diese Vorgänge schnell abzuschließen. Ansonsten führt dies zu einer Multiplizierung von Engpässen. Wenn zum Beispiel Station 2 keine freien Kapazitäten hat und 5 Patienten von Station 1 warten auf eine Verlegung auf diese Station, bleiben Ressourcen länger belegt als geplant. In der Konsequenz verzögern sich dadurch die Neuaufnahmen auf Station 1 und es wurde ein weiterer Engpass geschaffen. Hauptaufgabe des krankenhaushausweiten Patientenflussmanagements ist es, diese Verknappungen zu verhindern oder Richtlinien und Strategien zur Verfügung zu stellen, um diese Engpässe schnell und mit hoher Qualität zu beheben. Diese Möglichkeiten des Patientenflussmanagements werden im folgenden Kapitel detaillierter beschrieben.

3.3. Ziele und Maßnahmen für ein flexibles Patientenflussmanagement während Kapazitätsengpässen

Stresssituationen in einem Krankenhaus können im Fokus dieser Arbeit am einfachsten als kapazitätsbasierte Engpässe definiert werden. Aus der Patientenflussperspektive beschreiben sie ein Ungleichgewicht zwischen der Nachfrage nach Gesundheitsservices und das Angebot an Ressourcen über einen gewissen Zeitraum. Dabei werden drei verschiedene Zustände eines Krankenhauses unterschieden: der normale Zustand, ein moderater Engpass und ein kritischer Engpass [92]. Ein Krankenhaus befindet sich in einem moderaten Engpass, wenn die Nachfrage das Angebot für eine kurze akzeptierbare Zeitspanne übersteigt. In diesem Fall sind Interventionen des Patientenflussmanagers notwendig, um das Krankenhaus in den normalen Zustand zurückzubringen. Sollten diese Eingriffe keinen Erfolg bringen, kann das Krankenhaus in eine kritische Engpasssituation übergehen. Hier sind sofortige Interventionen notwendig, um die Arbeitsfähigkeit des Krankenhauses aufrecht zu erhalten. Das Krankenhaus kann jederzeit von einem Zustand in einen anderen schlechteren Zustand übergehen [92]. Dieser wird durch eine kurzfristige Änderung der Nachfrage ausgelöst. Der Übergang von schlechten zu besseren Zuständen ist jedoch ohne Eingreifen des Patientenflussmanagements nicht möglich [92]. Zur Verdeutlichung wird eine Station mit angeschlossener Röntgenabteilung betrachtet. Im normalen Zustand sind genügend Kapazitäten verfügbar, um die Patienten ohne Wartezeiten zu behandeln. Es sind genügend freie Betten für Neuaufnahmen und genügend Termine für die bildgebende Diagnostik vorhanden. Durch einen Anstieg der Aufnahmen auf dieser Station kann es vorkommen, dass genügend Betten für Patienten zur Verfügung stehen, aber keine Kapazitäten zur Durchführung der Diagnostik bereitstehen. Bereits aufgenommene Patienten warten auf einen Termin im Röntgen und somit verlängert sich ihre Verweildauer. Dies kann in diesem Fall als moderater Engpass bezeichnet werden, da die Station an sich noch Patienten aufnehmen kann und sich nur die Verweildauer der Patienten durch den Kapazitätsengpass der Röntgenabteilung verlängert. Um diese Engpasssituation aufzulösen, muss der Patientenfluss überwacht werden und eventuell die Terminplanung gemeinsam genutzten Kapazitäten angepasst werden. Ist diese Intervention nicht erfolgreich und die moderate Engpasssituation besteht für längere Zeit, kann die Station in eine kritische Situation übergehen. Dabei

3. Patientenflussmanagement in komplexen interdependenten Krankenhäusern

hat sich die Verweildauer der bereits aufgenommenen Patienten so verlängert, dass geplante Aufnahmen nicht durchgeführt werden können, da keine weiteren Bettenkapazitäten vorhanden sind. Hier ist eine sofortige Intervention notwendig, um das Abweisen der Patienten zu verhindern. Somit kann geschlussfolgert werden, dass zum Beispiel eine bessere Terminplanung der Röntgenabteilung die moderaten Engpasssituationen abbauen kann. Sollte sich der Engpass aber auf die Betten ausweiten, werden Aktionen des Patientenflussmanagements benötigt, um die Arbeitsfähigkeit der Station wieder herzustellen.

Das Hauptziel des Patientenflussmanagements ist dabei, die Behandlung möglichst vieler Patienten mit gegebenen Ressourcen sicherzustellen. Dabei soll ein effektives Patientenflussmanagement eine hohe Termintreue und geringe Wartezeiten ermöglichen. Weiterhin soll eine hohe Auslastung des Krankenhauses erreicht werden, um die Ressourcen möglichst wirksam zu nutzen. Jedoch ist zu beachten, dass je höher die Auslastung ist, desto anfälliger ist das Krankenhaus auf kurzfristige Fluktuationen des Patientenflusses. Die Vermeidung oder Behandlung von Belastungsspitzen ist somit die Hauptaufgabe des Patientenflussmanagements.

Das Hauptcredo des Patientenflussmanagements ist die Glättung des Patientenflusses in der Art, dass mit gegebenen Ressourcen möglichst viele Patienten mit einer hohen Qualität behandelt werden können. Hierbei wird bewusst die Möglichkeit der Erhöhung der verfügbaren Kapazitäten außer acht gelassen. In der Regel ist eine Kapazitätserhöhung nicht möglich. Finanzielle und organisatorische Hürden behindern das einfache Erhöhen der Kapazität. Weiterhin behebt die Anhebung der Kapazität nicht das Grundproblem der kapazitätsbasierten Engpässe im Krankenhaus, da die Engpasssituationen zwar verhindert werden, das jedoch auch zu einer deutlich geringeren Auslastung führen kann. Somit konzentriert sich diese Diskussion auf die Möglichkeiten des Patientenflussmanagements bei fixen Kapazitäten.

Die Aktionsweise des Patientenflussmanagements ist durch die Organisationsstruktur und Arbeitsweise des Krankenhauses bestimmt. Sollte das Krankenhaus aus einzelnen unabhängigen Organisationseinheiten bestehen, kann die Glättung des Flusses nur über eine zeitliche Anpassung der Nachfrage nach Kapazitäten erfolgen. Aufnahmen können durch Wartezeiten verzögert werden oder Termine elektiver Patienten können verschoben werden. Dabei wird zwar eine hohe Auslastung sichergestellt, jedoch verringert sich die Termintreue des Krankenhauses

3. Patientenflussmanagement in komplexen interdependenten Krankenhäusern

und somit ist nur ein Ziel des Patientenflussmanagements erfüllt. Durch die inhärente Unsicherheit der zukünftigen Nachfrage von Notfallpatienten sollte diese Variante mit Bedacht eingesetzt werden. Exzessive Terminverschiebungen führen im Allgemeinen zu einer subjektiven Verschlechterung der Behandlungsqualität eines Patienten. Bei Betrachtung mehrerer Stationen oder des gesamten Krankenhauses erweitern sich die Aktionsmöglichkeiten des Patientenflussmanagements. Unter der Annahme, dass verschiedene Organisationseinheiten gegenläufige Belastungsverläufe haben (Abb. 3.3), ergeben sich Möglichkeiten zur flexiblen Nutzung vorhandener Ressourcen. Es kann auftreten, dass eine Station komplett ausgelastet ist und keine weiteren Patienten aufnehmen kann, während eine andere Station noch freie Kapazitäten besitzt. In diesem Fall besteht die generelle Möglichkeit, Patienten in Engpasssituationen auf alternative Stationen zu verschieben. Somit können Belastungsspitzen im Krankenhaus verteilt werden und die vorhandene Kapazität kann besser ausgenutzt werden. In der Theorie führt dies zu einer gesteigerten Auslastung und einer höheren Termintreue. Durch unterschiedliche Spezialisierungen und Fähigkeiten der einzelnen Abteilungen kann diese Möglichkeit nicht unbegrenzt verwendet werden. Eine Voraussetzung zur flexiblen Nutzung alternativer Kapazitäten ist die Fähigkeit der Station, Patienten anderer Abteilungen zu behandeln. Somit spielen bei flexibler Ressourcennutzung die bereits diskutierten funktionellen Interdependenzen eine entscheidende Rolle.

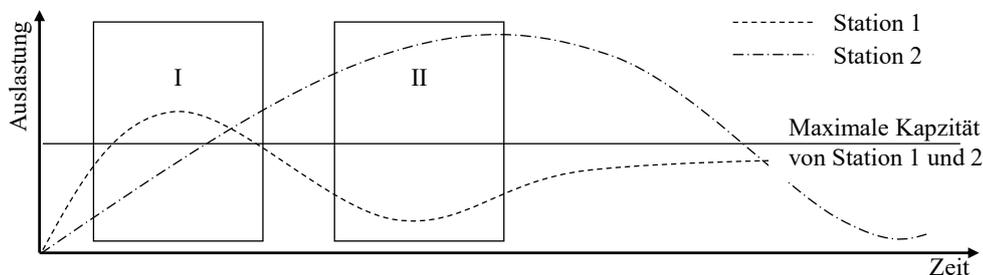


Abbildung 3.3.: Gegenläufige Belastungsverläufe von Stationen (Quelle: eigene Darstellung)

Die Möglichkeit der Verteilung von Patienten auf alternative Stationen stellt im Grunde den Rahmen für das flexible kapazitätsbasierte Patientenflussmanagement dar. Zur Verteilung der Patienten im Krankenhaus stehen im Allgemeinen zwei verschiedene Möglichkeiten zur Verfügung. Auf planerischer Ebene können Patienten vor ihrer eigentlichen Aufnahme umgeleitet werden. Dies bedeutet, dass die gewünschte Station aufgrund eines Kapazitätsengpasses geändert wird. Im Rahmen

3. Patientenflussmanagement in komplexen interdependenten Krankenhäusern

dieser Arbeit wird dies als Mittel der kurzfristigen Glättung des Patientenflusses verstanden. Es gibt jedoch auch die Möglichkeit, diese Überlegung dauerhaft für die Bearbeitung des Patientenflusses zu nutzen. Hier kann von einer permanenten Verschiebung von Service-Angeboten der Station gesprochen werden. Es werden die Verantwortlichkeiten für bestimmte Diagnosen dauerhaft oder temporär geändert. Eine zweite, auf die operative Steuerung des Patientenflusses ausgelegte Möglichkeit ist die Umlagerung bereits aufgenommener Patienten. Hiermit können Kapazitäten für neue Patienten geschaffen werden, indem andere Patienten auf weiterbehandelnde Stationen weitergeleitet werden. Da es sich dabei um eine neue Betrachtungsweise auf das Flussmanagement handelt, müssen die Entscheidungsträger von der Leistungsfähigkeit dieser Ansätze überzeugt werden. Aus diesem Grund werden aus diesen essenziellen Überlegungen Strategien zur flexiblen Nutzung der vorhandenen Kapazitäten entwickelt und evaluiert. Anschließend werden sie in Managementansätze für die Planung und Steuerung des Krankenhauses überführt.

In Kapitel 5 werden generelle, für das Patientenflussmanagement geeignete Strategien vorgestellt. In ihrer einfachsten Form wird eine flexible Ressourcennutzung durch den Verleih aktuell nicht benötigter Zimmer angrenzender Stationen realisiert. Damit kann im operativen Betrieb eine schnelle und unkomplizierte Reaktion auf Engpässe ermöglicht werden. So können Patienten nahe ihrer ursprünglich geplanten Station behandelt werden, ohne unnötig lange Wege für das behandelnde medizinische Personal zu verursachen. Diese generelle flexible Nutzung der Ressourcen wird in zwei Varianten verfeinert, durch die Einführung von Kapazitätspools für Intensivbetten und die Erstellung interdisziplinärer Stationscluster. In der ersten Verfeinerung werden die Ressourcen verschiedener Intensivstationen gebündelt. Damit soll eine bessere Auslastung der Kapazitäten ermöglicht werden. Diese Bündelung bewirkt im Endeffekt, dass sich alle Intensivstationen wie eine große Station verhalten. Also werden alle Kapazitäten gemeinsam geplant und gesteuert. Für die zweite Verfeinerung, die Einführung interdisziplinärer Stationscluster, werden ähnliche Stationen in Bezug auf Ausstattung, Personal und Fähigkeiten gebündelt. In Engpasssituationen können Patienten auf jeder Station eines Clusters aufgenommen werden. Auf planerischer Ebene bleiben die Stationen, im Gegensatz zum ersten Ansatz, unabhängig. Dies bedeutet, dass jeweils eine eigenständige Planung und Steuerung durchgeführt wird und nur in Ausnahmesituationen auf die Kapazitäten des Clusters zurückgegriffen wird.

3. Patientenflussmanagement in komplexen interdependenten Krankenhäusern

Trotz der theoretischen Vorteile, die eine flexible Ressourcennutzung mit sich bringt, bestehen Vorbehalte der Entscheidungsträger gegenüber neuen Strategien. Wie bereits im Allgemeinen diskutiert, können in einem komplexen Krankenhaus selbst minimale Anpassungen an Prozessen oder Arbeitsweisen einen negativen Einfluss auf das Gesamtsystem haben. Hier kann es möglich sein, dass eine erhöhte Auslastung auf spezialisierten Stationen im weiteren Verlauf des Patientenflusses zu neuen Verknappungen auf den Allgemeinstationen führen können. Weiterhin besteht die Befürchtung, dass einzelne Abteilungen, die im aktuellen Zustand nicht unter Engpässen leiden, durch die Aufnahme zusätzlicher Patienten auch in Engpasssituationen geraten können. Dadurch würden Wartezeiten für die eigenen Patienten entstehen.

Diese Vorbehalte machen eine strategische Evaluation der neuen Strategien notwendig, bevor sie in explizite Planungsverfahren und operative Leitlinien überführt werden. Aus diesem Grund wird ein generisches Simulationsmodell verwendet, um sie zu evaluieren. Im Gegensatz zum aktuellen Stand der Forschung benutzt das Simulationsmodell keine aggregierten Kapazitäten, um die Belegung zu prüfen. Stattdessen wird eine Belegungsheuristik verwendet, die verschiedene operative Nebenbedingungen beachtet. Die Evaluationsergebnisse zeigen, dass unter ihrer Beachtung eine realitätsnähere Evaluation möglich ist und somit die Einflüsse der neuen Strategien nicht überschätzt werden. Mithilfe der Strategien konnten Wartezeiten und Ablehnungen signifikant verringert werden, ohne einzelne Stationen zu benachteiligen oder die Gesamtperformance des Krankenhauses zu verschlechtern.

Diese strategischen Erkenntnisse werden im Weiteren in operative Richtlinien und Planungsansätze überführt. In der Planung soll eine proaktive Vermeidung von Engpässen implementiert werden. Dies erfolgt durch eine Aufnahmeplanung unter Berücksichtigung möglicher, noch unbekannter Notfallpatienten. Trotz guter Planung können nicht alle Engpässe im operativen Betrieb ausgeschlossen werden. Aus diesem Grund erfolgt anschließend die Ausarbeitung operativ nutzbarer Richtlinien zur Unterstützung der Entscheidungsträger im Krankenhaus, um eine schnelle und qualitativ hochwertige Reaktion auf Belastungsspitzen zu ermöglichen.

Im Rahmen der operativen Planung erfolgt eine Glättung des Patientenflusses durch eine detaillierte Aufnahmeplanung der Patienten. In der wissenschaftlichen Literatur wird diese im Allgemeinen für eine Station oder Organisationseinheit

3. Patientenflussmanagement in komplexen interdependenten Krankenhäusern

durchgeführt[145]. Dabei werden die Synergiepotenziale, die in der strategischen Evaluation aufgedeckt wurden, nicht berücksichtigt. Somit können diese Verfahren dem Entscheidungsträger keine Flexibilität in ihren Entscheidungen bieten. Zusätzlich erfolgt in der langfristigen Betrachtung nur eine Vergabe einzelner Termine. Dies ist insofern verständlich, da die Terminanfragen individuell über einen längeren Zeitraum im Krankenhaus eintreffen. Daher ergibt sich per se keine Optimierungsmöglichkeit. Einzig die Erstellung von standardisierten Terminplänen, basierend auf festen Zeitblöcken, für verschiedene Diagnosen ist denkbar [28, 107]. Innerhalb dieser Arbeit wird jedoch ein operativer Planungsansatz vorgeschlagen, der ausgehend von einem initialen Terminplan eine Verbesserung mit aktuell verfügbaren Informationen ermöglichen soll. Dabei wird ein Verfahren zur Anpassung der Termine elektiver Patienten unter Beachtung von Notfallpatienten auf planerischer Ebene gezeigt. Dabei erfolgt die Glättung des Flusses durch zwei verschiedene Möglichkeiten. Zum einen durch Terminverschiebungen elektiver Patienten und zum anderen durch die Nutzung alternativer Kapazitäten bei der Aufnahme. In Analogie zur Flussbetrachtung wird dieses Planungsproblem als Netzwerkflussproblem aufgefasst. Genauer gesagt als Umladeproblem mit deterministischen und stochastischen Angeboten. Das Modell wird zur proaktiven Vermeidung von Engpasssituationen verwendet. Dabei erfolgt eine Aufweichung der strikten Trennung zwischen planbarer und reservierter Kapazität. Durch das Antizipieren der Notfallpatienten können elektive Patienten aus Zeiträumen mit hoher Notfallnachfrage in Phasen mit niedriger Nachfrage verschoben werden. Somit erfolgt eine generelle Erhöhung der Auslastung, ohne zusätzliche Engpässe zu schaffen.

Trotz der proaktiven Vermeidung von Engpässen auf planerischer Ebene kann es im operativen Betrieb zu weiteren Konflikten um Ressourcen kommen. Diese werden durch schwer vorhersagbare Ereignisse oder ungenaue Vorhersagen ausgelöst und können nur durch kurzfristige Ad-hoc-Steuerung des Flusses aufgefangen werden. Auch hier wird eine flexible Nutzung vorhandener Kapazitäten angestrebt. Anders als auf strategisch taktischer Ebene existieren dabei keine homogenen Patientengruppen. Trotz gleicher Diagnose können sich die Patienten in ihren Bedürfnissen unterscheiden. Somit kann die Entscheidung zur Nutzung alternativer Kapazitäten für einen Patienten vorteilhaft, für einen anderen jedoch mit Nachteilen verbunden sein. Daher sind auf operativer Steuerungsebene patientenindividuelle Lösungen notwendig. Hierbei erfolgt die Flusssteuerung auf Basis individueller Patientenfades. Basierend auf der klinischen Perspektive des Pfades wird eine Behandlung

3. Patientenflussmanagement in komplexen interdependenten Krankenhäusern

festgelegt. Darauf aufbauend wird eine Liste geeigneter Stationen bestimmt. Das Wissen über die Behandlung und die Eignung der Abteilungen für diese sind entscheidende Voraussetzungen für die Implementierung operativer Richtlinien, deren Grundlage die bereits diskutierte flexible Nutzung der Ressourcen ist. Dabei kann ein Patient direkt bei der Aufnahme auf eine andere Station verlegt werden oder während seiner Behandlung umgelagert werden, um Kapazitäten freizugeben. Diese zwei grundlegenden Arten der Flexibilität werden verwendet, um Richtlinien festzulegen. In Kombination mit dem Wissen über den aktuellen Patienten ermöglichen sie eine schnelle und effiziente Entscheidungsfindung der Experten. Wichtig dabei ist, dass einem Krankenhaus die Möglichkeit gegeben wird, ein gefordertes Qualitätslevel festzulegen. Dabei sind Verlegungen nur erlaubt, wenn sie die Mindestanforderung an die Qualität erfüllen. Die Evaluation zeigt, dass fast alle kurzfristigen Engpasssituationen mithilfe dieser Richtlinien abgefangen werden können. Zusätzlich wurde aufgedeckt, dass die Flexibilität auf operativer Ebene die Qualität der Behandlung nicht negativ beeinflusst. Für Patienten, die während ihrer Behandlung unplanmäßig verlegt werden, erhöht sich sogar die durchschnittliche Behandlungsqualität.

Dieser Abschnitt hat ein Konzept für die ganzheitliche Einführung eines krankenhausesweiten Patientenflussmanagements vorgestellt. Dabei ist zu beachten, dass die einzelnen Stufen ineinander übergreifen und sich gegenseitig beeinflussen. Ausgehend von einer Entwicklung geeigneter Strategien wurde ein Planungsansatz entworfen, der sie aufgreift. Abschließend wurden operative Richtlinien vorgestellt, die eine Entscheidungsunterstützung im operativen Betrieb liefern sollen.

3.4. Kategorisierung der Problemstellungen im Patientenflussmanagement

Wie bereits diskutiert, werden die Anwendungsfelder für Entscheidungsunterstützung im Krankenhaus oft nur auf Basis der Problembereiche oder spezieller Organisationseinheiten kategorisiert. Für einen krankenhausesweiten Fokus im Patientenflussbasierten Kapazitätsmanagement wird eine neuartige Kategorisierung, basierend auf verschiedenen Abstraktionsebenen von klinischen Patientenpfaden und Ressourcen, benötigt. Dieses Schema und Auszüge der Diskussion sind bereits in [157] und [123] publiziert wurden.

3. Patientenflussmanagement in komplexen interdependenten Krankenhäusern

Die Ressourcenabstraktion, dargestellt auf der y-Achse in Abbildung 3.4, kann in drei verschiedene Ebenen aufgeteilt werden. In der Detailliertesten werden einzelne Behandlungen und ihre benötigten Ressourcen betrachtet. Bei weiterer Aggregation werden zuerst tageweise die Betten- oder Behandlungskapazitäten untersucht, um anschließend aggregierte Kapazitäten zu berücksichtigen. Auf der x-Achse sind die verschiedenen Abstraktionsebenen der Behandlungspfade abgetragen. Ausgehend von der in der Literatur vorherrschenden Definition eines abstrakten Patientenpfades wird der Begriff des Patientenpfades, basierend auf den betrachteten Organisationseinheiten und der Anzahl konkurrierender Patientenpfade, erweitert. Die nächste Abstraktionsebene ist durch alle Pfade auf einer Station oder funktionellen Einheit charakterisiert, die um gemeinsame Ressourcen konkurrieren. In der anschließenden Ebene werden die Pfade auf mehreren interdependenten Organisationseinheiten betrachtet. Abschließend werden krankenhausweite Pfade untersucht.

Mithilfe dieser Abstraktionsebenen lassen sich die vielfältigen Anwendungsfelder im patientenflussorientierten Belegungsmanagement identifizieren und klassifizieren. Dabei können die einzelnen Ausschnitte in den Kreuzungspunkten verschiedenen Sektoren zugeordnet werden. Mit S ist der Bereich der Terminplanung bezeichnet, der eher auf die operative Planung ausgelegt ist. A beinhaltet den analytischen Sektor, der strategische Planungsprobleme charakterisiert. Die Anwendungsfelder im Sektor O bezeichnen krankenhausweite Fragestellungen.

Weiterhin sind in dem Schema in Abbildung 3.4 die Einflüsse der Abstraktionslevel erkennbar. Ressourcenseitig führt ein steigender Detailgrad zu einer erhöhten Komplexität des Entscheidungsproblems. Ein abstrakterer Blick auf die Ressourcen führt generell zu strategischeren Entscheidungen. Dabei führt eine Veränderung des Detaillevels zu einer grundlegenden Änderung der Natur des Entscheidungsproblems. Im Gegensatz dazu ändert das Abstraktionslevel der Patientenpfade nicht die Art des Entscheidungsproblems. Eine detailliertere Betrachtung der Pfade führt zu einem detaillierteren Entscheidungsproblem und somit zu einem größeren Einfluss von Interdependenzen, die beachtet werden müssen. Dies lässt sich am Beispiel der Kapazitätsplanung I und II in den Sektoren A4 und A5 zeigen. In der Kapazitätsplanung I werden gemeinsam genutzte Ressourcen, wenn sie betrachtet werden, mit fixierten Mengen, die einer Station zugeordnet sind, abgebildet. Im Gegensatz dazu werden diese Ressourcen in der Kapazitätsplanung II explizit mit modelliert, um genauere Ergebnisse zu erhalten.

3. Patientenflussmanagement in komplexen interdependenten Krankenhäusern

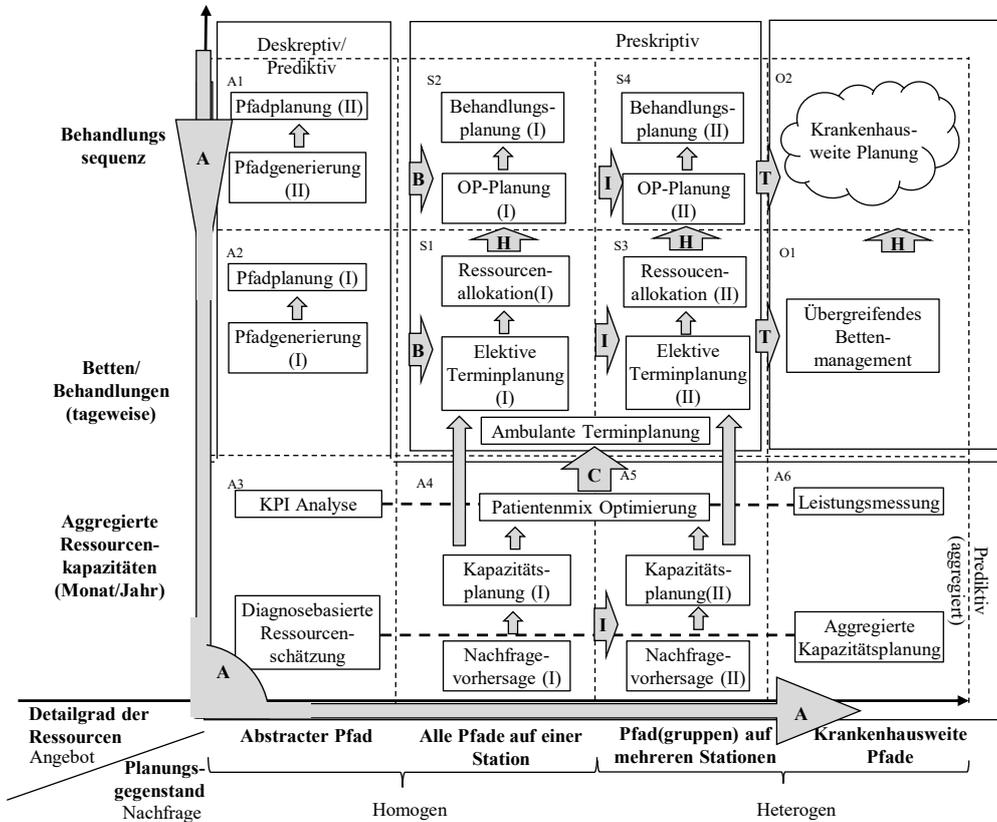


Abbildung 3.4.: Zwei-Dimensionales Klassifizierungsschema (Quelle: Eigene Darstellung)

Im Weiteren wird die aktuelle wissenschaftliche Literatur mit Bezug zum soeben vorgestellten Klassifizierungsschema untersucht. In Tabelle 3.1 ist dazu ein Auszug der aktuellen Literatur gegeben. Für ausgewählte Problemstellungen ist eine Einordnung in das Schema vorgenommen wurden. Dabei wird explizit zwischen simulationsbasierten- und optimierungsbasierten Ansätzen unterschieden. Hier ist zu erkennen, dass sich die aktuelle Forschungsliteratur vornehmlich auf die Quadranten A3 bis A6 und S1 sowie S3 bezieht. Aufgrund dieser Konzentration werden in den Ansätzen Interdependenzen in der Regel nicht betrachtet. Diese Nichtbetrachtung resultiert in einer verringerten Praxistauglichkeit der untersuchten Verfahren. Weiterhin zeigt die Fokussierung auf abstrakte Pfade ein weiteres Problem. Sie können im Allgemeinen die operative Variabilität der Patienten nicht

3. Patientenflussmanagement in komplexen interdependenten Krankenhäusern

Tabelle 3.1.: Einordnung der Literatur in das Klassifizierungsschema (Quelle: Eigene Darstellung)

Quadrant	Problembereich	Optimierung	Simulation
S1	Ambulante Terminplanung	[38, 47, 51, 119, 120, 130]	[59, 22]
S1	Elektive Terminplanung (I)	[10, 131]	[10]
S1	Ressourcenallokation (I)	[20, 161, 14, 129, 67]	–
S3	Ressourcenallokation (II)	[5]	–
S3	Elektive Terminplanung (II)	–	[132]
S4	OP-Planung	[9]	–
A3	Ressourcenschätzung	[44, 111]	–
A3	KPI-Analyse	–	[167, 101, 136, 30, 110]
A4	Kapazitätsplanung (I)	[125]	[167, 29, 37]
A4 A5	Patientenmix Optimierung	–	[56, 52]
A6	Leistungsanalyse	–	[27, 103, 148, 3]
A6	Kapazitätsplanung	–	[46]

genau genug abbilden und stellen somit Machbarkeitsstudien dar, denen durch die unzureichende Betrachtung von Interdependenzen der letzte Schritt zur praktischen Umsetzung fehlt.

In Tabelle 3.1 ist ein weiterer wichtiger Aspekt zu erkennen. Optimierungsverfahren werden vorwiegend für taktische und operative Problemstellungen verwendet. Für komplexere strategische Fragestellungen werden Simulationstechniken verwendet. Dennoch bleibt der größte Kritikpunkt an der wissenschaftlichen Literatur bestehen. Eine mehrheitliche Konzentration auf abstrakte Pfade in einer Organisationseinheit führt zu einer unzureichenden Abschätzung der Auswirkungen neuer Verfahren auf das gesamte Krankenhaus. Somit sollten neue Verfahren zumindest im Zusammenspiel mit den vor- bzw. nachgelagerten Organisationseinheiten untersucht werden.

Weiterhin zeigt das in Abbildung 3.4 vorgestellte Klassifizierungsschema zusätzliche Einsichten in die Kombinationsmöglichkeiten bzw. die Abhängigkeiten von Entscheidungsproblemen im Patientenflussmanagement. Grob lassen sich die einzelnen Sektoren des Schemas Planungs- und Analysetypen zuordnen. Die Quadranten A1 und A2 zeigen vor allem die Problemstellungen der Pfaderstellung und somit die deskriptive Analyse der Behandlungsdaten. Die Quadranten A3 bis A6 zeigen die strategische Planung, also die prediktive Planung, und die Performance Analyse, also eine deskriptive Analyse, des Krankenhauses. Ergänzend dazu zeigen die Sektoren S1 bis S4 die klassische preskriptive Sichtweise auf die Planungs-

3. Patientenflussmanagement in komplexen interdependenten Krankenhäusern

probleme innerhalb des Krankenhauses und die Sektoren O1 und O2 zeigen eine idealtypische Sicht auf eine krankenhausweite Planung. Die Übergänge B, C, H, I und T in der Abbildung 3.4 zeigen die Möglichkeiten zur Verbindung einzelner Fragestellungen. Diese Verbindungen werden unter Beachtung der verschiedenen Herangehensweisen als AI/OR-Synergien bezeichnet. Der Übergang H beschreibt dabei die klassische hierarchische Beziehung einzelner Problemstellungen. Hierbei wird in der Literatur oft zwischen einem Top-Level und einem Base-Level Problem unterschieden [147]. Durch die Kombination verschiedener Fragestellungen kann hier die Qualität der Ergebnisse und deren Praxistauglichkeit erhöht werden. Im Rahmen dieser Arbeit wird diese in [123] als OR/OR-Synergie bezeichnete Beziehung in Kapitel 6 zur Verbindung der elektiven Terminplanung und der Aufnahmeplanung verwendet. In diesem Kapitel wird ebenfalls der Planungsfokus durch die Untersuchung mehrerer Stationen unter Nutzung multimodaler Flüsse erweitert, dies ist durch die Transition I im Kategorisierungsschema gezeigt. Die Transition C zeigt die klassische Synergie zwischen deskriptiven und preskriptiven Methoden. Hierbei ist davon auszugehen, dass eine gute strategische Planung die Qualität der preskriptiven Planungsverfahren erhöhen kann. Dabei werden vorwiegend die feststehenden Parameter der Planungsverfahren, wie zum Beispiel die verfügbare Bettenkapazität oder die vorhandenen zentralen Ressourcen, bestimmt und als Eingabewerte für Optimierungsprobleme in der Terminplanung oder Ressourcenallokation verwendet. Eine weitere Form der Inputmodellierung ist durch die Transition B gegeben. Hierbei handelt es sich um eine neue Form der AI/OR-Synergie, die die Nutzung komplexer Inputstrukturen für Planungsprobleme beschreibt. Im Gegensatz zur Transition C, die einfache Daten und Inputstrukturen verwendet, werden hier komplexe Strukturen wie Patientenpfade als Input für Entscheidungsprobleme des Krankenhauses verwendet, um die Qualität preskriptiver Planungs- und Steuerungsmethoden zu erhöhen. Beispielhaft wird diese Synergie in Kapitel 7 verwendet, um operatives Wissen über Behandlungspfade zu generieren, welches im Anschluss für die operative Steuerung des Patientenflusses verwendet wird. Weiterführende Diskussionen und weitere Synergien zwischen künstlicher Intelligenz und Operations Research werden in [123] vorgestellt.

4. Standardisierte Behandlungsdaten als Grundlage einer krankenhausweiten Betrachtung

Um die Wiederverwendbarkeit der vorgestellten Verfahren zu gewährleisten, wird ein datengetriebener Ansatz gewählt. Alle Krankenhäuser in Deutschland sind nach der Einführung des Diagnosis Related Group (DRG)-Systems verpflichtet, patientenspezifische Daten in einem streng vorgegebenen Format aufzunehmen und zentral zu melden. Aus diesem Grund können die datengetriebenen Ansätze schnell und mit wenig Aufwand auf andere Krankenhäuser übertragen werden. Im folgenden Kapitel wird zuerst das G-DRG-System vorgestellt, um anschließend die Datenstruktur im Detail zu beschreiben. Abschließend wird der für diese Arbeit verwendete reale Datensatz analysiert.

4.1. G-DRG System als Treiber einer kontinuierlichen Datenlieferung

Im Jahr 2003 wurde mit der Einführung des G-DRG-Systems eine grundlegende Änderung der Krankenhausfinanzierung in Deutschland angestoßen. Damit sollte eine leistungsgerechte und transparente Vergütung der Krankenhäuser sichergestellt werden. Dabei wurden folgende grundlegende Ziele verfolgt [16]:

4. Standardisierte Behandlungsdaten als Grundlage einer krankenhausweiten Betrachtung

- wirtschaftlichere Versorgung der Bevölkerung mit Krankenhausleistungen
- Erhöhte Transparenz der Leistungen und Kosten der Krankenhäuser
- Stabilisierung der Ausgaben der GKV durch Erschließung von Wirtschaftlichkeitsreserven

Im Rahmen dieser Finanzierungsgrundlage werden alle stationären Krankenhaufälle auf Basis der DRG abgerechnet. Sie gruppieren Fälle mit ähnlichem Kostenaufwand. Somit wird eine Relation zwischen Art und Anzahl stationär behandelter Patienten und deren Ressourcenverbrauch hergestellt [105]. Vereinfacht ausgedrückt erfolgt die Vergütung in diesem System durch die Verrechnung der Bewertungsrelation einer DRG mit einem für alle DRG gleichen Basisfallwert. Somit ist die Finanzierung der Krankenhäuser direkt von der Eingruppierung der Patienten in eine DRG abhängig. Jede DRG besteht aus vier alphanumerischen Zeichen, zum Beispiel die *B39A*, welche die neurologische Komplexbehandlung eines Schlaganfalles beschreibt. Das erste Zeichen beschreibt die Hauptgruppe der DRG. Die aktuelle Version des G-DRG-Systems umfasst 25 Hauptgruppen. Das zweite und dritte Zeichen codieren die Basis-DRG, die durch unterschiedliche Faktoren wie Diagnosen, Prozeduren, Alter des Patienten und Schweregrad der Krankheit definiert werden. Das letzte Zeichen kennzeichnet den Ressourcenverbrauch einer Behandlung. Hier sind bis zu neun Stufen möglich. A bezeichnet dabei den höchsten Ressourcenverbrauch und I den niedrigsten. [100].

Um die Behandlungsleistung abzurechnen, muss das Krankenhaus jedem Patienten eine eindeutige DRG zuordnen. Aufgrund der Komplexität dieser Zuordnung wird dies über spezielle Anwendungssysteme, den sogenannten DRG-Groupern, durchgeführt. In dieses System werden alle relevanten Faktoren eingetragen und die DRG wird bestimmt. Aus diesem Grund müssen fallbasierte Patientendaten gespeichert und weiterverarbeitet werden. Weiterhin wird das G-DRG-System als lernendes System aufgefasst [162], welches kontinuierlich weiterentwickelt wird. Am G-DRG-System teilnehmende Krankenhäuser müssen im Rahmen der Evaluation und Weiterentwicklung des G-DRG-Systems jährlich ihre fallbezogenen Patientendaten an das Institut für das Entgeltsystem im Krankenhaus GmbH übermitteln [91]. Diese Datenlieferung erfolgt nach einem streng vorgegebenen Format, welches im Weiteren vorgestellt wird.

4.2. Routinedaten gemäß §21 KHEntG

Die Analysen und Verfahren in dieser Arbeit basieren auf standardisierten Behandlungsfalldaten, die jedes Krankenhaus in Deutschland auf Basis des §21 KHEntgG aufnehmen und weiterleiten muss. Dieser Datensatz enthält fünf wichtige Datenkategorien: Patientendaten, Falldaten, Stationsdaten und Behandlungsdaten. Diese Daten werden standardmäßig in einzelnen CSV-Dateien geliefert. Zur weiteren Verwendung der Daten werden sie in ein relationales Schema überführt und diskutiert. Die grundlegende Struktur der Daten ist in Abbildung 4.1 gegeben.

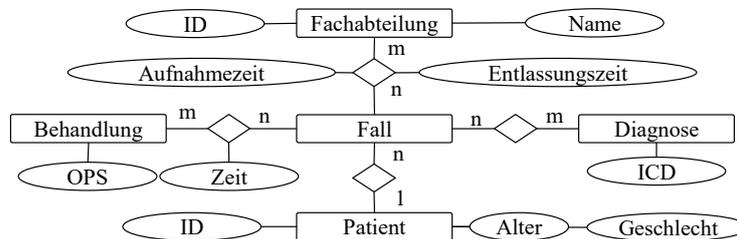


Abbildung 4.1.: Datenstruktur gemäß §21 KHEntG (Quelle: Eigene Darstellung in Anlehnung an [100])

In dieser Datenstruktur ist ein Patient mit einem bis mehreren Fällen verbunden. Jeder Fall beschreibt dabei eine Krankensepisode, das bedeutet eine zusammenhängende stationäre Behandlung eines Patienten. Zu beachten ist dabei aber, dass eine Episode auch durch einen kurzen Aufenthalt außerhalb des Krankenhauses unterbrochen werden kann. Erst wenn ein Patient erneut wegen einer neuen Diagnose im Krankenhaus behandelt wird, wird ein neuer Fall gebildet. Jeder Fall ist mit einer oder mehreren Diagnosen verbunden. Diese sind im Rahmen des ICD-10-GM-Schema codiert. Dieses Schema sieht einen drei bis fünfstelligen Code für die Beschreibung von Diagnosen vor, zum Beispiel steht *M54* für die Diagnose Rückenschmerzen. Durch die weitere Verfeinerung des Codes kann die Art der Rückenschmerzen näher spezifiziert werden. Während des stationären Aufenthaltes besucht ein Patient eine bis mehrere Stationen. Diese Aufenthalte enthalten den Aufnahme- und Entlassungszeitpunkt. Während eines Aufenthaltes erhalten Patienten eine Menge an Behandlungen, die im OPS-Schema codiert sind. Dabei handelt es sich wiederum um einen fünfstelligen Code. Beispielhaft zeigt der Code *3-05* eine Endosonographie. Durch eine weitere Verfeinerung durch die vierte und fünfte Stelle kann diese Sonographie näher kategorisiert werden.

4. Standardisierte Behandlungsdaten als Grundlage einer krankenhausweiten Betrachtung

Durch die Verwendung von Zeitstempeln können Behandlungen den einzelnen Stationen zugeordnet werden.

Da jedes Krankenhaus in Deutschland verpflichtet ist, diese Daten aufzunehmen und digital weiterzuleiten, ergibt sich eine besondere Situation für die Entwicklung datengetriebener Ansätze. Jegliche Planungs- und Evaluationsverfahren, die auf Basis dieser Strukturen entwickelt wurden, können ohne großen Aufwand auf jedes weitere Krankenhaus übertragen werden.

Eine Besonderheit der betrachteten Datenstruktur ist der ursprünglich gedachte Verwendungszweck. Diese Daten sind ursprünglich für das Controlling medizinischer Dienstleistungen konzipiert worden. Dafür werden sie auch hauptsächlich genutzt. Durch diese Ausrichtung stellen sie vergangenheitsbezogene Daten über den Behandlungsverlauf der Patienten zur Verfügung. Dadurch werden jedoch wichtige Aspekte des Patientenflusses überlagert und zusammenfassend dargestellt. In den Daten sind die Aufenthalte der einzelnen Patienten enthalten. Die Entscheidung, auf welcher Station ein Patient behandelt wird, kann auf zwei verschiedene Arten erfolgen. Zum Ersten auf Basis der medizinischen Indikation und zum anderen auf Basis operativer Entscheidungen in Engpasssituationen. Nachträglich lässt sich nicht mehr feststellen, aus welchem Grund diese Entscheidungen getroffen wurden. Diese Überlagerung der Informationen werden in der späteren Datenanalyse gesondert beachtet.

4.3. Beispieldatensatz

Im Rahmen dieser Arbeit wird ein realer, anonymisierter Datensatz verwendet. Dieser wird von einem großen Maximalversorger zur Verfügung gestellt. Laut dem Bettenplan für das Bundesland Sachsen-Anhalt verfügt dieses Krankenhaus über 1100 Patientenbetten, die auf 32 Fachabteilungen verteilt sind, die sich hinsichtlich ihrer Größe und Fähigkeiten unterscheiden. Weiterhin werden sie in 47 einzelne Stationen unterteilt. Der zur Verfügung gestellte Datensatz enthält Patientendaten über ein komplettes Jahr. 32.000 Patienten, die ca. 46.000 Fälle im Krankenhaus darstellen, sind im Datensatz beschrieben. Innerhalb dieser Fälle werden ca. 192.200 Behandlungsschritte bei ca. 50.700 Fachabteilungsaufenthalten durchgeführt. Angereichert wird dieser Datensatz durch Infrastrukturdaten zu den einzelnen Stationen und Fachabteilungen.

5. Entwicklung taktischer Überlaufregeln für ein flexibles Patientenflussmanagement und Krankenhausweite Simulation als Evaluationsinstrument

Zur flexiblen Ressourcennutzung benötigt ein Krankenhaus Strategien, in deren Rahmen Kapazitäten in Engpasssituationen allokiert werden können. Diese, im Allgemeinen als Überlaufregeln bezeichnete Strategien, werden in diesem Kapitel vorgestellt. Dazu erfolgt einleitend eine Diskussion möglicher Strategien zur flexiblen Nutzung der vorhandenen Bettenkapazitäten. Anschließend erfolgt die Entwicklung eines generischen Simulationsmodells, das den gesamten Patientenfluss darstellen kann. Mithilfe dieses Modells werden die vorgestellten Strategien in einem krankenhausesweiten Kontext evaluiert. Teile der folgenden Diskussionen wurden bereits in [77] und [79] veröffentlicht.

5.1. Entwicklung flexibler Überlaufregeln

Flexibilität im Belegungsmanagement ist ein wichtiger Treiber für die effektive Nutzung vorhandener Kapazitäten. In Zusammenarbeit mit den Mitarbeitern des Beispielkrankenhauses wurden verschiedene Strategien zur Verbesserung des Belegungsmanagements entwickelt, die drei zentrale Forderungen des Krankenhausmanagements erfüllen sollen. Zum einen beobachtet das Krankenhaus Belastungsspitzen auf einzelnen Stationen. Dabei kommt es zu kapazitätsbasierten Engpässen, während andere Stationen nicht genutzte Kapazitäten zur Verfügung

5. Stationsübergreifende Überlaufregeln im flexiblen Patientenflussmanagement

haben. Somit sollen alle Praktiken darauf basieren, aktuell ungenutzte Ressourcen anderer Stationen zu verwenden, um diese kurzfristigen Belastungsspitzen abzufangen. Weiterhin sollen nur Strategien in Erwägung gezogen werden, die geringe Anpassungen von Prozessen und Strukturen voraussetzen. Zusätzlich sollen diese Strategien ein niedriges Investitionsvolumen aufweisen. Auf Basis dieser Anforderungen wurden drei verschiedene Strategien entwickelt:

- S1 Flexible Belegung durch Zimmerverleih
- S2 Flexible Belegung durch Zusammenführung von ITS- und IMC-Stationen
- S3 Flexible Belegung durch die Schaffung interdisziplinärer Stationscluster
- S4 Frühzeitige Freigabe von Kapazitäten durch die Einführung einer Rehabilitationsstation

In [S1] können Engpässe durch den Verleih nicht genutzter Zimmer von räumlich angrenzenden Stationen vermieden werden. Das Krankenhaus konnte insgesamt acht potenzielle Tauschpartner identifizieren. Im Gegensatz zu [S4] bietet diese Strategie den Vorteil, dass sie nicht nur für bestimmte Patientengruppen eingesetzt werden können. Dieser Ansatz kann für alle Patienten in allen Phasen der Behandlung angewendet werden. Insbesondere zur Überwindung kurzzeitiger Engpässe bietet sich dieser Ansatz an. Interessanterweise wird diese Strategie punktuell schon eingesetzt. Aufgrund der Befürchtung der Benachteiligung der ausleihenden Stationen wird die Strategie von einer Mehrzahl der Abteilungen abgelehnt.

Ziel von [S2] ist das Pooling von Kapazitäten der ITS- und IMC-Stationen. Dadurch sollen bei Zimmern mit hohem Personal- und Ressourcenaufwand Kapazitätsengpässe vermieden werden. Durch die gebündelten Ressourcen wäre eine Verlegung aus dem Operationssaal oder der ZNA ohne große Wartezeit in den Pool möglich. Diese Bündelung der Kapazitäten geht jedoch mit einer gestiegenen Anforderung an die Interdisziplinarität des Personals oder der Ausstattung einher.

Die vorgestellten Strategien zielen darauf ab, die Wartezeit auf der ZNA zu reduzieren. Vor allem die der stationär aufgenommenen Notfallpatienten nach ihrer Behandlung auf der ZNA. In weiteren Diskussionen mit dem Krankenhausmanagement wurde deutlich, dass die Flexibilität der verschiedenen Strategien auf das gesamte Krankenhaus übertragen werden soll.

Vor diesem Hintergrund wurde das Konzept der Stationscluster entwickelt ([S3]). Generell bezeichnet ein Cluster einen Zusammenschluss gleichartiger Stationen,

5. Stationsübergreifende Überlaufregeln im flexiblen Patientenflussmanagement

Tabelle 5.1.: Zusammensetzung der Clusterkonfiguration 1 (CC-1) (Quelle: Eigene Darstellung)

NR	Beschreibung	# Stationen
1	Bauchcluster	10
2	Brustcluster	8
3	Knochencluster	6
4	Onkologiecluster	3
5	Geburtshilfe- und Kindercluster	8
6	Kopfcluster	9
7	nicht zugewiesen	3

Tabelle 5.2.: Zusammensetzung der Clusterkonfiguration 2 (CC-2) (Quelle: Eigene Darstellung)

NR	Beschreibung	# Stationen
1	Bauchcluster	9
2	Brustcluster	7
3	Knochencluster	2
4	Onkologiecluster	7
5	Geburtshilfe- und Kindercluster	5
6	Kopfcluster	9
7	Interne Medizin Cluster	6
8	nicht zugewiesen	2

die in der Lage sind, jegliche Patienten aller zugeordneten Abteilungen zu behandeln. Durch die Bündelung ähnlicher Stationen erfolgt eine grundlegende Betrachtung der medizinischen Bedürfnisse und der Fähigkeiten der Stationen. Vom Krankenhaus wurden verschiedene Clusterkonfigurationen vorgegeben. Diese sind in den Tabellen 5.1 bis 5.3 dargestellt. Um die Leistungsfähigkeit der Konfigurationen zu untersuchen, wird jede in drei unterschiedlichen Situationen analysiert. Im Ersten wird die jeweilige Zusammensetzung mit dem initialen Modell verglichen ([S3-1]). Im zweiten Anwendungsfall wird die durchschnittliche Auslastung der Stationen auf ca. 85 % durch die Entfernung von Betten reduziert ([S3-2]). In einer letzten Untersuchung wird die Anzahl elektiver Patienten um 50 % erhöht ([S3-3]). Durch die künstliche Erhöhung der Auslastung im zweiten und dritten Szenario wird es zwangsläufig zu vermehrten Engpässen in der Belegung kommen. Dabei wird die Reaktion der Cluster darauf untersucht.

5. Stationsübergreifende Überlaufregeln im flexiblen Patientenflussmanagement

Tabelle 5.3.: Zusammensetzung der Clusterkonfiguration 3 (CC-3) (Quelle: Eigene Darstellung)

NR	Beschreibung	# Stationen
1	Chirurgiecluster	11
2	Kopfcluster	9
3	Interne Medizin Cluster	12
4	Geburtshilfe- und Kindercluster	5
5	Onkologiecluster	6
6	Knochencluster	2
7	nicht zugewiesen	2

Die Strategien [S1] bis [S3] zielen darauf ab, geeignete Alternativen für Patienten während des Belegungsprozesses zu finden. In [S4] wird ein konträrer Ansatz untersucht. Hierbei wird versucht, die benötigte Kapazität für neue Patienten durch eine frühzeitige Verlegung anderer Patienten zur Verfügung zu stellen. Dabei geht diese Strategie davon aus, dass sich der Behandlungsprozess grundlegend in zwei Phasen, eine kritische Phase und eine Rehabilitationsphase, unterteilen lässt. Während der ersten Phase werden in der Regel stark spezialisierte Behandlungsschritte, wie zum Beispiel Operationen, durchgeführt, für die geeignete spezialisierte Stationen notwendig sind. Nach Abschluss dieser Behandlungsschritte erfolgen allgemeine Behandlungsschritte, wie die Überwachung der Patienten oder die Wundversorgung. Für diese Behandlungsschritte werden im Allgemeinen keine spezialisierten Pflegekräfte oder Ärzte benötigt, sodass die Prozeduren auf weniger spezialisierten Stationen erfolgen können. In diesem Kontext wird die Einführung einer allgemeinen Rehabilitationsstation vorgeschlagen, welche die Versorgung der Patienten zum Ende ihres Krankenhausaufenthaltes übernehmen soll.

Die Strategien [S1], [S2] und [S3] nutzen allgemein betrachtet das Konzept der Umleitungen, also die Aufnahme auf alternativen Stationen vor der eigentlichen Aufnahme oder bei klinikinternen Verlegungen. Im Gegensatz dazu nutzt [S4] das Konzept der Umlagerung, also das proaktive frühzeitige Schaffen von freien Kapazitäten. In diesem Fall, im Gegensatz zum Verfahren in Kapitel 7, auf planarerischer Ebene für fest definierte Patientengruppen. Durch die komplexen Strukturen und Wechselwirkungen eines Krankenhauses erfolgt die Evaluation dieser Strategien mit Hilfe eines ereignisdiskreten Simulationsmodells, welches im folgenden Kapitel vorgestellt wird.

5.2. Simulation als Evaluationsrahmen des Patientenflussmanagements

Die Simulation im Krankenhauskontext hat eine sehr lange Tradition. Aufgrund der Komplexität der betrachteten Prozesse und Patientenflüsse bietet sich der Einsatz ereignisdiskreter Simulation an. Aus diesem Grund erfolgt in diesem Abschnitt eine kurze Einführung in die methodischen Grundlagen mit einem Überblick über den aktuellen Forschungsstand im Bereich der krankenhausweiten Simulation. Anschließend wird das verwendete Simulationsmodell entwickelt und validiert.

5.2.1. Methodische Grundlagen zur ereignisdiskreten Simulation

Legt man die Definition von Shannon (1998) [153] zugrunde, beschreibt die Simulation den Prozess der Erstellung eines Modells eines realen Systems und das Experimentieren mit diesem Modell, um das Systemverhalten zu verstehen und verschiedene Strategien für Systemoperationen zu entwickeln oder zu evaluieren. Der Einsatz von Simulation ist immer dann sinnvoll, wenn ein hoch komplexes System untersucht werden soll, für das eine analytische Lösung schwierig ist [154]. Weiterhin wird das Konzept der Simulation genutzt, wenn Untersuchungen am Realsystem nicht möglich sind. Dies kann auftreten, wenn die Experimente zu teuer, zu gefährlich oder unmöglich sind, da die zu untersuchenden Aspekte noch nicht in der Realität existieren [153]. Im Allgemeinen bietet die Nutzung der Simulation verschiedene Vorteile. Die Eingangswerte eines Simulationsmodells können beliebig verändert werden und durch eine mögliche Zeitkompression kann das Verhalten eines Systems über einen längeren Zeitraum untersucht werden. Trotz der Vorteile ergeben sich Nachteile. Die Entwicklung von rechnergestützten Simulationsmodellen erfordert einen hohen Zeit- und Kostenaufwand. Vor allem in der Datensammlung und Interpretation der Ergebnisse erweist sich die Nutzung dieser Modelle häufig als schwierig. Ein weiterer gewichtiger Nachteil ist, dass das simulierte Verhalten nur dann repräsentativ ist, wenn die verwendeten Stichproben oder Verteilungen repräsentativ sind. Dies erfordert eine sorgfältige Validierung des genutzten Modells.

5. Stationsübergreifende Überlaufregeln im flexiblen Patientenflussmanagement

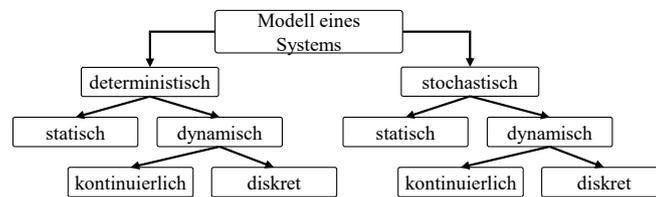


Abbildung 5.1.: Einordnung der Simulationsmodelle (Quelle: Eigene Darstellung in Anlehnung an [106, 154])

Die Art der verwendeten Simulationsmethode hängt klar von den Eigenschaften des Systems ab. In Abbildung 5.1 ist eine mögliche Klassifikation der Modelle gegeben. Eine erste Unterscheidung erfolgt in deterministische und stochastische Modelle. In deterministischen Systemen sind alle Systemzustände im Vorfeld bekannt. Dies kann zur Untersuchung von vergangenen Verhaltensweisen verwendet werden [154]. In stochastischen Modellen sind die verschiedenen Zustände des Modells im Vorfeld unbekannt und werden über Zufallszahlen und statistische Verteilungen beschrieben. Betrachtet man diese Art genauer, erfolgt eine Unterscheidung in statische und dynamische Modelle. Bei der statischen Betrachtung spielt die Zeit keine Rolle [154]. Dabei handelt es sich um unabhängige Zufallsexperimente, die häufig wiederholt werden [94]. Im Gegensatz dazu betrachten dynamische Modelle die Zustandsveränderungen eines Systems über die Zeit [106]. Im Wesentlichen erfolgt dabei die Unterscheidung auf Basis der Art der Zustandsänderung. Wenn kontinuierliche stetige Änderungen der Zustände über einen längeren Zeitraum untersucht werden sollen, spricht man von kontinuierlichen Simulationsmodellen. Diese werden im Bereich der Wirtschaftswissenschaften vorwiegend für die Untersuchung volkswirtschaftlicher Entwicklungen verwendet [106]. Innerhalb der diskreten Simulation unterscheidet die Literatur die zeitdiskrete und die ereignisdiskrete Variante. In der ersten werden die Zustandsänderungen an vorher fest vorgegebenen Zeitpunkten durchgeführt. Dies bedeutet, dass alle Vorgänge, die eine Änderung des Zustandes verursachen, gesammelt und zum nächstmöglichen Zeitpunkt in das System übertragen werden [154]. In der ereignisdiskreten Simulation ändern sich die Systemzustände direkt beim Eintreten eines Ereignisses. Also erfolgt dabei eine Simulation über die Fortschreibung sich auslösender Ereignisse [154]. Ihre Stärke spielt diese Art der Simulation bei komplexen Systemen mit stochastischen Eingabedaten aus, die sich gegenseitig beeinflussen [94, 106, 153]. Somit eignen sie sich besonders für die Simulation

5. Stationsübergreifende Überlaufregeln im flexiblen Patientenflussmanagement

komplexer Prozesse, wie sie in einem Krankenhaus zu finden sind. Dies wird durch eine Vielzahl an Simulationsstudien im Bereich des Krankenhauses verdeutlicht.

Ein weiterer wichtiger Faktor für die Nutzung und die Qualität von Simulationsmodellen ist die Modellierung exogener Einflüsse auf das Modell und endogene Entscheidungen innerhalb eines Modells. Bei der Modellierung der Inputdaten wird dabei die stochastische oder deterministische Variante unterschieden [106]. In der ersten Variante werden die Inputdaten als Wahrscheinlichkeitsverteilung, die entweder einer theoretischen oder empirischen Verteilung folgen, aufgefasst. In der zweiten Variante, der sogenannten trace-driven Simulation werden historische Daten direkt in der Simulation als Eingaben verwendet. Ein großer Unterschied ergibt sich in der Aussagekraft der Ergebnisse beider Varianten [154]. Durch die stochastischen Eigenschaften der Daten können die Ergebnisse generalisiert werden, wohingegen die trace-driven Simulation nur zur Abbildung bereits eingetretener Situationen genutzt werden können.

Die Sichtweise der stochastischen und deterministischen Simulation lassen sie auf die endogenen Entscheidungen eines Simulationsmodells erweitern. In einem Großteil der Simulationsstudien werden die Entscheidungen durch Wahrscheinlichkeitsverteilungen approximiert. Eine weitere Variante ist die Vorgabe der Entscheidung durch externe Verfahren. Dies wird vorwiegend zur Evaluation von Optimierungsverfahren verwendet. Eine neue in dieser Arbeit vorgestellte Variante ist die intelligente Entscheidung innerhalb eines Simulationsmodells. Dabei erfolgt die direkte Nachbildung der menschlichen Entscheidungslogik innerhalb des Simulationsmodells.

5.2.2. Aktueller Stand der Forschungsliteratur

Ereignisdiskrete Simulation (DES) und deren Einsatz im Krankenhaus hat eine lange Tradition. Eine umfangreiche Literaturanalyse [89] zeigt, dass DES eines der stärksten und intuitivsten Werkzeuge für die Analyse und Verbesserung komplexer Systeme im Gesundheitswesen ist. Eine Reihe weiterer Literaturanalysen untermauert dieses Denken [21, 90, 98, 126, 163]. Trotz der Vielzahl an Simulationsstudien tritt die Forschung auf der Stelle, da viele Forschungsprojekte unabhängig voneinander ähnliche Probleme mit ähnlichen Modellen lösen [58]. Um diesen Stillstand zu beenden, sollten neue Studien die Gesamtheit eines Krankenhauses betrachten, um generelle Kenntnisse über das Krankenhaus zu erhalten [51, 58, 68]. Aufgrund

5. Stationsübergreifende Überlaufregeln im flexiblen Patientenflussmanagement

der starken und komplexen Wechselwirkungen, die in Kapitel 2 vorgestellt wurden, können nur Ansätze, die mehrere Organisationseinheiten oder das ganze Krankenhaus betrachten, zu validen Ergebnissen führen [140]. Zusammenfassend sollten neuere Simulationsstudien folgende Eigenschaften aufweisen:

- Betrachtung mehrerer Organisationseinheiten
- Betrachtung essentieller Prozesse des Belegungsmanagements
- Betrachtung verschiedener Patientenflusstypen
- Generischer Aufbau für einfache Erweiterung bzw. Wiederverwendbarkeit

Nur wenige Studien, die im Weiteren vorgestellt werden, erfüllen teilweise diese Anforderungen. Eine Analyse der Aufnahme- und Entlassungsprozesse einer Intensivstation (ITS) kommt zu dem Ergebnis, dass die Leistungsfähigkeit einer ITS mehr von den Aufnahmeprozessen und Kapazitäten anderer Stationen abhängig ist als von der eigenen [97]. Realistische Ansätze zur Evaluation von Krankenhausprozessen müssen verschiedene Patiententypen berücksichtigen, um valide einsatzfähige Werkzeuge für das Belegungsmanagement zu entwerfen [73]. Simulation kann auch genutzt werden, um die benötigte Bettenkapazität einer Station zu schätzen. Dabei ist das Modell in der Lage, verschiedene Aufnahmekriterien, Prioritäten und Verweildauern zu betrachten [40]. Einen anderen Ansatz verfolgt ein mathematisches Simulationsmodell, um die Dynamik der Bettenbelegung einer ITS zu zeigen [11]. Dabei werden veränderbare Parameter auf angeschlossenen Organisationseinheiten untersucht, um die Auswirkungen auf die Belegungsprozesse der ITS zu diskutieren. Ein weiteres Problem der aktuellen Forschungsliteratur im Bereich der Simulation von Belegungsstrategien ist der Detailgrad der Kapazitätsmodellierung. Eine Reihe von Forschungsarbeiten konzentriert sich auf die Evaluation von flexiblen Strategien [7, 62, 64, 65, 73] mithilfe von Computersimulation. Hierbei werden wieder ähnliche Problemstellungen und Strategien mit eigenständigen Modellen untersucht. Eine Gemeinsamkeit aller Ansätze ist die Kapazitätsmodellierung. Alle vorgestellten Modelle nutzen aggregierte Bettenkapazitäten auf den Stationen. Aus Komplexitätssicht bietet dies den Vorteil, dass die Aufnahmeentscheidung im Simulationsmodell über einen einfachen Kapazitätsabgleich durchgeführt werden kann, welches kürzere Simulationszeiten ermöglicht. Nachteil dieses Verfahrens ist, dass der eigentliche Kapazitätsbedarf in Krankenhäusern mit einer strikten Geschlechtertrennung systematisch unterschätzt wird. Hier kann es auch zu nicht erlaubten Belegungen mehrerer Geschlechter in einem Zimmer kommen.

5. Stationsübergreifende Überlaufregeln im flexiblen Patientenflussmanagement

Bezugnehmend auf den beschriebenen Stand der Forschung schließt das Simulationsmodell dieser Arbeit folgende Lücken der Forschungsliteratur:

- Entwicklung eines krankenhausesweiten Simulationsmodells unter Beachtung der relevanten Prozesse des Belegungsmanagements
- Sicherstellung der Wiederverwendbarkeit des Modells durch datengetriebene Generierung
- Implementierung operativer Nebenbedingungen, um den Einfluss von neuen Belegungsentscheidungen nicht zu unterschätzen.
- Anpassbarkeit des Modells durch Nutzung eines objektorientierten Ansatzes

5.2.3. Simulationsmodell

Das Simulationsmodell in dieser Arbeit wurde in einem iterativen Prozess implementiert und weiterentwickelt. Das Ausgangsmodell erarbeitet die grundlegenden Patientenflüsse auf strategischer Ebene. Dieses Modell wird im Zuge der weiteren Verwendung für die Evaluation der operativen Planungs- und Steuerungsansätze angepasst. Die grundlegende Simulationslogik ist in Abbildung 5.2 dargestellt.

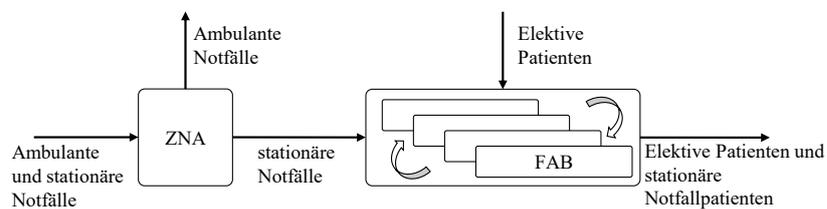


Abbildung 5.2.: Grundlegende Simulationslogik (Quelle: Eigene Darstellung)

Dabei werden zwei verschiedene Patiententypen betrachtet. Elektive, im Vorfeld geplante Patienten und Notfallpatienten, die über die ZNA das Krankenhaus betreten. Wenn diese Patienten nach ihrer Behandlung auf der ZNA entlassen werden, werden sie als ambulante Patienten bezeichnet. Sollte ein Aufenthalt auf einer weiterbehandelnden Station notwendig sein, zählen sie als stationäre Notfallpatienten. Innerhalb eines Krankenhauses konkurrieren stationäre Notfallpatienten und elektive Patienten um Bettenressourcen. Die essenziellen Bewegungen und Eigenschaften der Patienten werden über empirische Zufallsverteilungen bestimmt.

5. Stationsübergreifende Überlaufregeln im flexiblen Patientenflussmanagement

Tabelle 5.4.: Ankunftsverteilungen (Quelle: Eigene Darstellung)

#	Name	Basierend auf
1	Anzahl Ankünfte	Station, Wochentag
2	Anzahl Notfallankünfte	Wochentag
3	Ankunftszeit	Station
4	Ankunftszeit ZNA	Wochentag

Dabei werden Wahrscheinlichkeitsverteilungen für folgende Eigenschaften verwendet: Patientenankünfte, Geschlecht, erste Station und weitere Stationen.

Diese Wahrscheinlichkeitsverteilungen basieren auf den in §21 KHEntgG geforderten Daten, die in Kapitel 4 detailliert beschrieben wurden. Sie sind in drei Gruppen aufgeteilt. In der ersten Gruppe befinden sich die Verteilungen für die Ankünfte der Patienten. Diese basieren auf einer repräsentativen Woche. Die Anzahl der Ankünfte ist dabei vom Wochentag abhängig. Elektive Ankünfte variieren zusätzlich basierend auf der betrachteten Station. Die Zwischenankunftszeiten elektiver Patienten sind von der Station abhängig, wohingegen die Zwischenankünfte der Notfallpatienten vom Wochentag abhängig sind. In der zweiten Verteilungsgruppe werden die Eigenschaften eines Patienten (Geschlecht, Isolationsstatus und Anzahl zu besuchender Stationen) festgelegt. Für elektive Patienten sind diese Verteilungen von der aktuellen Station abhängig. Einzig die Verteilung zur Anzahl der zu besuchenden Stationen ist zusätzlich vom Geschlecht bestimmt. Die Verteilungen für Notfallpatienten sind unabhängig oder vom Geschlecht abhängig. Die dritte und letzte Gruppe der Verteilungen sind die Verteilungen auf der Station. Dabei werden mit verschiedenen Abhängigkeiten die Verweildauer und eine eventuell folgende Station festgelegt. Einen Überblick über die Verteilungen geben die Tabellen 5.4 bis 5.6.

Da für das Belegungsmanagement der eigentliche Behandlungsprozess nicht entscheidend ist, wird dieser stark vereinfacht im Modell umgesetzt. Generell betritt ein Patient die Station, bekommt ein Bett zugewiesen und verbringt, basierend auf seiner Verweildauer, eine definierte Zeitspanne auf der Station. Anschließend wird der Patient entweder entlassen oder auf eine weitere Station verlegt. Bei Aufnahmen und Entlassungen kommt einer der wichtigsten Prozesse des Belegungsmanagements zum Tragen. Es muss entschieden werden, ob die gewünschte Station genügend freie Kapazitäten zur Verfügung hat, um den entsprechenden

5. Stationsübergreifende Überlaufregeln im flexiblen Patientenflussmanagement

Tabelle 5.5.: Patientenverteilungen (Quelle: Eigene Darstellung)

#	Name	Basierend auf
1	Geschlecht	Station
2	Geschlecht ZNA	—
3	Isolationsstatus	Station
4	Isolationsstatus ZNA	—
5	Anzahl Stationen	Station, Geschlecht
6	Anzahl Stationen ZNA	Geschlecht

Tabelle 5.6.: Stationsverteilungen (Quelle: Eigene Darstellung)

#	Name	Basierend auf
1	Nächste Station	Station, Geschlecht
2	Verweildauer	Station, Wochentag
3	Verweildauer ZNA	Geschlecht

Patienten aufzunehmen. Sollte kein freies Bett vorhanden sein, verzögert sich die Aufnahme oder die Verlegung. Im schlimmsten Fall könnte der Patient abgewiesen werden. Diese Entscheidung ist von der aktuellen Belegung des Krankenhauses abhängig. Die nominell verfügbare Kapazität kann sich von der tatsächlich nutzbaren deutlich unterscheiden. Aufgrund der vorherrschenden strengen Geschlechtertrennung und der Berücksichtigung von zu isolierenden Patienten kann es vorkommen, dass ein Patient trotz freier Betten nicht aufgenommen werden kann. Auf einer Beispielstation mit zwei Zimmern, die jeweils eine Kapazität von zwei Betten haben, sind bereits drei weibliche Patienten aufgenommen. Rein rechnerisch existiert ein freies Bett. Wenn der nächste Patient weiblich ist, ergibt sich kein Problem für die Aufnahme. Ein männlicher Patient kann jedoch nicht aufgenommen werden und muss entweder warten oder seine Behandlung verschieben. Normalerweise wird diese Entscheidung vom medizinischen Personal einer Station oder von Belegungsmanagern getroffen. Um dies im Simulationsmodell nachbilden zu können, wird eine Belegungsheuristik (Abb. 5.3) implementiert.

5. Stationsübergreifende Überlaufregeln im flexiblen Patientenflussmanagement

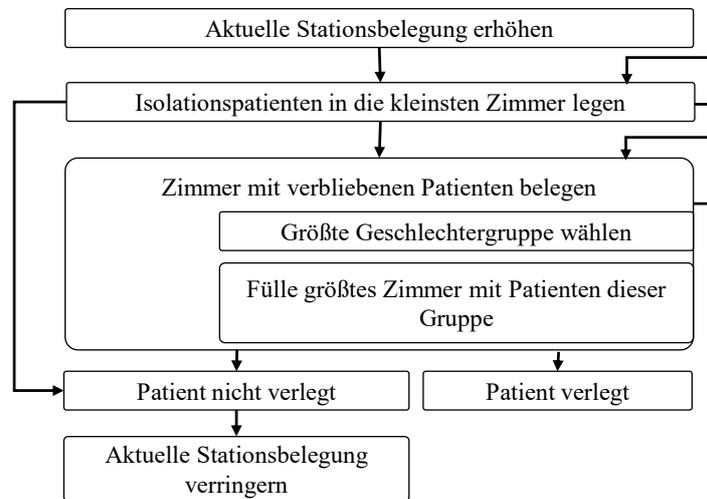


Abbildung 5.3.: Belegungsheuristik (Quelle: Eigene Darstellung)

Die Heuristik lässt sich in drei grundlegende Schritte unterteilen:

1. Isolationspatienten werden auf die kleinsten Zimmer verteilt
2. Verbliebene Patienten werden auf die übrigen Zimmer, beginnend mit den größten, verteilt. Hierbei wird in jeder Iteration die zahlenmäßig größte verbliebene Gruppe, basierend auf den Geschlechtern, ausgewählt
3. Die Heuristik terminiert, sobald alle Patienten auf die Zimmer verteilt sind (gültige Belegung) oder keine freien Zimmer für verbliebene Patienten zur Verfügung stehen (ungültige Belegung)

Bei einer ungültigen Belegung kann der Patient nicht aufgenommen werden und eventuelle Kompensationsmaßnahmen müssen durchgeführt werden. Im Vorfeld jeder Belegungsänderung wird diese Heuristik verwendet, um eine Aufnahme oder Verlegung zu prüfen.

Das Simulationsmodell wurde initial in ARENA 10.0 von Rockwell Software implementiert und für die Evaluation der Szenarien S1 und S2 genutzt [77]. Um die Wiederverwendbarkeit des Modells zu erhöhen, wurde es in einer zweiten Iteration [79] in der Software SIMIO neu erstellt. SIMIO ist ein Modellierungswerkzeug für die Erstellung von Simulationsmodellen unter Einhaltung objektorientierter Prinzipien [134, 133]. Dabei werden Objekte mit eigener Prozesslogik erstellt. Die

5. Stationsübergreifende Überlaufregeln im flexiblen Patientenflussmanagement

Simulationslogik der Patientenflüsse und die Heuristik werden aus der ersten Iteration übernommen. Um das Krankenhaus darzustellen, werden vier grundlegende Objekte (Abb. 5.4) erstellt.

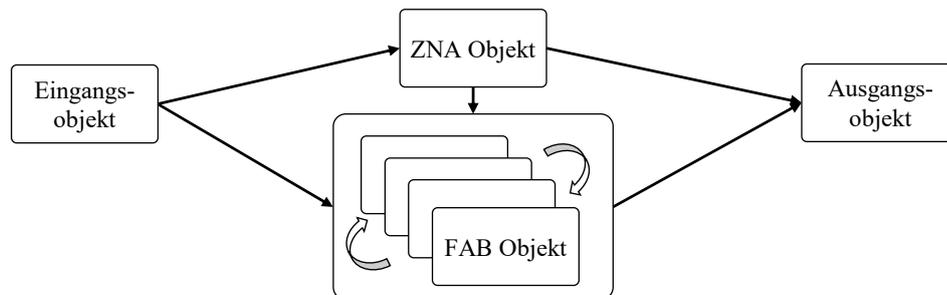


Abbildung 5.4.: Simulationsobjekte (Quelle: Eigene Darstellung)

Im Eingangsobjekt werden die Patienten, basierend auf Ankunftsverteilungen, erstellt. Anschließend werden mithilfe verschiedener Wahrscheinlichkeitsverteilungen die Patienteneigenschaften, wie z. B. Geschlecht, Isolationsstatus und nächste Station festgelegt. Im Ausgangsobjekt werden Patienten, deren Behandlung abgeschlossen ist, aus dem Krankenhaus entlassen und verschiedene Statistiken aufgenommen. Die eigentliche Behandlung der Patienten findet im ZNA-Objekt und in den Stationsobjekten statt. Dabei wird ein Patient auf der jeweiligen Station aufgenommen und wartet seine Verweildauer ab. Anschließend wird entschieden, ob der Patient auf eine neue Station verlegt oder entlassen wird. Jede Patientenbewegung in diesem Modell erfolgt durch einen Entscheidungsknoten. Innerhalb dieses Entscheidungsknotens ist die Heuristik implementiert.

Dieses Modell wurde initial für die Evaluation des Szenarios [S3] erstellt. Jedoch zeigt die Nutzung objektorientierter Prinzipien die Möglichkeiten der Wiederverwendbarkeit. Zum einen ist die Prozesslogik innerhalb der Objekte gekapselt. Dies bedeutet, dass man die interne Logik eines Objektes ändern kann, ohne die komplette Modellstruktur anzupassen. Dieser Umstand wird bei der Evaluation der Ansätze aus den Kapiteln 6 und 7 deutlich. Für den Abschnitt 6 wird der Prozess der Patientenerstellung angepasst. Anstelle der Wahrscheinlichkeitsverteilungen werden Terminpläne für Patienten verwendet. Im Kapitel 7 erfolgt zusätzlich eine Anpassung des Entscheidungsprozesses, um den vorgestellten Ansatz im Simulationsmodell zu implementieren. Ein weiteres objektorientiertes Prinzip, welches

5. Stationsübergreifende Überlaufregeln im flexiblen Patientenflussmanagement

bei der Erstellung des Modells berücksichtigt wurde, ist die Vererbung. Dabei können in SIMIO neue Objekte durch Vererbung bereits bestehender Objekte erstellt werden [133]. Die ursprüngliche Prozesslogik kann beibehalten werden und die Einzigartigkeit des neuen Objektes kann über zusätzliche Prozesse oder Objekteigenschaften dargestellt werden. Dies wurde bei der Erstellung der ZNA-Objekte und der Stationsobjekte genutzt. Das Stationsobjekt stellt dabei die Basisklasse dar und das ZNA-Objekt ist die abgeleitete Klasse. Im ZNA-Objekt wurde die Prozesslogik angepasst, um die Besonderheiten einer ZNA widerzuspiegeln. Ein weiteres wichtiges Prinzip, welches umgesetzt wird, ist die Komposition. In SIMIO besteht jedes Simulationsmodell aus einer Zusammensetzung von Instanzen von Objekten [133]. Dabei kann jedes Krankenhaus in Deutschland anhand der Basisobjekte aus der Abbildung 5.4 erstellt werden. Um die Wiederverwendbarkeit des Simulationsmodells sicherzustellen, ist es in ein datengetriebenes System (Abb. 5.5 a) eingebettet, welches es dem Nutzer erlaubt, für verschiedene Datensätze eigene Simulationsmodelle zu erstellen. Dabei muss das Simulationsmodell nicht händisch verändert werden. Solange die Daten der Struktur aus Kapitel 4 entsprechen, kann das System genutzt werden. Diese Rohdaten werden in einer Datenbank gespeichert. Mithilfe verschiedener Daten-Verarbeitungsroutinen werden die Daten aufbereitet und die Verteilungen gebildet. Diese werden anschließend in Kombination mit den Infrastrukturdaten genutzt, um ein Simulationsmodell zu erstellen und zu berechnen. Die Erstellung des Modells erfolgt über ein selbst entwickeltes Plug-in für SIMIO, welches aus den berechneten Daten und den Basisobjekten eine Instanz des Simulationsmodells generieren kann. Die Nutzung des datengetriebenen Systems ist in Abbildung 5.5 b beschrieben.

Um die Wiederverwendbarkeit dieses Modellierungsansatzes zu unterstreichen, wird das Modell zusätzlich verwendet, um die Verfahren der Kapitel 6 und 7 zu evaluieren. Dabei werden verschiedene Iterationsstufen des Simulationsmodells, basierend auf endogenen Entscheidungsprozessen und den exogenen Patientenankünften, verwendet. Dabei werden zur Simulation der Überlaufregeln die Entscheidungsprozesse zur initialen Wahl der Station durch Wahrscheinlichkeitsverteilungen approximiert. Dies erfolgt in Kombination mit im Vorfeld bekannten und durch die jeweilige Strategie vorgegebene Alternativen. In Kapitel 6 wird diese Entscheidung exogen durch das verwendete Optimierungsmodell zur Termin- und Aufnahmeplanung vorgegeben. In Kapitel 7 wird ein intelligenter Entscheidungsprozess zur operativen Patientenflusssteuerung implementiert. Daher erfolgt hier die Nachahmung menschlicher Entscheidungskompetenz innerhalb des Simula-

5. Stationsübergreifende Überlaufregeln im flexiblen Patientenflussmanagement

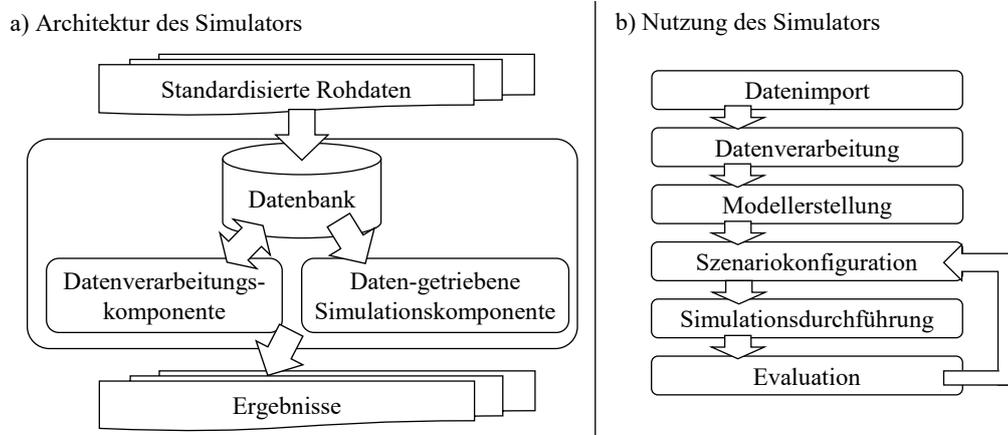


Abbildung 5.5.: Einordnung des Simulationsmodells in einen datengetriebenen Simulator und dessen Nutzung (Quelle: Eigene Darstellung)

tionsmodells. Somit kommt es zu einer generellen Verfeinerung der Entscheidungsfindung innerhalb des Modells. Der Übergang von einer Approximation der Entscheidung durch Wahrscheinlichkeitsverteilungen zur direkten Implementation des Entscheidungsalgorithmus kann den in [123] diskutierten Model-Reality-Gap verkleinern. Dabei werden Annahmen zur Modellierung sukzessive durch realitätsnahe Implementierungen ersetzt. Dies führt zu einer höheren Genauigkeit der Simulationsergebnisse und eine bessere Überführbarkeit in die Praxis. Auch im Bereich der Inputdatenmodellierung, in diesem Fall explizit die Modellierung der exogenen Patientenankünfte, variiert mit dem Anwendungszweck. Während der Untersuchung der Überlaufregeln erfolgt die Modellierung der Patientenankünfte über empirische Verteilungen, wie in diesem Kapitel beschrieben. Zur Evaluation der operativen Patientenflusssteuerung und der Termin- und Aufnahmeplanung erfolgt eine deterministische Simulation mit direkt aus den Daten extrahierten Patientenankünften. Im Falle der Termin- und Aufnahmeplanung wird dieser trace-driven Ansatz durch die Nutzung empirischer Verteilungen zur Generation von Notfallpatienten verfeinert. Aufgrund des objektorientierten Ansatzes lassen sich diese verschiedenen Iterationsstufen der Entscheidungs- und Ankunftsmodellierung frei kombinieren, um weitere Fragestellungen des Patientenflussmanagements zu untersuchen.

5.2.4. Verifizierung und Validierung

Um die Ergebnisse der Simulationsstudien einzuordnen und erfolgreich in die Praxis zu überführen, ist es von großer Bedeutung, das Modell zu verifizieren und zu validieren [94]. Verifizierung beschreibt hier den Prozess der Überprüfung der Korrektheit der Modellierung. Dies wird im Allgemeinen in Zusammenarbeit mit Domänenexperten durchgeführt. In diesem Fall wurde die Struktur der Objekte, ihre Verbindung untereinander und die jeweiligen Prozesslogiken mit Mitarbeitern des Beispielkrankenhauses diskutiert. Dabei wurde bescheinigt, dass die Modellierung angemessen ist und einen für die vorliegenden Fragestellungen ausreichenden Detailgrad besitzen. Die Validation, also die Untersuchung des korrekten Systemverhaltens wiederum, wird datengetrieben durchgeführt. Dazu wird das Verhalten des initialen Modells mit den Ausgangsdaten verglichen. Dabei werden vor allem die Anzahl der elektiven Patienten und der Notfälle sowie deren Verteilung über den Tag untersucht. Weiterhin werden die im Simulationsmodell gemessenen Verweildauern mit den aus den Daten extrahierten Werten verglichen. Abschließend wird auf Basis der durchgeführten Aufenthalte auf den Stationen ermittelt, ob die Übergangsverteilungen zwischen den Stationen korrekt arbeiten.

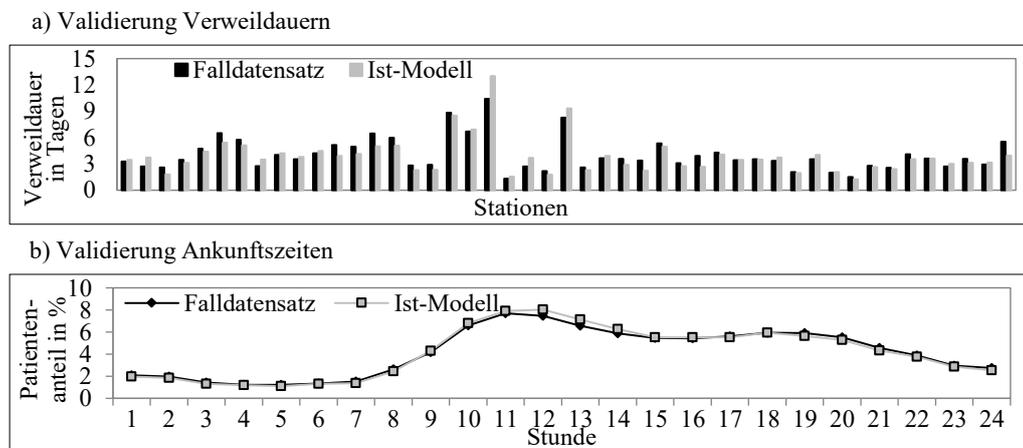


Abbildung 5.6.: Validierung der Verweildauern und der Ankunftszeiten (Quelle: Eigene Darstellung)

5. Stationsübergreifende Überlaufregeln im flexiblen Patientenflussmanagement

Basierend auf dem zugrunde liegenden Datensatz wurden 25.589 elektive Patienten und 9.087 stationäre Notfallpatienten im Beispieljahr behandelt. In einer Simulationsstudie mit 100 Replikationen wurden vom Simulationsmodell durchschnittlich 24.707 elektive Patienten und 9.064 stationäre Notfallpatienten erzeugt. Dies zeigt, dass die Anzahl der zu behandelnden Patienten von der Ankunftsverteilung sehr genau getroffen werden.

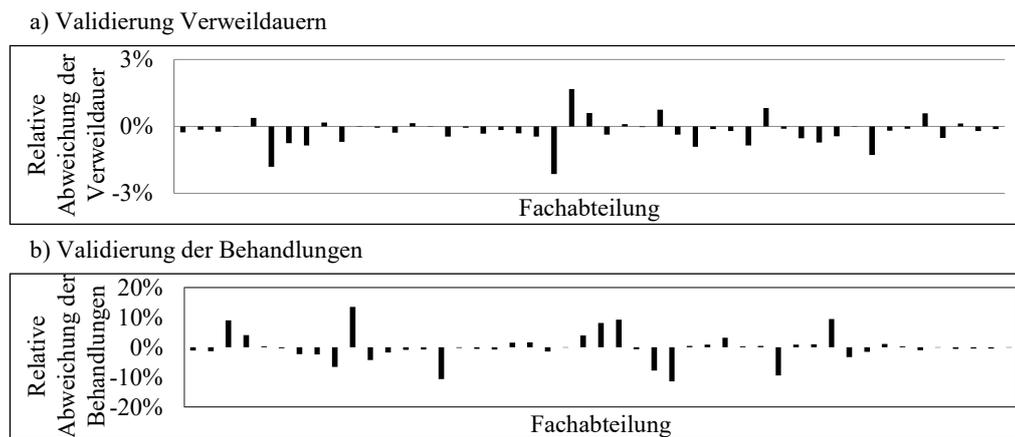


Abbildung 5.7.: Validierung der Verweildauern und der Behandlungsanzahl (Quelle: Eigene Darstellung)

In Abbildung 5.6 werden die durchschnittlichen Verweildauern und die beobachteten Ankunftszeiten innerhalb eines Tages untersucht. Die Kurven der Ankunftszeiten (Abb. 5.6 b) zeigen deutlich, dass die Verteilungen der Zwischenankunftszeiten die Realität sehr genau trifft. Es ist lediglich eine kleine Abweichung zu erkennen. In der gleichen Abbildung befindet sich eine Validierung der durchschnittlichen Verweildauer in Tagen auf jeder Station (Abb. 5.6 a). Hier wird gezeigt, dass die Verweildauerberechnung im Simulationsmodell die Realität genau trifft. Dies wird von Abbildung 5.7 a unterstrichen. Hier ist die prozentuale Differenz der Verweildauern angegeben. Die Abweichungen schwanken zwischen -2,1 % und 1,6 % mit einer durchschnittlichen Abweichung von 0,23 %. Um die Bewegung der Patienten genauer zu untersuchen, werden die durchgeführten Behandlungen detailliert betrachtet. Das Modell generiert 45.013 Behandlungen im Jahr, die den Wert von 45.172 Behandlungen in den Daten sehr genau widerspiegelt. In Abbildung 5.7 b) werden diese Behandlungen für die einzelnen Stationen aufgeschlüsselt. Hier schwanken die Abweichungen zwischen -11 % und 13 %. Unter

5. Stationsübergreifende Überlaufregeln im flexiblen Patientenflussmanagement

Beachtung, dass nur drei Stationen eine Abweichung von mehr als $\pm 10\%$ haben, kann der Schluss gezogen werden, dass die Bewegung der Patienten im Modell die Realität hinreichend genau darstellt. Zusammenfassend wurde in der Verifikation und Validierung gezeigt, dass das präsentierte Simulationsmodell die korrekte Logik implementiert und die berechneten Verteilungen die Realität hinreichend genau widerspiegeln.

5.3. Praxisorientierte Evaluation der Überlaufregeln

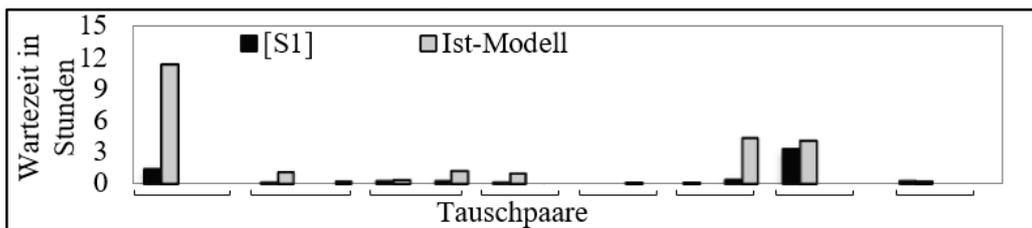
Die folgenden Ergebnisse wurden auf Basis des Simulationsmodells aus diesem Kapitel und dem in Kapitel 4 vorgestellten Datensatz ermittelt. Dazu wurden Simulationsläufe mit der Dauer von einem Jahr und jeweils 100 Replikationen durchgeführt. Die Simulation der Strategie [S4], also der Einführung einer allgemeinen Rehabilitationsstrategie hatte im vorliegenden Datensatz keinen Einfluss auf die Wartezeiten der Patienten. Dies lässt sich damit begründen, dass die Patientengruppen, die für eine frühe Rehabilitation vorgesehen sind, selten auf Engpassstationen behandelt werden. Somit lässt sich beim Zugrundelegen des vorhandenen Datensatzes keine abschließende Entscheidung zur Einführung einer allgemeinen Rehabilitationsstation treffen. Aber die zugrunde liegende Idee, also das frühzeitige wieder zur Verfügung stellen von Kapazitäten zur Behandlung bietet aus theoretischer Sicht viele Vorteile, die in Kapitel 7 genutzt werden, um die Flexibilität in der operativen Patientenflusssteuerung mit Hilfe von Umlagerungen zu erhöhen.

In Abbildung 5.8 sind die Ergebnisse der Zimmertauschstrategie [S1] dargestellt. Hier ist deutlich zu erkennen, dass die Wartezeit der Patienten auf eine Verlegung auf eine andere Station deutlich sinkt. Bei einer Verlegung von einer Normalstation auf eine weitere Normalstation reduziert sich die Wartezeit um bis zu 10 Stunden. Auf vielen Stationen wurde die Wartezeit nahezu komplett eliminiert. Bei der Verlegung eines Patienten von der ZNA auf eine Normalstation ergibt sich ein ähnliches Bild. Hier sind die Wartezeiten um bis zu 50 % reduziert. Anzumerken ist, dass es auf allen Stationen weiterhin zu Wartezeiten kommt. Die von den Stationen befürchtete Benachteiligung einzelner Stationen trat nicht auf. Generell ist die Wartezeit entweder gesunken oder annähernd gleich geblieben. Dies zeigt

5. Stationsübergreifende Überlaufregeln im flexiblen Patientenflussmanagement

eindrucksvoll, dass eine gesteigerte Flexibilität die Handlungsfähigkeiten der Stationen in Engpasssituationen deutlich verbessern kann.

a) Wartezeiten von Station auf Folgestation



b) Wartezeiten von ZNA auf Folgestation

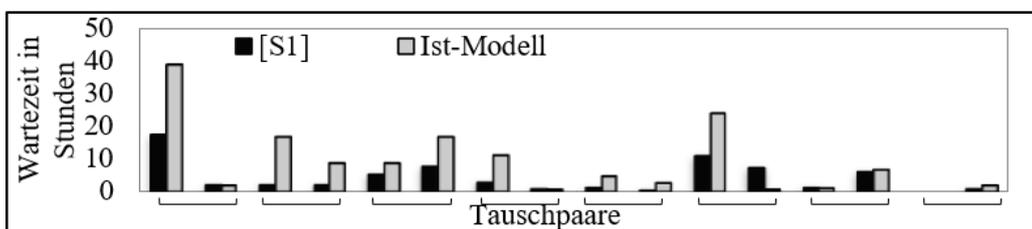


Abbildung 5.8.: Veränderung der Wartezeit in [S1] (Quelle: Eigene Darstellung)

Die Ergebnisse der Zusammenführung der Kapazitäten der ITS- und IMC-Stationen in Abbildung 5.9 zeigen, dass mit dieser Strategie die Wartezeiten auf ein Bett in diesen wichtigen Bereichen vollständig vermieden werden. Die im Ausgangsmodell hohen Wartezeiten wurden auf 0 reduziert, ohne die Normalstationen zu benachteiligen. Der in Kapitel 2 diskutierte und von Praktikern befürchtete negative Einfluss von Prozessverbesserungen auf nachgelagerte Organisationseinheiten trat hier nicht ein.

Zusammenfassend haben die Strategien [S1] und [S2] untermauert, dass Flexibilität im Belegungsprozess die Wartezeit der Patienten deutlich reduzieren kann. Aus diesem Grund wurden [S1] und [S2] zu einem Clusterszenario zusammengefasst [S3]. Anders als in [S1] und [S2] ist die Wartezeit nicht der entscheidende Faktor zur Evaluation. Hier werden grundlegende Kapazitätsentscheidungen unter der Annahme getroffen, dass eine geplante Verlegung auf jeden Fall durchgeführt werden muss. Wenn sie aufgrund fehlender Kapazitäten nicht möglich ist, verlegt das Simulationsmodell diesen Patienten in ein virtuelles Bett. Dies spiegelt die gängige Praxis der Krankenhäuser wider, für Patienten in Engpasssituationen verfügbare

5. Stationsübergreifende Überlaufregeln im flexiblen Patientenflussmanagement

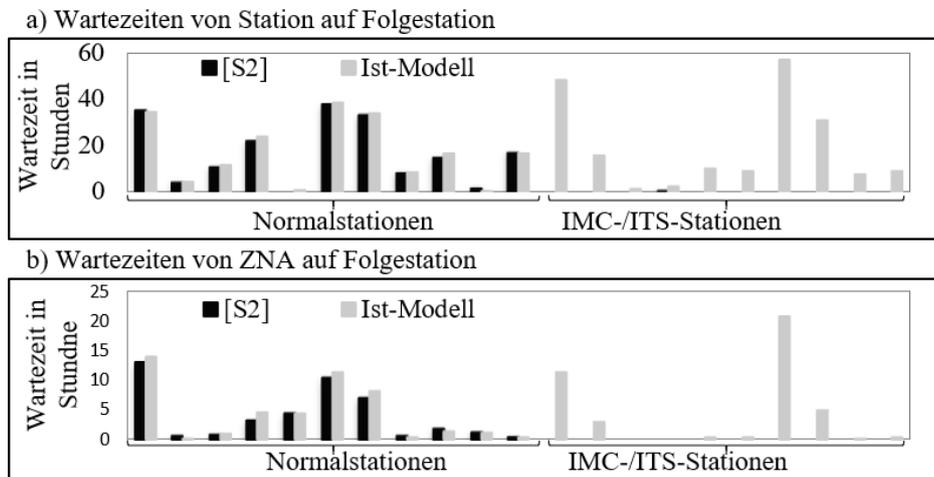


Abbildung 5.9.: Veränderungen der Wartezeiten in [S2] (Quelle: Eigene Darstellung)

Kapazitäten im Krankenhaus zu finden, auf denen er temporär aufgenommen werden kann. In der Regel werden diese Entscheidungen nicht dokumentiert. Somit spiegelt die Anzahl der genutzten virtuellen Betten auch die Anzahl undokumentierter Ad-hoc Entscheidungen im Belegungsmanagement wider, welche minimiert werden sollten.

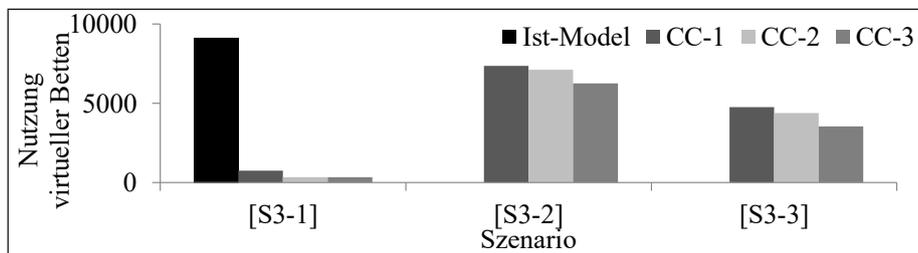


Abbildung 5.10.: Nutzung virtueller Betten in den Clusterkonfigurationen von [S3] (Quelle: Eigene Darstellung)

In Abbildung 5.10 sind die Ergebnisse der Clusterkonfiguration für die verschiedenen Szenarien dargestellt. Im Vergleich zum aktuellen Modell konnte die Nutzung der virtuellen Betten signifikant reduziert werden. Die Anzahl genutzter virtueller Betten reduzierte sich von 9.135 auf 746 (CC-1), 347 (CC-2) bzw. 341 (CC-3). Diese deutlichen Reduktionen unterstreichen das große Potenzial eines flexiblen

5. Stationsübergreifende Überlaufregeln im flexiblen Patientenflussmanagement

Belegungsmanagements. Die durchschnittliche Auslastung der Stationen zeigt in diesem Szenario keine signifikante Veränderung und bleibt bei einem Wert zwischen 55 % und 56 %. Jedoch konnten kurzfristige Belastungsspitzen abgefangen werden. Basierend auf den Ergebnissen des ersten Szenarios wurde die Anzahl der zu streichenden Betten im zweiten Szenario berechnet. Hier konnten laut Berechnung 354 Betten eingespart werden. Das Ziel, die durchschnittliche Stationsauslastung auf 85 % zu erhöhen, wurde erreicht. Da keine der Stationen eine Auslastung von deutlich über 85 % aufweist, kann auch darauf geschlossen werden, dass die Verteilung der Belastungsspitzen weiterhin funktioniert. Jedoch sind die Stationen nun anfälliger für kurzfristige Belastungsspitzen. Der Anstieg der Nutzung der virtuellen Betten bestätigt dies. Interessanterweise könnte das Krankenhaus in diesem Szenario trotz des Wegfalls eines Drittels aller Betten besser arbeiten als im Ausgangsmodell. Die Erhöhung der Patientenzahlen im dritten Szenario zeigt einen ähnlichen Effekt. Die Auslastung stieg auf durchschnittlich 81 % und die Nutzung der virtuellen Betten liegt weiterhin unter denen des initialen Modells.

Die Ergebnisse dieser Fallstudien zeigen deutlich, dass eine gesteigerte Flexibilität in der Lage ist, kurzfristige Engpassituationen effizient zu lösen. Dabei werden sporadische Belastungsspitzen ausgeglichen und die Arbeitsbelastung fair unter den Stationen eines Clusters aufgeteilt.

Zur genaueren Untersuchung des Einflusses operativer Nebenbedingungen auf die Simulationsergebnisse wurde das initiale Simulationsmodell einmal mit und einmal ohne die Nebenbedingungen zur Geschlechtertrennung und zur Patientenisolierung simuliert. Wurden im Ausgangsmodell ca. 9.000 virtuelle Betten verwendet, nutzt das Modell bei abgeschalteten Nebenbedingungen lediglich 4.325. Das ist eine Verringerung um mehr als die Hälfte. Diese Differenz stärkt die Annahme, dass operative Nebenbedingungen in Simulationsmodelle integriert werden sollten, um die Ergebnisse der Simulationsstudie nicht zu verfälschen.

Die Strategien, die in diesem Kapitel vorgestellt wurden, repräsentieren generelle Handlungsempfehlungen für das Krankenhaus, welche mit Hilfe der Simulationsstudien evaluiert wurden. Sie können nicht unmittelbar im Krankenhaus implementiert werden. Bezugnehmend auf die unterschiedlichen Ebenen der operativen Planung und Durchführung der Behandlung müssen diese Empfehlungen in die operative Planung der Aufnahmetermine und der operativen Durchführung von Aufnahmen berücksichtigt werden.

6. Operative Terminplanung elektiver Patienten unter Antizipation von Notfallpatienten mithilfe robuster Optimierung

Die in den vorherigen Kapiteln vorgestellten Überlaufregeln sind theoretisch in der Lage, kurzfristige Belastungsspitzen zu verteilen. Um das volle Potenzial auszuschöpfen, müssen diese Erkenntnisse in den operativen Betrieb überführt werden. Basierend auf den Ergebnissen der vorherigen Kapitel wird ein Verfahren zur operativen Aufnahmeplanung elektiver Patienten vorgestellt. Dabei wird ein Optimierungsmodell implementiert, welches die Möglichkeit der flexiblen Ressourcennutzung erlaubt.

6.1. Zielstellung der operativen Terminplanung

Das Ziel der operativen Aufnahmeplanung liegt darin, die Auslastung eines Krankenhauses zu maximieren. Diese kann planbar lediglich erreicht werden, wenn die Anzahl der elektiven Patienten erhöht wird, was mit der derzeitigen Praxis in Krankenhäusern nur bedingt möglich ist. Durch die fixe Aufteilung in Kapazitäten für elektive Patienten und für Notfallpatienten liegt die maximal planbare Auslastung immer unter 100 %. Ein weiteres Ziel der operativen Terminplanung ist es, einen initialen Plan möglichst ohne weitere Terminverschiebungen durchzuführen. Durch die oftmals aggregierte Betrachtung der Kapazitäten ohne Beachtung operativer

6. Operative Terminplanung elektiver Patienten mit Antizipation von Notfallpatienten

Nebenbedingungen ist die Wahrscheinlichkeit hoch, dass ein initialer Terminplan nicht umsetzbar ist. Dies wurde im vorherigen Kapitel mit der Untersuchung des Einflusses der Geschlechtertrennung gezeigt. Ohne Beachtung dieser operativen Nebenbedingung wird der Einfluss neuer Planungsmethoden überschätzt und die Notwendigkeit der operativen Neuplanung ist gegeben. Zusätzlich kann es zu Terminverschiebungen und Ablehnungen im operativen Betrieb kommen, wenn die Anzahl der Notfallpatienten die reservierte Kapazität überschreitet. Somit ist das zweite Ziel der operativen Aufnahmeplanung die Vermeidung von Terminverschiebungen und Ablehnungen im operativen Betrieb.

Um diese Ziele zu erreichen, erfolgt eine Dynamisierung der festen Kapazitätsgrenzen. Somit kann bei einer hohen Nachfrage von Notfallpatienten mehr Kapazität für diese bereitgestellt werden und bei geringerer Nachfrage können mehr elektive Patienten aufgenommen werden. Das entscheidende Problem dabei ist, dass elektive Patienten schon im Voraus und Notfallpatienten erst im operativen Betrieb bekannt sind. Somit lässt sich die Planung der elektiven Patienten als Offline-Planung charakterisieren. Die initiale Terminvergabe erfolgt langfristig auf Basis aggregierter Kapazitäten, da diese Patienten nach und nach Terminanfragen stellen und eine Optimierung daher nicht möglich ist. Zur Dynamisierung der Kapazitätsgrenzen sind somit kurzfristige Umplanungen notwendig. Da Notfallpatienten erst im operativen Betrieb bekannt werden, können sie nicht explizit in der Offline-Planung integriert werden. Eine Integration der Notfallpatienten ist in der täglichen Aufnahmeplanung möglich [32]. Dabei wird an jedem Tag ein neues Planungsproblem mit aktuellsten Informationen gelöst. Hier ergibt sich jedoch das Problem, dass mögliche Terminverschiebungen elektiver Patienten erst am Tag der geplanten Aufnahme erkannt werden. Dies führt zu Unannehmlichkeiten bei diesen Patienten. Daher ist eine Offline-Planung mit Antizipation der Notfallaufnahmen notwendig, um diese negativen Aspekte der Terminverschiebung so gering wie möglich zu halten.

Trotz der frühzeitigen Information über Terminverschiebungen sollten diese, wenn möglich, vermieden werden. Daher ist eine Flexibilisierung der Ressourcennutzung angestrebt. Die Erkenntnisse aus dem vorherigen Kapitel werden verwendet, um die in diesem Kapitel vorgestellte Modellierung auf mehrere Stationen anzuwenden. Somit können Stationen mit temporär geringerer Nachfrage ihre Kapazitäten anderen Stationen zur Verfügung stellen.

Daher zeigt dieses Kapitel ein Verfahren, das die Bettenallokation elektiver Patienten auf planerischer Ebene [45] mit der Planung von Terminverschiebung auf operativer Durchführungsebene [32] verbindet, um eine robuste Terminverschiebung auf operativer Ebene zu ermöglichen. Zusätzlich wird die flexible Nutzung vorhandener Ressourcen auf anderen Stationen ermöglicht. Im folgenden Abschnitt wird die Modellierung formalisiert, um sie anschließend in ein robustes lineares Optimierungsmodell zu überführen.

6.2. Aktueller Stand der Literatur und Formalisierung der operativen Terminplanung elektiver Patienten

Wie bereits angesprochen, teilt sich die operative Terminplanung elektiver Patienten in zwei Bestandteile: taktische Terminplanung und der Zuordnung von Patienten zu Betten. Die Verteilung der Patienten auf die Betten wurde erstmals von Deemeester et al. (2010) [45] formalisiert. Diese Variante erlangte viel Wahrnehmung in der wissenschaftlichen Literatur. Viele verschiedene Forschungsgruppen betrachteten und betrachten diese Problemstellung [31, 19, 33, 165, 70, 138, 96, 161, 1, 14, 20, 66]. Hierbei handelt es sich eher um ein akademisches Interesse mit dem Ziel, bessere Lösungsalgorithmen zu entwickeln. Probleme bei der Überführung in den operativen Betrieb werden nicht betrachtet. Während der Zuordnung der Patienten zu Betten ist eine Veränderung der Aufnahmetermine nicht vorgesehen. Dies bedeutet, dass ein initialer Terminplan zwingend mit operativen Nebenbedingungen lösbar sein muss. Damit betrachtet diese Variante lediglich eine Optimierung des Patientenkomforts und hat keine Auswirkungen auf die Auslastung des Krankenhauses. Die Zuordnung von Patienten zu Betten kann somit nur in Verbindung mit einer initialen Terminplanung der Patienten erfolgen. Die Untersuchung der Erstellung von Terminplänen für Patienten ist ein reichhaltiges Forschungsgebiet, welches von verschiedenen Publikationen [13, 39, 53, 54, 144] gestützt wird. Im Generellen wird die Zuordnung der Aufnahmetermine lange vor der eigentlichen Aufnahme durchgeführt und es werden nur elektive Patienten betrachtet. Zusätzlich erfolgt eine Entscheidung ohne Beachtung operativer Nebenbedingungen auf Basis aggregierter Kapazitäten. Die Natur dieser Entscheidung ist aber von den Patienten vorgegeben, da sie Termine zu unterschiedlichen

6. Operative Terminplanung elektiver Patienten mit Antizipation von Notfallpatienten

Zeiten nachfragen. Im Allgemeinen erfolgt dies nach einer Vorstellung bei einem niedergelassenen Arzt. Ein Sammeln der Anfragen, um eine Optimierung der Aufnahmedaten zu ermöglichen, ist tendenziell nicht möglich, da die Patienten eine direkte verbindliche Terminzusage erwarten. Somit ist eine Neuplanung unter Berücksichtigung operativer Nebenbedingungen kurz vor der Aufnahme sehr wahrscheinlich. Diese Umplanung wurde erstmals von Ceschia und Schaerf (2012a) [32] gezeigt. Hier erfolgt eine Zuordnung von Patienten zu Betten mit der Möglichkeit der Anpassung von Aufnahmetermenin, um mögliche Kapazitätsengpässe zu verhindern. Dabei werden zusätzlich Notfallpatienten betrachtet. Diese Problemstellung wurde aus akademischer Sicht von vielen Forschern aufgegriffen, die neue Lösungsalgorithmen entwickeln und die Lösungen für akademische Probleminstanzen sukzessive verbessern [32, 164, 34, 112, 67]. Im Gegensatz zur individuellen Betrachtung der Terminvergabe und der Bettenzuordnung handelt es sich hierbei um eine Online-Planung, bei der das Entscheidungsproblem jeden Tag mit aktuellsten Informationen gelöst wird. Dabei werden sehr gute Lösungen erzielt, um den operativen Betrieb eines Krankenhauses aufrecht zu erhalten. Jedoch offenbart ein Online-Planungsansatz verschiedene Nachteile. Zum einen können vorherige Entscheidungen nicht geändert werden und zum anderen erfolgen die Benachrichtigungen über Terminverschiebungen sehr kurzfristig. Dies erzeugt unnötigen Stress für die Patienten.

Ein echter Ansatz zur Umplanung elektiver Patienten mit der Betrachtung von Notfallpatienten fehlt in der wissenschaftlichen Fachliteratur. Dieses Kapitel schließt diese Lücke, indem es den grundlegenden Gedankengang von [32] aufgreift und zu einem Offline-Planungsansatz erweitert. Dabei wird ein initialer Terminplan unter Berücksichtigung operativer Nebenbedingungen auf Machbarkeit geprüft.

Die formalen Bestandteile des Planungsproblems sind in Tabelle 6.1 gegeben. Eine Planungsperiode beschreibt eine Menge aufeinanderfolgende Tage, welche die Zeiteinheit für einen Patientenaufenthalt angeben. Die Patienten sind in elektive und stationäre Notfallpatienten unterschieden. Wie bereits diskutiert, sind die elektiven Patienten im Vorfeld bekannt und die geplanten Aufnahmetermine können nach Bedarf angepasst werden. Stationäre Notfallpatienten sind zum Planungszeitpunkt unbekannt. Eine weitere Besonderheit dieser Patientengruppe ist der Umstand, dass diese nicht verschoben werden dürfen. Wenn sie das Krankenhaus betreten, müssen sie entweder versorgt oder abgelehnt werden. Die Patienten werden auf einer Station aufgenommen, welche die Organisationseinheit

6. Operative Terminplanung elektiver Patienten mit Antizipation von Notfallpatienten

Tabelle 6.1.: Formalisierung der Terminplanung (Quelle: Eigene Darstellung in Anlehnung an [45])

Element	Beschreibung
Planungsperiode	Anzahl aufeinanderfolgender Tage
Tag	Zeiteinheit des Patientenaufenthaltes
Elektive Patienten	sind im Vorfeld bekannt können umgeplant werden
Stationäre Notfallpatienten	werden erst in der Planung bekannt sofortige Aufnahme notwendig
Station	sind auf verschiedene Behandlungen spezialisiert Patienten werden im Vorfeld zugewiesen
Zimmer	sind einer Station zugeordnet stellen Bettenkapazitäten zur Verfügung
Cluster	Zusammenschluss ähnlicher Stationen

zur Behandlung darstellt. Den Stationen sind Zimmer zugeordnet, die eine gewisse Kapazität an Betten haben.

Das Ziel ist es, die Patienten den Zimmern zuzuordnen, sodass eine maximale Auslastung erreicht wird. Diese Belegung erfolgt unter Beachtung verschiedener Nebenbedingungen (Tabelle 6.2). Diese werden in harte und weiche Nebenbedingungen unterschieden. Harte Nebenbedingungen müssen eingehalten werden und bestimmen somit die Lösbarkeit des Modells. Im Gegensatz dazu haben weiche Nebenbedingungen einen Einfluss auf die Qualität der Lösung und werden in der Zielfunktion berücksichtigt. Die erste harte Nebenbedingung (*RC*) beschreibt die Raumkapazität. Bei der Belegung mit Patienten darf die vorgegebene Kapazität eines Zimmers nicht überschritten werden. Die zweite Nebenbedingung (*RG*) bezieht sich auf die strikte Geschlechtertrennung in einem Zimmer. Unabhängig von der Kapazitätssituation dürfen in einem deutschen Krankenhaus Männer und Frauen nicht zeitgleich in einem Zimmer aufgenommen oder behandelt werden. Die folgenden weichen Nebenbedingungen (*SZ*, *V* und *ZA*) bestimmen in der Zielfunktion die Qualität der Lösung. *SZ* beschreibt die Stationszuordnung der Patienten. Dabei sollte ein Patient möglichst auf der gewünschten Station aufgenommen werden. Während Kapazitätsengpässen ist jedoch eine Aufnahme auf Alternativstationen möglich. Die Nebenbedingung *V* beschreibt die Anzahl der Verlegungen eines Patienten während des Aufenthaltes. Prinzipiell ist es möglich, dass ein Patient während der Behandlung das Zimmer wechselt. Da dies Unannehmlichkeiten

6. Operative Terminplanung elektiver Patienten mit Antizipation von Notfallpatienten

Tabelle 6.2.: Nebenbedingungen (Quelle: Eigene Darstellung in Anlehnung an [45])

Restriktion	Typ
Raumkapazität (RC)	HC
Geschlecht (RG)	HC
Stationszuordnung (SZ)	SC
Verlegung (V)	SC
Raumbelegung (ZA)	SC

bedeutet, sollte die Anzahl dieser Verlegungen minimiert werden. Hierbei ist zu beachten, dass nach erfolgter Aufnahme nur ein Zimmerwechsel innerhalb einer Station möglich ist. ZA beschreibt die Belegungsdichte. Dabei sollen so wenig Zimmer wie möglich verwendet werden, um die freien Kapazitäten flexibel im operativen Betrieb zu nutzen.

6.3. Methodische Grundlagen der Netzwerkmodellierung und der robusten linearen Optimierung

Von Natur aus besitzen viele Planungsprobleme eine Netzwerkstruktur [158]. Bekannte Vertreter netzwerkartiger Planungsprobleme sind Transport-, Fluss- und Distributionsprobleme. Innerhalb dieses Kapitels wird gezeigt, dass sich auch die Terminplanung elektiver Patienten in diese Problemkategorie einsortieren lässt.

Ein Vorteil netzartiger Planungsprobleme ist, dass sie sich einfach als lineare Optimierungsmodelle darstellen lassen. Zusätzlich ergeben sich aus ihrer Struktur Lösungsvorteile bei der Verwendung spezieller Netzwerkalgorithmen [158]. Jedoch weisen viele praxisrelevante Netzwerkprobleme oft zusätzliche Restriktionen auf, die nicht durch die Netzwerkstruktur erfasst werden können und daher die Nutzung eines linearen Optimierungsmodells unabdingbar ist. Da der betrachtete Patientenfluss tendenziell eine netzartige Struktur aufweist, erfolgt eine Modellierung als Netzwerkflussproblem. Aufgrund zusätzlicher operativer Flussrestriktionen, wie z. B. die Geschlechtertrennung, muss diese Flussmodellierung in ein lineares Optimierungsmodell überführt werden. Zur Vorbereitung der Modellierung des

6. Operative Terminplanung elektiver Patienten mit Antizipation von Notfallpatienten

Patientenflusses und dessen Optimierung erfolgt in diesem Abschnitt eine kurze Einführung in die methodischen Grundkonzepte der Netzwerkmodellierung auf Basis der Graphentheorie und der linearen Optimierung.

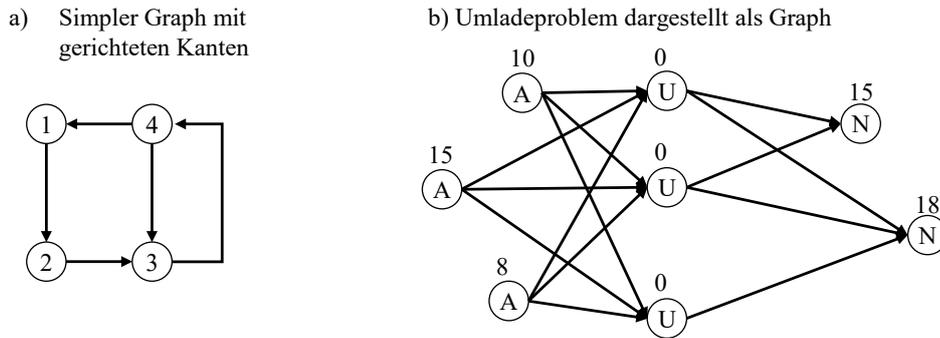


Abbildung 6.1.: Darstellung eines simplen Graphens und eines Umladeproblems (Quelle: Eigene Darstellung in Anlehnung an [158])

In der Graphentheorie besteht ein Graph immer aus einer Menge an Knoten (N) und Kanten (E). Kanten können dabei gerichtet oder ungerichtet sein. Gerichtete Kanten verbinden zwei Knoten immer genau in eine Richtung, während ungerichtete Kanten zwei Knoten ohne Beachtung der Richtung verbinden [158]. Formal gesehen werden in dieser Arbeit gerichtete Kanten zwischen den Knoten i und j als Paar (i, j) dargestellt, wobei die Reihenfolge der Knoten die Richtung der Kante vorgibt [48]. Daraus ergibt sich folgende vereinfachte formale Definition eines Graphen G : $G = (N, E)$. Ein Beispiel eines einfachen Graphen, entnommen aus [158], ist in Abbildung 6.1 a zu sehen. Hier ist ein Graph mit vier Knoten und fünf gerichteten Kanten dargestellt. Da die Menge der Kanten in einem Graphen schnell sehr groß werden kann, hat sich die Speicherung der Struktur eines Graphen in einer sogenannten Adjazenzmatrix durchgesetzt. Dabei handelt es sich um eine $n \times n$ -Matrix, bei der n die Anzahl der Knoten angibt. Die Elemente $a_{i,j}$ der Adjazenzmatrix geben die Anzahl der Kanten zwischen den Knoten wieder. Unter der Annahme, dass keine parallelen gerichteten Kanten zwischen zwei Knoten existieren, liegt dieser Wert bei eins, wenn eine Kante existiert und bei null, wenn keine Kante existiert [48]. Weiterhin lassen sich für einen Graphen verschiedene Bewertungen angeben. In diesem Fall wird die Definition des Graphen erweitert zu $G = (N, E, c, \lambda, \kappa)$. Dabei entspricht c einer Funktion, die jeder Kante E im Graphen einen Kostenwert $c_{i,j}$ zuweist. Analog stellen λ und κ Funktionen dar,

6. Operative Terminplanung elektiver Patienten mit Antizipation von Notfallpatienten

die einer Kante eine untere, $l_{i,j}$, und obere, $u_{i,j}$, Kapazitätsschranke zuweisen. Eine weitverbreitete Anwendung der Graphentheorie für Optimierungsprobleme liegt in der Bestimmung eines kostenminimalen Flusses von Gütern durch ein Netzwerk [158, 49, 48, 6]. Dabei wird die bestehende Definition des Graphen um eine Funktion ρ erweitert, die jedem Knoten im Netzwerk einen Bedarf bzw. ein Angebot $b(i)$ zuweist. Für den Fall, dass $b(i) > 0$ gilt, wird der Knoten als Angebotsknoten bezeichnet. Im umgekehrten Fall, also $b(i) < 0$, ist es ein Nachfrageknoten. Allgemein sendet ein Angebotsknoten Waren in das Netzwerk, ein Nachfrageknoten empfängt sie und ein Umladeknoten verteilt sie. Wenn $b(i) = 0$ gilt, dann ist es ein reiner Umladeknoten. Mit der nun nutzbaren Definition von G , $G = (N, E, c, \lambda, \kappa, \rho)$ lässt sich das in Abbildung 6.1 b dargestellte Umladeproblem darstellen. Dieses Problem lässt sich mithilfe verschiedener Algorithmen, wie z. B. dem Successiv-Shortest-Path Algorithmus, lösen. Für eine genauere Beschreibung verschiedener Lösungsalgorithmen für netzwerkbasierte Optimierungsprobleme sei in diesem Fall auf verschiedene Lehrbücher verwiesen [49, 158]. Im klassischen Umladeproblem besitzen nur die Kanten Kapazitätseinschränkungen. Aus praktischer Sicht kann es jedoch zur Forderung kommen, dass auch Knoten mit einer Kapazitätsbeschränkung versehen werden. Dies kann zum Beispiel erforderlich sein, wenn ein Umladeknoten im Netzwerk nur in der Lage ist, eine bestimmte Anzahl an Gütern umzuschlagen. Diese Eigenschaft lässt sich mit vergleichsweise einfachen Mitteln in das klassische Umladeproblem einbinden [158]. Dabei wird das Nodesplitting verwendet. Jeder Knoten i mit einer Kapazitätsbeschränkung wird in zwei Knoten i^1 und i^2 aufgeteilt, die mit einer Kante (i^1, i^2) verbunden sind, die als obere Schranke die Kapazität des ursprünglichen Knotens erhält.

Unter der Annahme, dass $X_{i,j}$ die Flussgröße auf der Kante (i, j) darstellt, lässt sich das vorgestellte Umladeproblem als lineares Optimierungsmodell darstellen, welches die Flusskosten minimieren soll:

6. Operative Terminplanung elektiver Patienten mit Antizipation von Notfallpatienten

$$\min \sum_{(i,j) \in E} c_{i,j} \cdot x_{i,j} \quad (6.1)$$

unter folgenden Nebenbedingungen:

$$\sum_{j:(i,j) \in E} X_{i,j} - \sum_{j:(j,i) \in E} X_{j,i} = b(i) \quad \forall i \in N \quad (6.2)$$

$$l_{i,j} \leq X_{i,j} \leq u_{i,j} \quad \forall (i,j) \in E \quad (6.3)$$

Dabei wird in der Zielfunktion (6.1) ein kostenminimaler Fluss angestrebt, indem die Kosten pro Flusseinheit mit der tatsächlichen Flussmenge multipliziert werden. Die Nebenbedingung 6.2 stellt sicher, dass ein Fluss aufrecht erhalten wird. Hier gilt, dass die Differenz des ausgehenden und eingehenden Flusses eines Knotens immer gleich der Nachfrage sein muss. Beispielsweise bedeutet dies, dass bei einem Umladeknoten der gesamte eingehende Fluss auch diesen Knoten wieder verlassen soll, da sein Angebot bei null liegt. Diese klassische Modellierung, die in vielen Lehrbüchern zu finden ist [49, 158], wird im weiteren Verlauf als Grundlage für die Darstellung des Patientenflusses verwendet. Im hier vorgestellten Optimierungsproblem sind alle wichtigen Eingabewerte und Parameter bekannt. Im realen Einsatz kommt es immer wieder vor, dass relevante Informationen einer gewissen Unsicherheit unterliegen. Die klassische lineare Optimierung, auch als einwertiges Verfahren bezeichnet, weist im Fall unsicherer Werte Mängel auf. Sie liefert nur für eine Realisierung der Eingabewerte und Parameter eine optimale Lösung. Mehrwertige Optimierungsmethoden, wie zum Beispiel die stochastische Optimierung und die robuste Optimierung, können hierbei die Lösungsgüte im Hinblick auf die Realität deutlich verbessern [149, 55]. Das Ziel hierbei besteht nicht mehr darin, ein optimales Ergebnis für eine bestimmte Kombination der Eingabewerte zu finden, sondern ein Ergebnis zu ermitteln, das in allen bzw. vielen Szenarien gut abschneidet. Im Folgenden wird die robuste Optimierung näher beleuchtet. Die Robustheit einer Entscheidung ist im Allgemeinen durch seine Unempfindlichkeit gegenüber zufälligen Umwelteinflüssen definiert [146]. Daher kann eine Entscheidung als robust angesehen werden, wenn sie für jede Umweltlage zu guten Ergebnissen führt [149]. Die Robustheit lässt sich anhand verschiedener Kriterien beurteilen. Dabei werden vor allem die Ergebnisrobustheit, die Optimalitätsrobustheit und die Zulässigkeitsrobustheit betrachtet. Das erste

6. Operative Terminplanung elektiver Patienten mit Antizipation von Notfallpatienten

Kriterium beschreibt die Eigenschaft der Ergebnisse, dass sie bei jeder möglichen Kombination der Eingabewerte einen bestimmten Mindestwert der Zielfunktion erreichen. Im zweiten Kriterium wird beschrieben, dass sich ein szenariospezifisches Optimum möglichst wenig vom Optimum der robusten Lösung unterscheiden soll. Die Zulässigkeitsrobustheit beschreibt die Eigenschaft, dass ein Ergebnis möglichst für alle möglichen Eingabewerte zulässig sein soll oder die Zulässigkeit durch mögliche Kompensationsmöglichkeiten sichergestellt wird.

Aus diesem Grund werden in der robusten Optimierung häufig Kompensationsmodelle verwendet, um die Zulässigkeit eines Planes zu ermöglichen. In einem Produktionsplan kann dies zum Beispiel der Zukauf von Produkten sein[55]. Beim Einsatz von Kompensationsmodellen sind diese Ausgleichsmaßnahmen bereits im Vorfeld bekannt und können in der Planung antizipiert werden. Dabei ergibt sich bei der simultanen Optimierung mehrerer Szenarien die Möglichkeit, einen unveränderlichen Grundplan und szenariospezifische Anpassungen zu ermitteln. Dabei sollen die Auswirkungen der Anpassungsmaßnahmen möglichst gering sein, da sie mit hohen Kosten verbunden sind. Gleichzeitig sollen unnötige Kosten im Grundplan vermieden werden. Somit wägen Kompensationsmodelle diese beiden Pläne gegeneinander ab [149, 55]. Im Allgemeinen besteht jedoch die Schwierigkeit bei der Anwendung der robusten Optimierung darin, zu entscheiden, welche Variablen szenarioabhängig sind, also für Anpassungsmaßnahmen verwendet werden und welche Variablen szenariounabhängig sind, also zum Grundplan gehören.

Der Fluss der Patienten in der Termin- und Aufnahmeplanung kann prinzipiell als Netzwerkfluss modelliert werden. Dies wird im folgenden Abschnitt dargestellt. Durch die Unsicherheit bezüglich der Nachfrage der Notfallpatienten werden Kompensationsmodelle der robusten Optimierung verwendet, um dieses Planungsproblem zu lösen.

6.4. Darstellung der Terminplanung elektiver Patienten als Netzwerkfluss-Problem

Grundlegend kann die vorgestellte formale Darstellung der Terminplanung als Zuordnungsproblem dargestellt und gelöst werden. Dieser Ansatz wird häufig verwendet [45, 32]. Jedoch handelt es sich dabei um ein NP-hartes Optimierungsproblem, welches zurzeit nur mit Heuristiken gelöst werden kann [166]. Um dieses Problem zu umgehen, wird eine neue Variante der Modellierung gezeigt. Dabei werden die Patienten zu Gruppen zusammengefasst. Dies bedeutet, dass sich der Fluss nicht mehr aus individuellen Patienten zusammensetzt, sondern aus Gruppen gleichartiger Patienten. Zusätzlich wird nicht die Zuordnung zu einzelnen Betten untersucht, sondern lediglich die Zuweisung zu Zimmern. Dies wird ermöglicht, da sich die einzelnen Betten in einem Zimmer nicht unterscheiden. Somit ist es aus planerischer Sicht unerheblich, welches Bett der Patient belegt. Innerhalb dieser Terminplanung ist es die Aufgabe des Belegungsmanagers, den Patientenfluss dieser Gruppen über einen längeren Zeitraum zu planen. Aus diesem Grund ist die Betrachtung als Netzwerkfluss naheliegend. Innerhalb des Netzwerkflusses können Teile der einzelnen Patientengruppen unterschiedliche Routen wählen, welches die Verteilung der Patienten auf die Zimmer und die Stationen darstellt. Ein Nachteil dieser Komplexitätsreduktion ist, dass eine direkte Zuordnung individueller Patienten innerhalb des Flusses nicht möglich ist. Daher ergibt sich die Notwendigkeit einer nachfolgenden Flussdekomposition.

Ein typisches Flussproblem in der Produktion und Logistik besteht aus Angebots-, Nachfrage- und Umladeknoten [158]. Den Patientenfluss betrachtend, sind klare Analogien erkennbar. Die Anzahl der Patienten, die an einem bestimmten Tag auf die Aufnahme warten, können als Angebot für das Umladeproblem gesehen werden. Um einen Fluss zu gewährleisten, zählen Patienten, die an einem bestimmten Tag entlassen werden, als Nachfrage. Da der Patientenfluss auch als Bewegung der Patienten durch verschiedene Orte im Krankenhaus definiert werden kann, werden in diesem Fall die Zimmer als Umladeknoten betrachtet.

Um den Netzwerkfluss zu vereinfachen, werden die Patienten zu verschiedenen Flussgruppen zusammengefasst. Alle Patienten mit dem gleichen Entlassungsdatum werden zu einer Gruppe aggregiert. Dies hat den Vorteil, dass jede Gruppe nur einen Nachfrageknoten benötigt. Wenn ein Patient einer Gruppe aufgrund fehlender Kapazitäten nicht aufgenommen werden kann, muss der Termin verschoben

6. Operative Terminplanung elektiver Patienten mit Antizipation von Notfallpatienten

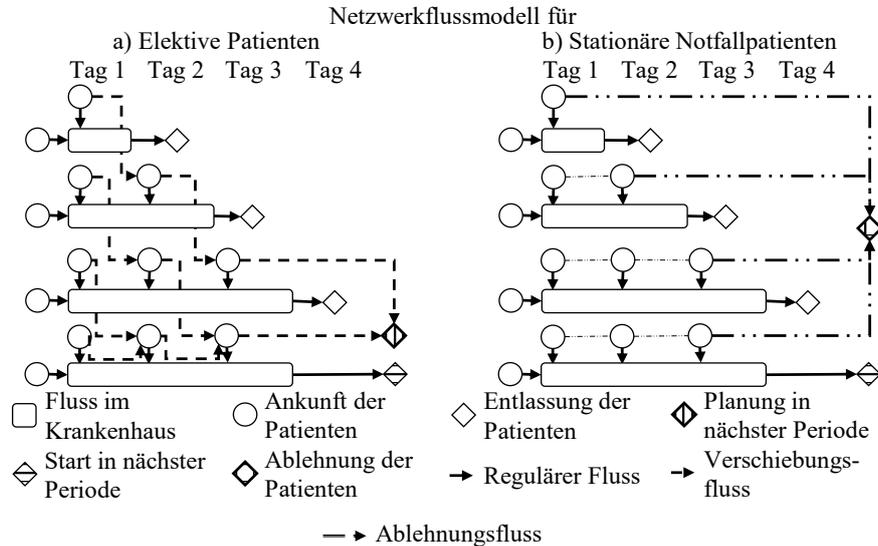


Abbildung 6.2.: Netzwerkflussmodell für elektive Patienten und stationäre Notfallpatienten (Quelle: Eigene Darstellung)

werden. Da diese Terminverschiebung mit einer Veränderung des Entlassungsdatums einhergeht, können sie über eine Verbindung der Angebotsknoten der aufeinanderfolgenden Patientengruppen modelliert werden. Da die Patienten bei gleichem Entlassungsdatum an unterschiedlichen Tagen aufgenommen werden können, werden für jede Gruppe, jeden Tag und jede Station Angebotsknoten erstellt. Da ein Krankenhaus zu Beginn einer Planungsperiode nicht leer ist, werden bereits belegte Patienten aus früheren Planungsperioden als Startangebot ohne die Möglichkeit einer Terminverschiebung modelliert. Die letzte Patientengruppe erfüllt eine besondere Aufgabe. Da die Entlassungsdaten der Patienten auch außerhalb des Planungszeitraumes liegen können, werden diese Patienten in der letzten Gruppe zusammengefasst. Jeder Fluss zur Nachfrage dieser Gruppe fungiert als Startangebot für den nächsten Planungszeitraum. In Abbildung 6.2 ist das Netzwerkflussproblem abstrakt für elektive und stationäre Notfallpatienten dargestellt. Hier wird auch der große Unterschied dieser Patiententypen sichtbar. Notfallpatienten müssen sofort aufgenommen werden, daher ist keine Terminverschiebung erlaubt und bei nicht auflösbaren Kapazitätsengpässen werden diese Patienten nicht aufgenommen.

6. Operative Terminplanung elektiver Patienten mit Antizipation von Notfallpatienten

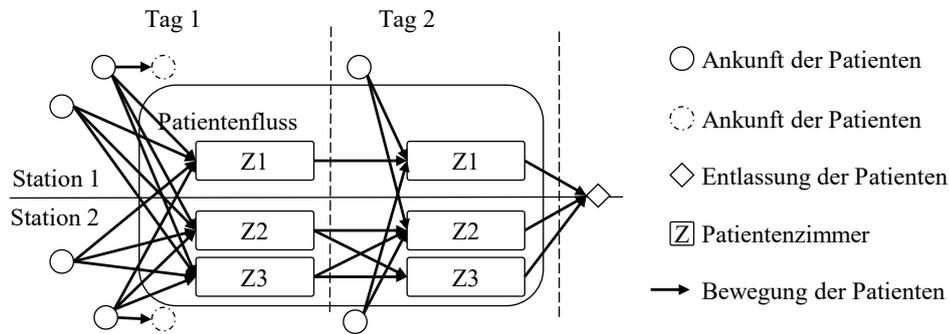


Abbildung 6.3.: Beispielhaftes Netzwerk für den Fluss im Krankenhaus (Quelle: Eigene Darstellung)

Der Fluss im Krankenhaus spiegelt die Bewegung der Patienten durch die Zimmer wider. In Abbildung 6.3 ist zu sehen, dass den Patienten nach der Aufnahme ein Zimmer zugewiesen wird. Dabei ist auch zu erkennen, dass die Patienten während eines Aufenthaltes das Zimmer wechseln können. Beim Übergang zweier Tage können die Patienten das Zimmer wechseln. Zu beachten ist, dass für jede Patientengruppe ein eigenes Zimmernetzwerk gebildet wird. Eine Besonderheit des vorgestellten Netzwerkes ist, dass die Zimmerknoten kapazitierte Umladeknoten widerspiegeln. Um diese Kapazitäten effizient in das Netzwerk zu integrieren, wird die Technik des Nodesplittings [158] angewendet. Dabei wird ein Knoten in einen Start- und Endknoten aufgeteilt, die mit genau einer Kante verbunden werden. Die obere Flussschranke entspricht in diesem Verfahren der ursprünglichen Kapazität.

In Abbildung 6.4 ist die Gesamtdarstellung des Netzwerkes zu sehen. Die einzelnen Elemente sind eindeutig durch eine Kombination verschiedener Indizes identifiziert. Dabei codiert k die Patientengruppe und g das Geschlecht. Der Index w beschreibt die Station. Die einzelnen Zimmer werden durch r identifiziert. Abschließend beschreibt t den betrachteten Tag innerhalb des Planungszeitraumes. Die aufzunehmenden Patienten sind durch das Angebot b_a und Startangebot b_{st} gekennzeichnet. Dadurch, dass die stationären Notfallpatienten im Vorfeld unbekannt sind, wird das Angebot in den jeweiligen Patientengruppen, Tagen und Geschlechtern durch eine Zufallsvariable modelliert. Im Gegensatz zu klassischen Umladeproblemen steht die Nachfrage b_n und b_r im Vorfeld nicht fest, da sich durch Terminverschiebungen und Ablehnungen die Flussgrößen in den einzelnen Patientengruppen ändern können. Generell gilt jedoch, dass die Summe alle

6. Operative Terminplanung elektiver Patienten mit Antizipation von Notfallpatienten

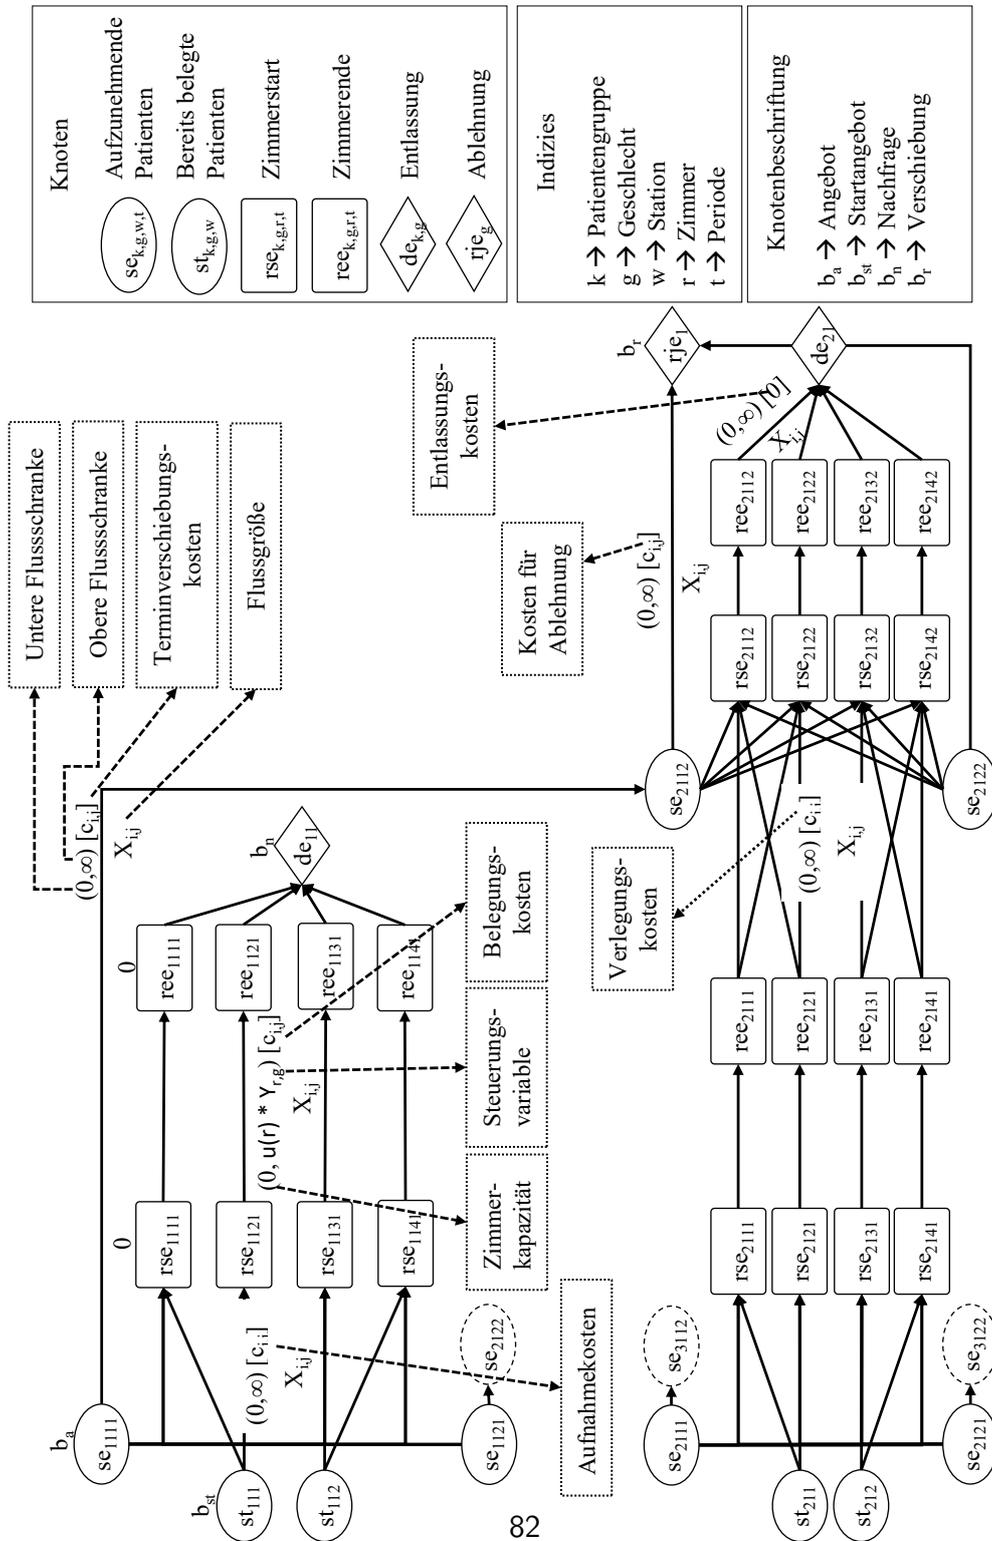


Abbildung 6.4.: Gesamtdarstellung des Netzwerkflusses (Quelle: Eigene Darstellung)

Angebote für ein Geschlecht gleich der Summe aller Nachfragen sein muss.

In Umladeproblemen hat jede Kante eine untere und obere Flussschranke. In der vorliegenden Problemstellung ist die untere Schranke immer 0 und die obere Schranke, mit Ausnahme der Kanten zwischen den Start- und Endknoten der Zimmer, bei unendlich. Die obere Schranke der Zimmerkanten ist gleich der Kapazität $u(r)$ eines Zimmers. In Verbindung mit einer binären Steuerungsvariable können somit die beiden harten Nebenbedingungen RC und RG sichergestellt werden. Über die Flussschranke können nicht mehr Patienten aufgenommen werden, als Kapazität vorhanden ist und die binäre Variable sorgt für die Geschlechtertrennung. Wenn in einem Zimmer Männer aufgenommen werden, wird die korrespondierende Binärvariable auf 1 gesetzt. Durch spezielle Nebenbedingungen wird anschließend sichergestellt, dass die zugehörige Steuerungsvariable für Frauen die obere Schranke auf diese Kante auf 0 setzt. Da für jedes Zimmer in jeder Periode eine Kante pro Patientengruppe existiert, muss zur Sicherstellung der Restriktion RC die Summe aller Flüsse auf diesen Kanten kleiner oder gleich der verfügbaren Kapazität sein. Somit werden die harten Restriktionen der operativen Aufnahmeplanung entweder direkt durch die Netzwerkstruktur oder durch das Hinzufügen von Steuerungsvariablen sichergestellt.

Der Vorteil der Modellierung als Netzwerkflussproblem liegt darin, dass die Steuerung des Flusses und somit die weichen Nebenbedingungen vollständig über die Flusskosten der Kanten abgebildet werden. Dabei wird der kostenminimale Fluss maximaler Größe gesucht. Um diesen Fluss zu berechnen, erfolgt im nächsten Abschnitt die formale Beschreibung des skizzierten Umladeproblems als lineares stochastisches Optimierungsmodell.

6.5. Lineares stochastisches Optimierungsmodell

Zur Durchführung einer Optimierung wird der grundlegende Modellansatz in ein mathematisches Optimierungsmodell überführt. Dazu werden zuerst die grundlegenden Definitionen eingeführt und der Graph konstruiert. Anschließend wird das mathematische Modell vorgestellt.

6.5.1. Überlegungen zur robusten Optimierung

Das Angebot der stationären Notfallpatienten ist durch eine Zufallsverteilung charakterisiert. In der Modellierung des Patientenflusses werden die Ankünfte und Eigenschaften der Patienten über empirische Verteilungen ermittelt. Im Endeffekt sucht das Patientenflussmanagement nach einem angepassten Plan, der die elektiven Patienten mit Aufnahmedaten versieht, die resistent gegenüber den Schwankungen der Nachfrage für stationäre Notfallpatienten sind. Somit bietet sich die Nutzung der Verfahren zur robusten Optimierung an. Ziel der robusten Optimierung ist es nicht, die optimale Entscheidung für einen möglichen Fall zu treffen, sondern eine Entscheidung zu treffen, die in allen möglichen Szenarien gut abschneidet. Zur Ermittlung eines robusten Terminplanes elektiver Patienten gegenüber den stationären Notfallpatienten wird die Nutzung eines Kompensationsmodelles vorgeschlagen. Dabei werden Verletzungen der harten Nebenbedingungen durch Kompensationsmaßnahmen ausgeglichen. Eine Schwierigkeit dabei ist es, die Kompensationsmöglichkeiten in szenarioabhängige und -unabhängige Kompensationen zu unterteilen. Hierbei sind die Entscheidungen für elektive Patienten szenariounabhängig, was bedeutet, dass alle Kompensationsmöglichkeiten in allen Szenarien durchführbar sein müssen. Im Gegensatz dazu erfolgen die Kompensationen für stationäre Notfallpatienten szenarioabhängig. Die Kompensationsmöglichkeiten sind bereits von der Netzwerkstruktur vorgegeben. Bei Kapazitätsengpässen können die Aufnahmetermine der elektiven Patienten verschoben werden oder der Fluss kann auf eine alternative Station, die von den interdisziplinären Stationsclustern vorgegeben wird, umgelenkt werden. Da für Notfallpatienten keine Terminverschiebungen möglich sind, wird als Kompensationsmöglichkeit zusätzlich zur Nutzung der Stationscluster die Möglichkeit der Ablehnung von Patienten verwendet. Generell sind die Kompensationsmöglichkeiten so abzuwägen, dass möglichst viele Notfallpatienten aufgenommen werden können, ohne eine exzessive Verwendung von Terminverschiebungen elektiver Patienten. Daraus ergibt sich eine Präferenz der Kompensationsmöglichkeiten, die in der Kostenfunktion des linearen Optimierungsmodells berücksichtigt werden muss. Die bevorzugte Art der Kompensation ist die Nutzung alternativer Stationen im Cluster, gefolgt von Terminverschiebungen elektiver Patienten. Die am wenigsten favorisierte Kompensation ist die Ablehnung der Notfallpatienten.

6.5.2. Definitionen

In der Tabelle 6.3 sind die verschiedenen Parameter des linearen Optimierungsmodells aufgeführt. Die Anzahl der zu betrachtenden Patientengruppen wird mit dem Parameter AC beschrieben und die Anzahl der Belegungstage wird mit AB bezeichnet. Aus der schematischen Darstellung geht hervor, dass $AB = AC - 1$ gelten muss. Weitere Parameter sind die Anzahl der Zimmer (AR) und die Anzahl der Stationen (AW). Für die robuste Optimierung ist weiterhin die Anzahl der zu betrachtenden Szenarien (AS) relevant.

Tabelle 6.3.: Parameter des Optimierungsmodells (Quelle: Eigene Darstellung)

Name	Beschreibung
AC	Anzahl der verschiedenen Patientengruppen
AR	Anzahl der Zimmer
AW	Anzahl der Stationen
AB	Anzahl der Belegungstage ($AB = AC - 1$)
AS	Anzahl der Szenarien

Mithilfe der vorgestellten Parameter lassen sich die für die Modellierung notwendigen Mengen definieren. Diese Mengen sind in Tabelle 6.4 dargestellt. Dabei ist zu beachten, dass alle Mengen ganzzahlig sind. Dabei wird zum Beispiel die Menge der betrachteten Geschlechter mit 1 (männlich) und 2 (weiblich) codiert.

Tabelle 6.4.: Mengen zur Konstruktion des Optimierungsmodells (Quelle: Eigene Darstellung)

Name	Konstruktion	Beschreibung
K	$K = \{1..AC\}$	Menge der Patientengruppen
G	$G = \{1, 2\}$	Menge der Geschlechter (1 \rightarrow männlich, 2 \rightarrow weiblich)
R	$R = \{1..AR\}$	Menge der Zimmer
W	$W = \{1..AW\}$	Menge der Stationen
T	$T = \{1..AB\}$	Menge der Belegungstage
SZ	$SZ = \{1..AS\}$	Menge der Szenarien

Im Rahmen dieser Arbeit wird das Netzwerk G durch folgende Definition dargestellt: $G = (V, E, c, \kappa)$. Dabei beschreibt V die Menge der Knoten, E die Menge der Kanten, c die Kostenzuordnung und κ die Zuordnung der oberen Schranken.

6. Operative Terminplanung elektiver Patienten mit Antizipation von Notfallpatienten

Auf Basis der vorgestellten Mengen in Tabelle 6.4 lassen sich die einzelnen Knoten detailliert definieren. Um die Übersichtlichkeit zu gewährleisten, werden für elektive Patienten (Tabelle 6.5) und stationäre Notfallpatienten (Tabelle 6.6) separate Knoten definiert, die zu Mengen zusammengefasst werden. Dabei werden die Mengen der Angebotsknoten, Nachfrageknoten, Ablehnungsknoten, Zimmerstartknoten und Zimmerendknoten unterschieden. Für jede Patientengruppe k , Geschlecht g , Station w und Tag t wird ein separater Angebotsknoten erzeugt. Der Vorteil der vorgestellten Modellierung ist es, dass für jede Patientengruppe und Geschlecht nur ein Nachfrageknoten notwendig ist. Weiterhin muss pro Geschlecht ein Ablehnungsknoten hinzugefügt werden. Für jedes Zimmer wird für jede Patientengruppe, jedes Geschlecht und jeden Tag jeweils ein Startknoten und ein Endknoten erzeugt. Die Erzeugung der Knotenmengen der stationären Notfallpatienten erfolgt analog. Es wird lediglich ein weiterer Index, der die Szenarionummer sz beschreibt, eingefügt. Somit besteht die gesamte Knotenmenge des zu untersuchenden Netzwerkes aus der Vereinigungsmenge aller Knotenmengen der Tabellen 6.5 und 6.6.

Tabelle 6.5.: Knotenmengen für elektive Patienten (Quelle: Eigene Darstellung)

Typ	Konstruktion
Angebot	$SE = \{se_{k,g,w,t} \mid k \in K, g \in G, w \in W, t \in T : t \leq k \wedge t \leq AB\}$
Startangebot	$ST = \{st_{k,g,w} \mid k \in K, g \in G, w \in W\}$
Nachfrage	$DE = \{d_{k,g} \mid k \in K, g \in G\}$
Ablehnung	$RJE = \{rj_g \mid g \in G\}$
Zimmerstart	$RSE = \{rs_{k,g,r,t} \mid k \in K, g \in G, r \in R, t \in T : t \leq k\}$
Zimmerende	$REE = \{re_{k,g,r,t} \mid k \in K, g \in G, r \in R, t \in T : t \leq k\}$

Tabelle 6.6.: Knotenmengen für stationäre Notfallpatienten (Quelle: Eigene Darstellung)

Typ	Konstruktion
Angebot	$SN = \{sn_{k,g,w,t}^{sz} \mid sz \in SZ, k \in K, g \in G, w \in W, t \in T : t \leq k\}$
Nachfrage	$DN = \{dn_{k,g}^{sz} \mid sz \in SZ, k \in K, g \in G\}$
Ablehnung	$RJN = \{rjn_g^{sz} \mid sz \in SZ, g \in G\}$
Zimmerstart	$RSN = \{rsn_{k,g,r,t}^{sz} \mid sz \in SZ, k \in K, g \in G, r \in R, t \in T : t \leq k\}$
Zimmerende	$REN = \{ren_{k,g,r,t}^{sz} \mid sz \in SZ, k \in K, g \in G, r \in R, t \in T : t \leq k\}$

Da es sich bei dem vorliegenden Netzwerk nicht um einen vollständig verbundenen Graphen handelt, wird die Menge der Kanten über die zugehörige Adjazenzmatrix definiert. Dabei werden für die Kanten der elektiven Patienten und für die Kanten der stationären Notfallpatienten in den einzelnen Szenarien eigene Adjazenzmatrizen gebildet. Aus diesem Grund besteht die Kantenmenge E aus der Vereinigungsmenge aller so definierten Kantenmengen. Die Kostenzuordnung c beschreibt eine Funktion, die jeder Kante in E einen positiven Zahlwert zuordnet: $c : E \mapsto \mathbb{R}_+$. Dabei beschreibt c_{ij} die Kosten pro Flusseinheit auf der Kante (i, j) . In diesem Kontext bedeutet das die Kosten pro Patientenbewegung auf dieser Kante. Weiterhin ordnet die Funktion κ jeder Kante eine obere Schranke zu: $\kappa : E \mapsto \mathbb{R}_+ \cup \{\infty\}$. Für das vorliegende Netzwerk haben alle Kanten bis auf die Kanten zwischen den Start- und Endknoten der Zimmer eine obere Schranke von ∞ . Die obere Schranke der Zimmerkanten wird durch die Kapazität der Zimmer vorgegeben, welche mit $u(r)$ bezeichnet wird. Auf die Definition einer unteren Schranke wird verzichtet, da im vorliegenden Fall jede Kante eine untere Schranke von 0 hat.

6.5.3. Mathematisches Modell

Aus den Vorüberlegungen zur Definition des Netzwerkes lässt sich ein mathematisches Modell definieren, welches den kostenminimalen Fluss durch das Netzwerk bestimmen kann. Die Flussgröße auf einer Kante $(i, j) \in E$ wird durch die ganzzahlige Variable $X_{i,j}$ beschrieben. Zur Synchronisation der Zimmerkapazitäten wird weiterhin eine binäre Hilfsvariable $Y_{r,t}^g$ benötigt. Mit ihrer Hilfe wird für jedes Zimmer, Geschlecht und Periode festgelegt, wie das jeweilige Zimmer belegt ist.

Im Folgenden werden die Modellierungen der einzelnen Nebenbedingungen gezeigt. Zur besseren Übersicht ist dieses Modell in einen elektiven Teil und einen Notfallteil der Flussgleichungen gespalten. Eine Verbindung der Teilmodelle erfolgt über die Synchronisation der Zimmerflusskanten, die die Kapazitätsbeschränkungen des Modells darstellen. Abschließend wird die Zielfunktion diskutiert. Im Teilmodell für die elektiven Patienten zeigt die Nebenbedingung 6.4 die Flussrestriktion der Angebotsknoten. Die Restriktion für das Startangebot (6.5) unterscheidet sich in dem Sinne, dass kein Fluss in den Knoten möglich ist. Die Restriktionen (6.6) und (6.7) sind klassische Flusserhaltungsrestriktionen, die sicherstellen, dass

6. Operative Terminplanung elektiver Patienten mit Antizipation von Notfallpatienten

der komplette eingehende Fluss den Knoten auch wieder verlässt. Bei den Nebenbedingungen der Nachfrageknoten (6.8) und der Ablehnungsknoten (6.9) ergibt sich eine Besonderheit. Die Nachfrage eines Nachfrageknotens beziehungsweise eines Ablehnungsknotens steht nicht im Vorfeld fest. Durch die Möglichkeit des Wechsels der Patientengruppe und der der Ablehnung von Patienten ändert sich die Nachfrage. Aufgrund der Modellstruktur können aber an diesen nicht mehr Patienten ankommen, als über die Angebotsknoten in das Netzwerk der Zimmer geleitet wurden. Somit ergibt sich eine vereinfachte Darstellung der Nebenbedingungen in (6.8) und (6.9), da die Nachfrage nicht explizit angegeben werden muss.

$$\sum_{m:(i,m) \in E} X_{i,m} - \sum_{o:(o,i) \in E} X_{o,i} = b(i) \quad \forall i \in SE \quad (6.4)$$

$$\sum_{m:(i,m) \in E} X_{i,m} - 0 = b(i) \quad i \in ST \quad (6.5)$$

$$\sum_{m:(i,m) \in E} X_{i,m} - \sum_{o:(o,i) \in E} X_{o,i} = 0 \quad \forall i \in RSE \quad (6.6)$$

$$\sum_{m:(i,m) \in E} X_{i,m} - \sum_{o:(o,i) \in E} X_{o,i} = 0 \quad \forall i \in REE \quad (6.7)$$

$$- \sum_{m:(i,m) \in E} X_{i,m} \geq -\infty \quad \forall i \in DE \quad (6.8)$$

$$- \sum_{m:(i,m) \in E} X_{i,m} \geq -\infty \quad \forall i \in RJE \quad (6.9)$$

Die Flussgleichungen für die stationären Notfallpatienten werden analog zu den bereits beschriebenen Gleichungen gesetzt. Sie unterscheiden sich in dem Sinne, dass sie sich auf andere Knotenmengen beziehen. Ein größerer Unterschied ist jedoch in der Flussgleichung der Angebotsknoten (6.10) zu finden. Da für stationäre Notfallpatienten keine Terminverschiebungen zugelassen sind, entfällt der Fluss in den Angebotsknoten. Die einzelnen Flussrestriktionen sind in den Formeln (6.11) bis (6.14) gegeben.

6. Operative Terminplanung elektiver Patienten mit Antizipation von Notfallpatienten

$$\sum_{m:(i,m) \in E} X_{i,m} = b(i) \quad \forall i \in SN \quad (6.10)$$

$$\sum_{m:(i,m) \in E} X_{i,m} - \sum_{o:(o,i) \in E} X_{o,i} = 0 \quad \forall i \in RSN \quad (6.11)$$

$$\sum_{m:(i,m) \in E} X_{i,m} - \sum_{o:(o,i) \in E} X_{o,i} = 0 \quad \forall i \in REN \quad (6.12)$$

$$- \sum_{m:(i,m) \in E} X_{i,m} \geq -\infty \quad \forall i \in DN \quad (6.13)$$

$$- \sum_{m:(i,m) \in E} X_{i,m} \geq -\infty \quad \forall i \in RJN \quad (6.14)$$

Im Weiteren folgt die Synchronisation der einzelnen Patientengruppen und der Geschlechter. Da alle Patienten die gleichen Zimmer nutzen und jede Gruppe ihre eigenen Zimmerkanten hat, muss die Gesamtsumme der Flüsse für ein Zimmer über alle Gruppen die Kapazität einhalten. Da eine strikte Geschlechtertrennung herrscht, wird die verfügbare Kapazität, also die obere Flussschranke, auf 0 gesetzt, sobald ein anderes Geschlecht in diesem Raum versorgt wird. Dies wird über binäre Variable $Y_{r,t}^g$ abgebildet. Zur Formulierung der Nebenbedingungen werden zwei Hilfsmengen definiert:

$$\begin{aligned} ZE_{g,r,t} &= \{(rse_{k,g,r,t}, ree_{k,g,r,t}) \mid rse_{k,g,r,t} \in RSE : k \in K, ree_{k,g,r,t} \in REE\} \\ &\quad \forall g \in G, r \in R, t \in T \\ ZN_{g,r,t}^{sz} &= \{(rse_{k,g,r,t}^{sz}, ree_{k,g,r,t}^{sz}) \mid rsn_{k,g,r,t}^{sz} \in RSN : k \in K, ren_{k,g,r,t}^{sz} \in REN\} \\ &\quad \forall g \in G, r \in R, t \in T \end{aligned} \quad (6.15)$$

Diese Mengen nehmen alle Kanten zwischen dem Start und dem Ende eines Zimmers für jedes Geschlecht, jedes Zimmer und jeden Tag im Belegungszeitraum auf. In der Restriktion (6.16) wird sichergestellt, dass die vorhandene Kapazität in einem Zimmer nicht überschritten wird. Zusätzlich wird sichergestellt, dass die

6. Operative Terminplanung elektiver Patienten mit Antizipation von Notfallpatienten

verfügbare Kapazität auf 0 gesetzt wird, sobald ein Patient des anderen Geschlechts in diesem Zimmer behandelt wird. (6.18) stellt sicher, dass nur ein Geschlecht gleichzeitig in einem Zimmer behandelt wird.

$$\sum_{\substack{(i,j) \\ \in ZE_{g,r,t}}} X_{i,j} + \sum_{\substack{(m,n) \\ \in ZN_{g,r,t}^{sz}}} X_{m,n} \leq u(r) \cdot Y_{r,t}^g \quad \forall sz \in SZ, g \in G, t \in T, r \in R \quad (6.16)$$

$$\sum_{\substack{(i,j) \\ \in ZE_{g,r,t}}} X_{i,j} + \sum_{\substack{(m,n) \\ \in ZN_{g,r,t}^{sz}}} X_{m,n} \leq u(r) \cdot Y_{r,t}^g \quad \forall sz \in SZ, g \in G : g = 2, t \in T, r \in R \quad (6.17)$$

$$\sum_{g \in G} Y_{r,t}^g \leq 1 \quad \forall r \in R, t \in T \quad (6.18)$$

Da der Fluss der Patienten komplett über die Flusskosten gesteuert wird, ist eine klassische Minimierung der Kosten möglich. Durch die Anwendung der szenario-basierten robusten Optimierung erfolgt in (6.19) eine Unterscheidung in eine Zielfunktion für elektive Patienten und eine für stationäre Notfallpatienten für jedes Szenario. Die jeweiligen Zielfunktionen für Notfallpatienten werden mit der jeweiligen Eintrittswahrscheinlichkeit des Szenarios multipliziert.

$$\begin{aligned} \min ZF &= ZF_{\text{elektiv}} + \sum_{sz \in SZ} \hat{g}_{sz} \cdot ZF_{\text{Notfall}}^{sz} \\ ZF_{\text{elektiv}} &= \sum_{(i,j) \in E^e} X_{i,j} \cdot c_{i,j} \\ ZF_{\text{Notfall}}^{sz} &= \sum_{(i,j) \in E_{sz}^n} X_{i,j} \cdot c_{i,j} \end{aligned} \quad (6.19)$$

6.5.4. Flussdekomposition

Der Fluss, der vom mathematischen Optimierungsmodell erzeugt wird, muss dekomponiert werden. Aus dem Fluss muss extrahiert werden, welche Patienten eine Terminverschiebung erhalten, welche Patienten auf einer alternativen Station aufgenommen werden und welche Patienten abgewiesen werden. Daher wird die Dekomposition in zwei Bereiche eingeteilt. In einem ersten Schritt werden die Patienten identifiziert, deren Aufnahmetermine verschoben werden müssen. Die Information über die Anzahl der Patienten wird aus dem Ergebnis des Optimierungsmodells extrahiert. Der Fluss auf den Kanten zwischen den einzelnen Angebotsknoten spiegelt die Anzahl der zu verschiebenden Patienten des jeweiligen Geschlechts, der jeweiligen Station und des jeweiligen Tages wider. Aus der Terminliste der Patienten werden passende Patienten ausgewählt und deren Aufnahme- und Entlassungsdaten um eins erhöht. Dabei werden bevorzugt die Patienten ausgewählt, die bereits eine Terminverschiebung hatten. Damit wird sichergestellt, dass eine möglichst geringe Zahl an Patienten neue Termine erhalten. Patienten, deren Aufnahmedatum nach Abschluss der Dekomposition außerhalb des Planungszeitraumes liegt, werden abgelehnt. In einem nächsten Schritt werden die Patienten identifiziert, die auf einer alternativen Station im Cluster aufgenommen werden. Dazu werden die Flüsse auf den Kanten von den Angebotsknoten zu den Zimmerstartknoten betrachtet. Es werden nur die Zimmer berücksichtigt, deren Station sich zu den Angebotsknoten unterscheidet. Da in der Modellierung der Aufenthalt auf einer alternativen Station durchgängig ist, bedeutet dies, eine Rückverlegung auf die eigentliche Station ist nicht möglich. Somit können Patienten, deren Aufnahmedatum mit dem Zeitindex des Angebotsknotens übereinstimmen, ausgewählt werden. Diese Auswahl erfolgt zufallsbasiert. Das gleiche Vorgehen wird für die stationären Notfallpatienten verwendet. Einziger Unterschied ist, dass hier keine Kanten zwischen den Angebotsknoten existieren, sondern jeder Fluss, der nicht ins Krankenhaus geleitet werden kann, wird direkt an Ablehnungsknoten gelenkt.

Um längere Planungszeiträume zu ermöglichen, werden das Optimierungsmodell und die Flussdekomposition in einen rollierenden Ansatz eingebettet. Dies hat den Vorteil, dass iterativ mehrere kleinere Optimierungsmodelle gelöst werden. Dies hat einen positiven Einfluss auf die Berechnungszeit. Weiterhin wird die Nutzung eines rollierenden Ansatzes durch die Modellierung der Netzwerkstruktur begünstigt. Patienten, die in der letzten Gruppe einer Iteration aufgenommen werden, ergeben,

6. Operative Terminplanung elektiver Patienten mit Antizipation von Notfallpatienten

basierend auf ihrer verbleibenden Verweildauer, das Startangebot der jeweiligen Patientengruppen der nächsten Iteration. Patienten, die in einer Iteration abgelehnt werden, bilden ein Zusatzangebot am ersten Tag der nächsten Iteration in ihren jeweiligen Patientengruppen. Schlussendlich werden alle Patienten, die in der letzten Iteration abgelehnt werden, endgültig in dieser Planungsperiode abgelehnt. Wenn alle Iterationen betrachtet wurden, kann ein endgültiger Terminplan für den gesamten Planungszeitraum ausgegeben werden.

6.6. Evaluation der Praxistauglichkeit

Um die Anwendbarkeit des Ansatzes zu zeigen, werden reale initiale Terminpläne erstellt. Für die Antizipation der Notfallpatienten werden die Verteilungen aus dem Simulationsmodell verwendet und verschiedene Szenarien generiert. Die Kosten für die Aufnahmen der Patienten werden über den Cluster festgelegt. Eine Aufnahme auf der gewünschten Station erzeugt im Modell keine Kosten. Unabhängig vom Ziel einer Aufnahme im Cluster, werden die gleichen Kosten veranschlagt. Die Kosten für die Belegung der einzelnen Zimmer werden so gewählt, dass große Zimmer bevorzugt verwendet werden. Ein Überblick über die einzelnen Kosten ist in Tab. 6.7 gegeben.

Tabelle 6.7.: Kosten für Patientenbelegungen im Optimierungsmodell(Quelle: Eigene Darstellung)

Art	Wert
Aufnahme auf gewünschter Station	0
Aufnahme auf alternativer Station	5
Terminverschiebung	10
Ablehnung	100
Ein-Bett-Zimmer	7
Zwei-Bett-Zimmer	3
Drei-Bett-Zimmer	2
Vier-Bett-Zimmer	1

Die zur Vorstellung verwendete Fallstudie basiert auf dem in Kapitel 4 vorgestellten Datensatz und bezieht sich auf einen Zeitraum von 40 Tagen. Dabei wird von dem Fall ausgegangen, dass der Belegungsmanager die Aufnahmedaten für den

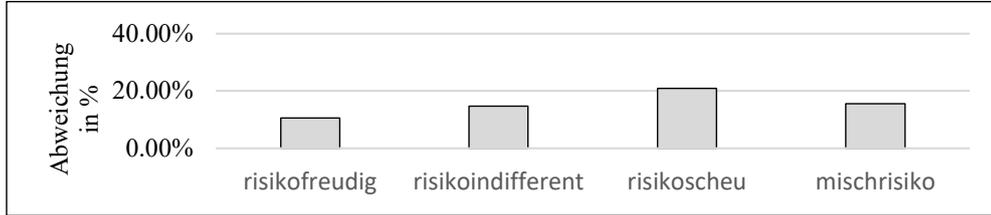
6. Operative Terminplanung elektiver Patienten mit Antizipation von Notfallpatienten

kommenden Monat überprüfen möchte. Um den Übergang zwischen zwei Monaten mit einzubeziehen, wurde der Zeitraum auf 40 anstatt 30 Tage festgelegt. Für die Optimierung werden 8 verschiedene Patientengruppen betrachtet. Daraus ergeben sich pro Berechnung 7 Belegungstage. In der vorliegenden Fallstudie wird ein Cluster, bestehend aus 7 Stationen mit insgesamt 47 Zimmern, betrachtet. Um eine robuste Optimierung zu ermöglichen, werden jeweils 10 verschiedene Szenarien integriert. Die Szenarien stellen im Prinzip die Schätzung der Notfallpatienten dar. Um die Variabilität der Entscheidungsträger zu untersuchen, werden vier verschiedene Schätzungen durchgeführt. In einer risikofreudigen Schätzung werden wenige Notfallpatienten antizipiert. Somit wird erwartet, dass hier mehr elektive Patienten eingeplant werden. In einer risikoindifferenter Schätzung wird mit einer durchschnittlichen Anzahl an Notfallpatienten gerechnet. Ein risikoscheuerer Entscheider antizipiert deutlich mehr Patienten. Als letzte Schätzung wird eine Mischschätzung verwendet. Dabei werden die ersten drei Schätzungen zu einer neuen Schätzung kombiniert. Die Schätzungen werden aus dem validierten Simulationsmodell aus Kapitel 5 gewonnen. Dazu werden aus den genutzten Verteilungen 200 Terminpläne für Notfallpatienten generiert und auf Basis der Patientenzahlen sortiert. Terminpläne im unteren Quartil werden den risikofreudigen Schätzungen zugeordnet. Pläne zwischen dem unteren und oberen Quartil werden den risikoindifferenter Schätzungen zugeordnet. Die verbleibenden Terminpläne gehören zur risikoscheueren Schätzung. Aus diesen drei Gruppen werden 10 Pläne zufällig ausgewählt. Für die Mischschätzungen werden aus jeder Gruppe 3 Pläne ausgewählt. Als zehntes Szenario wird ein zufälliger Plan ausgewählt. Zur Evaluation der Flexibilität werden zwei verschiedene Szenarien betrachtet. Im ersten Szenario (Flex1) wird nur die Möglichkeit der Terminverschiebung zugelassen und im zweiten Szenario (Flex 2) können zusätzlich alternative Stationen im Cluster verwendet werden.

In einer ersten Evaluation werden die grundlegenden Eigenschaften der robusten Optimierung überprüft. Dabei ist die Betrachtung der Ergebnisrobustheit nicht notwendig, da kein Anspruchsziel vorgegeben ist. Die Optimalitätsrobustheit, dargestellt in Abb. 6.5 zeigt, dass die Optimierung einzelner Szenarien immer einen besseren Zielfunktionswert liefert als die robuste Optimierung. Dabei werden Unterschiede im Bereich von 7 % bis 20 % beobachtet. Je mehr Notfallpatienten betrachtet wurden, umso größer ist die Abweichung. Dies ist ein Indiz dafür, dass es eine sehr hohe Variabilität der Notfallpatienten gibt. Um für alle Szenarien lösbar zu bleiben, müssen dadurch mehr elektive Patienten verschoben oder abgelehnt

6. Operative Terminplanung elektiver Patienten mit Antizipation von Notfallpatienten

a) Nur Terminverschiebungen möglich



a) Terminverschiebungen und Clusternutzung möglich

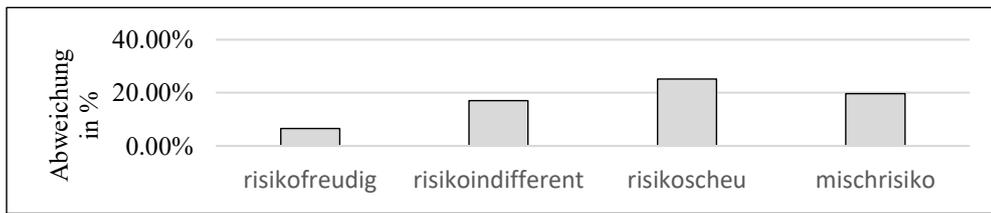


Abbildung 6.5.: Abweichungen der szenariooptimalen und gesamtoptimalen Lösungen (Quelle: Eigene Darstellung)

werden. Somit ist jede Lösung der robusten Optimierung zulässigkeitsrobust. Hierbei ist zu beachten, dass die Szenarien nicht jede mögliche Realität abbilden. Um einen Näherungswert für diese Eigenschaft zu ermitteln, werden die berechneten Terminpläne im Simulationsmodell aus Kapitel 5 evaluiert. Dabei ergibt sich ein Wert von ca. 90 %, dargestellt in Abb. 6.7 als Termintreue. Die bedeutet, dass der Plan für 90 % der elektiven Patienten zulässig ist und für die verbleibenden Patienten operative Maßnahmen ergriffen werden müssen. Im Folgenden werden die Optimierungsergebnisse aus Sicht des Krankenhauses ausgewertet.

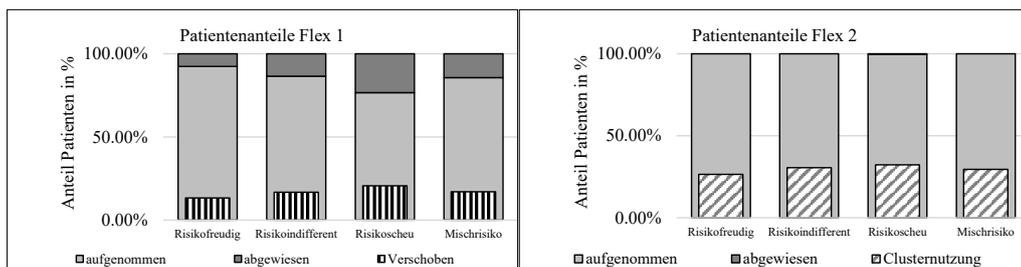


Abbildung 6.6.: Patientenanteile nach der Optimierung (Quelle: Eigene Darstellung)

6. Operative Terminplanung elektiver Patienten mit Antizipation von Notfallpatienten

In Szenario *Flex1* zeigt sich vor allem, dass sich, abhängig von der Risikobereitschaft des Entscheiders, die Optimierungsergebnisse unterscheiden. In einem risikofreudigen Szenario werden die Termine von 13,45% der elektiven Patienten verschoben und ca 7,56% der Patienten werden abgelehnt. Im risikoindifferenten Szenario werden 16,89% der Patienten verschoben und 13,45% abgelehnt. Ein risikoscheuer Entscheider würde 20,73% verschieben und 23,45% ablehnen. Somit steigt die Zahl der Verschiebungen und Ablehnungen mit der Zahl der Notfallpatienten. Im Mischrisiko werden 17% der Patienten verschoben und 14% abgewiesen. Die Ergebnisse zeigen, dass unabhängig von der Risikobereitschaft der Entscheider der initiale Terminplan nicht durchführbar ist. Wird die Möglichkeit der Clusternutzung aktiviert, Szenario *Flex2*, können unabhängig von der Risikobereitschaft alle Patienten aufgenommen werden. Hier variiert nur die Nutzung alternativer Stationen. Je risikofreudiger ein Entscheider ist, desto geringer ist die geplante Clusternutzung. Dabei werden 26 bis 32% der Patienten auf einer alternativen Station aufgenommen. Die Ergebnisse sind in Abb. 6.6 dargestellt.

Technisch gesehen liefert das Modell nutzbare Ergebnisse. Aufgrund der Variabilität der Notfallpatienten ist es nicht sichergestellt, dass die Optimierungsergebnisse zu 100 % in den Betrieb übernommen werden können. Um die Ergebnisse zu evaluieren, wird wieder das Simulationsmodell aus Kapitel 5 verwendet. Dabei werden die empirischen Ankunfts- und Stationsverteilungen durch die berechneten Terminpläne ersetzt. Zur genaueren Evaluierung des Optimierungsergebnisses wird die Möglichkeit zur Clusternutzung im Simulationsmodell ausgeschaltet. Somit können nur Clusterzuordnungen aus der Optimierung verwendet werden. Patienten, die im Simulationsmodell nicht aufgenommen werden können, werden direkt abgewiesen. Als grundlegende Ergebnisgröße wird die Termintreue verwendet. Dies ist gleichbedeutend mit der Zulässigkeitsrobustheit und stellt den Prozentsatz der eingehaltenen Termine aus dem Simulationsmodell dar. Weiterhin wird die absolute Anzahl aufgenommener elektiver Patienten ausgewertet. Abschließend wird das Servicelevel für Notfallpatienten evaluiert. Dies ist gleichbedeutend mit dem Prozentsatz der aufgenommenen stationären Notfallpatienten. Der Übersichtlichkeit halber erfolgt diese Auswertung über alle Entscheider und es werden die Mittelwerte evaluiert.

Wenn der ursprüngliche Terminplan simuliert wird, kann eine Termintreue von 84% erreicht werden und es werden insgesamt 300 Patienten aufgenommen. Dies bedeutet, dass 57 Patienten kurzfristig über eine Terminverschiebung informiert werden müssen. Wenn das vorgestellte Optimierungsmodell verwendet wird, steigt

6. Operative Terminplanung elektiver Patienten mit Antizipation von Notfallpatienten

die Termintreue auf ca. 93% in beiden Untersuchungen. Der Vorteil der Nutzung alternativer Stationen ergibt sich hier in der absoluten Anzahl an aufgenommenen Patienten. Ohne eine flexible Kapazitätsnutzung können 286 Patienten aufgenommen werden. Wenn alternative Kapazitäten genutzt werden, können mit gleichen Kapazitäten 333 Patienten aufgenommen werden. Somit beobachtet das Krankenhaus in dem Fall eine höhere planbare Auslastung und somit höhere planbare Einnahmen. Bei Betrachtung der stationären Notfallpatienten zeigt sich für den ursprünglichen Terminplan ein Servicelevel von 87%. Bei einem bearbeiteten Terminplan mit Terminverschiebungen erhöht sich dieser Wert auf 91%. Durch die Nutzung alternativer Stationen können alle stationären Notfallpatienten aufgenommen werden.

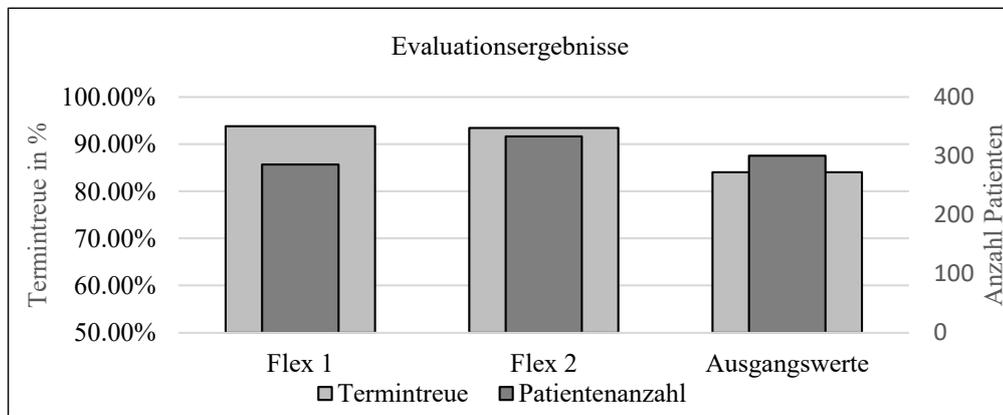


Abbildung 6.7.: Simulationsergebnisse der ermittelten Terminpläne (Quelle: Eigene Darstellung)

Zusammenfassend lässt sich erkennen, dass die Nutzung des Optimierungsmodells die Ausgangslage in jedem Fall verbessert. Bei der Benutzung alternativer Kapazitäten ergeben sich für die maßgeblichen Kennzahlen die höchsten Werte. Jedoch zeigt die Evaluation, dass nicht alle geplanten Patienten auch tatsächlich aufgenommen werden können. Dies ist ein Indiz dafür, dass unabhängig von der Lösungsqualität der Planungsmodelle ein gewisses Maß an operativer Flexibilität benötigt wird, um die verbleibenden Engpässe auf operativer Steuerungsebene zu beheben. Aus diesem Grund wird im folgenden Kapitel ein datengetriebenes Verfahren zur operativen Patientenflusssteuerung gezeigt.

7. Operative wissenschaftsbasierte Handlungsrichtlinien für die Steuerung des Patientenflusses bei Kapazitätsengpässen

Die Variabilität des Patientenflusses und vor allem die grundlegende Unsicherheit hinsichtlich der Notfallpatienten bewirken, dass Engpasssituationen nicht vollständig durch gute Planung verhindert werden können. Aus diesem Grund benötigen Entscheidungsträger im Krankenhaus zusätzlich zu Planungsansätzen effiziente operative Richtlinien, um Kapazitätsengpässe schnell zu behandeln. Diese werden in diesem Kapitel vorgestellt und mithilfe des Simulationsmodells evaluiert. Die Methoden, Verfahren und Ergebnisse dieses Kapitels basieren auf einer internationalen Forschungskollaboration des Lehrstuhls für Wirtschaftsinformatik und Operations Research mit PD Dr. M. Masmoudi.

7.1. Beschreibung der Problemstellungen der Patientenflusssteuerung und des benötigten Wissens zur Entscheidungsunterstützung

Um operative Engpasssituationen aufzulösen, werden im Allgemeinen Ad-hoc Entscheidungen von medizinischem Fachpersonal getroffen. Ein großes Problem in der Praxis von Krankenhäusern ist die Art dieser Entscheidungsfindung. In der Regel erfolgen sie unstrukturiert und undokumentiert. Dies bedeutet, dass sie im späteren Verlauf der Analyse eines Krankenhauses nicht mehr nachvollziehbar und tendenziell nicht reproduzierbar sind. Um einen strukturierten operativen

7. Handlungsrichtlinien zur Unterstützung von operativen Entscheidungen

Entscheidungsprozess zu ermöglichen, benötigen Entscheidungsträger ausgereifte und erprobte Handlungsrichtlinien. Durch die komplexe Struktur eines Krankenhauses ist es klar, dass Richtlinien, die sich auf einzelne Abteilungen oder Stationen fokussieren, unzureichend sind, um Engpasssituationen effizient aufzulösen. Analog zu den Ergebnissen der vorherigen Kapitel stellen krankenhausweite Lösungsansätze, die Interdependenzen nutzen, einen vielversprechenden Ansatz dar. Vor allem funktionelle Wechselwirkungen, also die Eignung verschiedener Stationen für die gleiche Behandlung, sind in der Lage, die Kapazitätsnachfrage auf den Stationen effizient zu verteilen und somit Engpasssituationen aufzulösen.

Wie bereits gezeigt, bietet die flexible Nutzung sonst ungenutzter Kapazitäten von anderen Stationen ein großes Potenzial in der Reaktion auf kapazitätsbasierte Engpässe. In der Literatur wird dies oft als Patient Boarding bezeichnet [137]. Das Konzept des Boardings genießt im Krankenhaus einen schlechten Ruf. Verschiedene Autoren, z. B. [155] zeigen, dass sich die Verweildauer der Patienten verlängert und die Qualität der Behandlung leiden kann. Dies ist darauf zurückzuführen, dass im Boarding versucht wird, einen Patienten so schnell wie möglich aufzunehmen, aber in der Regel nicht überprüft wird, ob die ausgewählte Station in der Lage ist, diesen speziellen Patienten zu behandeln. Im Gegensatz zu den in der Literatur vorgestellten Ansätzen versteht diese Arbeit diese flexiblen Verlegungen nicht als Aufnahmen auf einer beliebigen Station, sondern als operative Serviceverschiebung zu einer geeigneten Abteilung. Durch die Betrachtung interdependenter Krankenhausstrukturen ist es sehr wahrscheinlich, dass mehrere Stationen die gleiche Behandlung durchführen können. Aus diesem Grund muss eine ungeplante Verlegung während Engpässen nicht zwangsläufig mit einer Verschlechterung der Behandlungsqualität einhergehen, aber die Flexibilität kann genutzt werden, um Engpässe aufzulösen. Zusätzlich unterscheidet diese Arbeit zwei verschiedene Arten von ungeplanten Verlegungen: Umleitungen und Umlagerungen. Beide haben einen entscheidenden Unterschied. Umleitungen erfolgen vor der eigentlichen Aufnahme des Patienten, also stellen sie eine im gewissen Maße planbare Verlegung dar. Dabei wird in der finalen Aufnahmeprüfung ein Kapazitätsengpass auf der gewünschten Station erkannt. Daher wird der Patient planerisch auf eine Alternative umgeleitet und kann bei seinem Eintreffen im Krankenhaus direkt auf die neue Station geleitet werden. Bei den Umlagerungen handelt es sich um eine physische Verlegung eines bereits aufgenommenen Patienten, um Kapazitäten für andere Patienten freizugeben. Dies bedeutet, um einen neuen Patienten aufnehmen zu können, muss ein anderer Patient, dessen Behandlung schon begonnen hat, auf

eine andere Station verlegt werden.

Unabhängig von der Art der gewählten Verlegung stellt sich die Hauptfrage, wie eine alternative Station ausgewählt werden kann. Die Behandlung einer Diagnose ist ein komplexer Prozess. Selbst wenn ein Behandlungspfad die Grundlage darstellt, können sich Veränderungen des Behandlungsprozesses ergeben. Durch individuelle Eigenschaften verschiedener Patienten kann es auch bei gleicher Diagnose zu unterschiedlichen Behandlungsprozessen kommen. Daher kann die Nutzung vorher festgelegter Alternativen auf Basis von Ähnlichkeiten der Stationen zu negativen Effekten führen. Eine Station bietet im Allgemeinen viele verschiedene Behandlungen an. Da alle angebotenen Behandlungen in der Regel die Grundlage für die Bestimmung der Ähnlichkeiten ist, kann folgende Situation eintreten: Die Station mit der höchsten Ähnlichkeit zur eigentlich gewünschten Station bietet nicht die komplette benötigte Behandlung für einen speziellen Patienten an. Aber eine weniger ähnliche Station könnte alle Behandlungen anbieten, wird aber aufgrund der geringen Ähnlichkeit nicht ausgewählt. Um diese Situation zu verhindern, werden patientenzentrierte Entscheidungen benötigt. Aus diesem Grund wird in diesem Kapitel ein datengetriebener Ansatz zur Generierung behandlungsspezifischer Eignungswerte einer Station vorgeschlagen.

Das medizinische (Behandlungspfad) und organisatorische (Stationspfad) Wissen zur Auswahl geeigneter Stationen ist normalerweise in Fachexperten verborgen. Um sich in der Entscheidungsfindung nicht ausschließlich darauf zu verlassen, zeigt dieses Kapitel ein datengetriebenes Verfahren zur automatischen Wissensgenerierung. In einer umfangreichen Literaturanalyse [114] wird gezeigt, dass die Generierung medizinischen und organisatorischen Wissens ein viel beachtetes Forschungsgebiet ist. Die Autoren kommen zum Schluss, dass die Art des erlangten Wissens und dessen Komplexität direkt vom verwendeten Datensatz abhängt. Die Mehrzahl der in [114] untersuchten Arbeiten differenzieren nicht zwischen dem klinischen und organisatorischen Wissen. Somit bilden diese Ansätze nur die tatsächlich durchgeführten Prozesse ab, ohne neue Erkenntnisse zu generieren. Im Gegensatz zur aktuellen Forschung erfolgt in dieser Arbeit eine strikte Trennung zwischen krankenhausunabhängigem klinischen Wissen über die Behandlung einer Diagnose und dem krankenhausabhängigen organisatorischen Wissen, wo eine Behandlung durchgeführt werden kann. Somit bilden beide Wissensarten unabhängige Voraussetzungen für operative Entscheidungen. Zu beachten ist dabei, dass dieses Wissen nicht direkt für eine Entscheidung verwendet wird, sondern im operativen Betrieb für jeden Patienten individuell kombiniert wird, um das

benötigte operative Wissen zu generieren. Um die Datenerhebung zu vereinfachen, wird wiederum der in Kapitel 4 vorgestellte Datensatz verwendet. Das klinische Wissen wird auf Basis der faktisch durchgeführten Behandlungsabläufe generiert und das organisatorische Wissen wird auf Basis der Behandlungshäufigkeiten der Stationen erstellt.

7.2. Entwirrung der klinischen und organisatorischen Struktur zur Gewinnung operativen Wissens

Die aktuelle Forschung im Patientenflussmanagement fokussiert sich vorwiegend auf die Planung und Evaluation des Flusses auf Basis abstrakter Patientenflüsse. Laut [18] werden diese Flüsse oft mit Warteschlangenmodellen und Simulation untersucht. Dabei ist der Patientenfluss durch Organisationseinheiten und Übergangswahrscheinlichkeiten charakterisiert. Das Wissen über diese Flüsse wird dabei über stark aggregierte Datenanalysen generiert. Zur Planung und Analyse der Flüsse ist diese Aggregationsebene ausreichend. Für eine operative Entscheidungsunterstützung und zur Steuerung des Patientenflusses ist eine detailliertere Betrachtung der klinischen Pfade notwendig. In einer aktuellen Literaturanalyse [114] wird gezeigt, dass ein Großteil der Forschung zur automatisierten Gewinnung von Behandlungswissen auf Process Mining basiert, welches versucht, Sequenzen von Behandlungsschritten in den Daten zu identifizieren. Dabei existieren in der Literatur zwei generelle Varianten. In der ersten Variante wird ausschließlich klinisches Behandlungswissen generiert [135] und in der zweiten Variante werden die Behandlungen und die Bewegung der Patienten durch das Krankenhaus simultan extrahiert [85]. Unabhängig von der gewählten Variante besitzt das Process Mining einen entscheidenden Nachteil. Durch die Fokussierung auf Sequenzen und die inhärente Komplexität der Behandlungen entstehen spaghetti-artige Strukturen, die nicht für eine operative Entscheidungsunterstützung verwendet werden können [156].

Für operative Entscheidungsunterstützung ist eine klare Trennung der medizinischen und organisatorischen Perspektive des Patientenflusses nötig. Um die Berechnung geeigneter Alternativen weiter zu verfeinern, wird die medizinische

7. Handlungsrichtlinien zur Unterstützung von operativen Entscheidungen

(treatment set mining) und die organisatorische (department-treatment capability) Perspektive, wie in Abb. 7.1 gezeigt, verbunden, um das für die Steuerung des Patientenflusses nötige operative Wissen zu generieren.

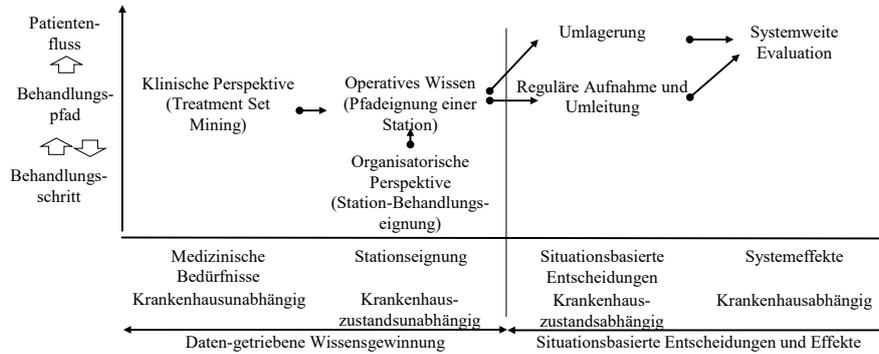


Abbildung 7.1.: Konzept der Wissensgenerierung und -nutzung (Quelle: Eigene Darstellung)

Erste Forschungen [78] beschäftigten sich bereits mit der Unterscheidung von klinischem und organisatorischem Wissen, um es für eine Entscheidungsunterstützung nutzbar zu machen. Sie separieren die Sequenz der Behandlung von der Durchführung auf der Station. Diese Unterscheidung erlaubt es, dass generierte Wissen direkt für die Optimierung zu nutzen. In [78, 151] wird es verwendet, um eine hierarchische Optimierung auf operativer Planungsebene durchzuführen. Dabei wird das organisatorische Wissen genutzt, um Patienten Betten zuzuweisen. Anschließend wird das generierte Behandlungswissen verwendet, um die einzelnen Behandlungsschritte zu terminieren. Dabei wird grundlegend berücksichtigt, dass nur einzelne Stationen in der Lage sind, diese durchzuführen. Im Gegensatz zum in [78, 151] vorgestellten Ansatz nutzt das in diesem Kapitel vorgeschlagene Verfahren das generierte Wissen nicht sequenziell, sondern die Kombination dieser beiden Wissensarten generiert neues vorher unbekanntes Wissen für die operative Steuerung des Patientenflusses. Klassische Process Mining Ansätze können nur bereits vorhandenes Wissen aufdecken. Dies bedeutet, dass die Zuordnung von Behandlungssequenzen zu Stationen bereits in den Daten vorhanden sein muss. Somit können selbst bei der Durchführung von Behandlungssequenzen durch verschiedene Stationen keine neuen Alternativen aufgedeckt werden. Eine unabhängige Betrachtung der Behandlungsschritte und der Eignungen der Stationen erlaubt es, vorher unbekannte Alternativen zu identifizieren und während operativer Engpasssituationen zu nutzen.

7. Handlungsrichtlinien zur Unterstützung von operativen Entscheidungen

Ein weiterer entscheidender Unterschied ist die Abkehr von der Betrachtung von Behandlungssequenzen in der Generierung des klinischen Wissens. Die Reihenfolge einzelner Behandlungsschritte nur partiell definiert [114]. Dies bedeutet, dass ein Teil der Behandlungsschritte einer strengen Sequenz folgt, während die übrigen unabhängig eingeplant werden. Daher hängt die Bewegung eines Patienten durch die Stationen nicht von der Reihenfolge der Behandlungen ab und die generelle Zusammensetzung der klinischen Perspektive eines Patientenpfades ist ausreichend für diese Art der Entscheidung. Zusätzlich werden in dieser Arbeit die einzelnen Behandlungsschritte tageweise gruppiert. Damit werden detaillierte Reihenfolgebeziehungen außer acht gelassen, aber strikte tagesbasierte Abhängigkeiten implizit betrachtet. Innerhalb eines Tages kann, wenn notwendig, eine detailliertere Terminplanung und Sequenzierung erfolgen. Diese gewollte Reduktion der Komplexität erlaubt die Nutzung einfacherer Data-Mining-Techniken und führt zu besser zu verstehenden Ergebnissen.

Um das organisatorische Wissen zu generieren, wird die Entscheidung, welche Station für einen Behandlungspfad geeignet ist, von historischen, organisatorisch begründeten Entscheidungen getrennt. Daher wird die Eignung nicht auf Basis kompletter Behandlungspfade berechnet. Hier wird unter der Annahme, dass eine Station für einen Behandlungspfad geeignet ist, wenn sie die enthaltenen Behandlungsschritte durchführen kann, die Eignung auf Basis granularer Behandlungsschritte berechnet. Dies bedeutet, selbst wenn eine Station nicht für den gesamten Pfad geeignet ist, kann sie für einen Teil der Behandlungsschritte eine geeignete Alternative darstellen. So wird für jede Kombination aus Behandlungsschritt und Station ein Kompetenzwert berechnet.

Die tageweise Betrachtung der Patientenpfade und die detaillierte Berechnung der Eignung von Behandlungsschritten führt zu einer präziseren Bestimmung der Eignung von Stationen, welche das benötigte operative Wissen zur schnellen Reaktion auf Stresssituationen darstellt.

7.3. Flexible, auf situationsabhängigen Richtlinien basierende Entscheidungsfindung

Wie bereits diskutiert, hat ein Krankenhaus mehrere Möglichkeiten zur Reaktion auf kapazitätsbasierte Engpässe. Wie in den vorherigen Kapiteln gezeigt, kann eine flexible Kapazitätsnutzung die Reaktionsfähigkeit signifikant erhöhen. Jedoch konzentrieren sich die in der Literatur vorgestellten Ansätze [17, 43, 88, 36] eher auf die Formulierung und Evaluation allgemeiner Strategien zur flexiblen Kapazitätsnutzung. Eine direkte Entscheidungsunterstützung wird dabei nicht geboten. Lediglich [121] und [35] haben ein Entscheidungsproblem zur operativen Belegung von Patienten entwickelt, bei der die medizinischen Bedürfnisse als Teil der Entscheidung berücksichtigt werden. Jedoch werden hier nur allgemeine medizinische Bedürfnisse, die von der Diagnose vorgegeben werden, berücksichtigt. Eine echte patientenzentrierte Entscheidung, basierend auf den individuellen Bedürfnissen, erfolgt nicht.

Im operativen Betrieb kann das in diesem Kapitel generierte Wissen genutzt werden, um für jeden Patienten individuell eine Liste geeigneter Stationen zu generieren. Sie kann als Grundlage für die eigentliche operative Entscheidung zur Belegung und Verteilung der Patienten genutzt werden. Jedoch ist die Entscheidung, welche geeignete Station aktuell verfügbar ist, von der aktuellen Situation des Krankenhauses abhängig. Um die Entscheidung effizient zu unterstützen, werden verschiedene Richtlinien zur Verfügung gestellt (Tab. 7.1). Die Standardrichtlinie ist die direkte Aufnahme auf der gewünschten Station. Während Stresssituationen sind drei weitere Richtlinien möglich. Als einfachste Richtlinie ist die Umleitung eines Patienten möglich, wenn die gewünschte Station einen Kapazitätsengpass hat und eine qualitativ hochwertige Alternative mit verfügbarer Kapazität existiert. Wenn diese Variante nicht möglich ist, kann ein bereits aufgenommener Patient auf eine Alternativstation umgelagert werden, um Platz auf der gewünschten Station zu schaffen. Die komplexeste Richtlinie ist eine Kombination aus Verlegungen bereits aufgenommener Patienten und einer Umleitung. Dabei befinden sich sowohl die gewünschte als auch die alternative Station in einer Stresssituation. Diese Richtlinien werden im weiteren Verlauf dieses Kapitels zu komplexen operativen Strategien kombiniert.

7. Handlungsrichtlinien zur Unterstützung von operativen Entscheidungen

Tabelle 7.1.: Darstellung der Handlungsrichtlinien (Quelle: Eigene Darstellung)

Nr	Name	Beschreibung
1	Direkte Aufnahme	Standardrichtlinie
2	Umleitung	Engpass auf gewünschter Station mit verfügbarer Alternative
3	Direkte Aufnahme mit Umlagerung	Engpass auf gewünschter Station mit verfügbarer Alternative für andere Patienten
4	Umleitung und Umlagerung	Mehrere Engpässe mit verfügbarer Alternative

Jede Entscheidung im operativen Betrieb eines Krankenhauses ist abhängig von der jeweiligen Situation, die durch die aktuelle Ressourcennutzung, den aktuell zu belegenden Patienten und die Ausstattung des Krankenhauses abhängig ist. Um schnell auf die jeweiligen Situationen reagieren zu können, werden die vier bereits vorgestellten Richtlinien (Tab. 7.1) zu operativen Entscheidungsregeln kombiniert. In Abb. 7.2 sind die Richtlinien und deren Implikationen visualisiert.

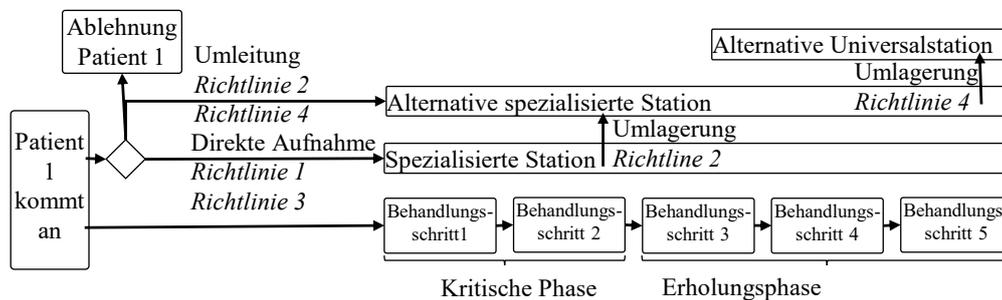


Abbildung 7.2.: Visualisierung der Handlungsrichtlinien (Quelle: Eigene Darstellung)

Während der Benutzung von Umleitungen und Umlagerungen muss der Entscheidungsträger Abwägungsentscheidungen treffen. Dabei müssen mögliche Qualitätsgewinne und -verluste der einzelnen Patienten gegeneinander abgewogen werden. Da die Reaktion auf Stresssituationen zeitsensitiv ist, muss der Entscheidungsträger mit Entscheidungsstrategien ausgestattet werden, die ihm eine angemessene Reaktion ermöglichen. Innerhalb dieser Arbeit werden zwei verschiedene, auf den bereits vorgestellten Richtlinien basierende, Strategien vorgeschlagen. Die erste

7. Handlungsrichtlinien zur Unterstützung von operativen Entscheidungen

Strategie (VF) vereint alle Handlungsalternativen. Um eine hohe Behandlungsqualität zu gewährleisten, wird die Grenze für eine akzeptable Qualität (MQN) auf den höchstmöglichen Wert gesetzt. Anschließend wird Richtlinie 1 überprüft. Falls hier eine Belegung nicht möglich ist, werden nacheinander die verbliebenen Richtlinien überprüft. Sollten alle beteiligten Stationen die aktuelle Qualitätsgrenze einhalten, ist eine Aufnahme, basierend auf den Richtlinien, möglich. Sollte dies nicht möglich sein, wird die Qualitätsgrenze um eins verringert, solange eine vorher definierte Minimalqualität nicht erreicht ist. Ist eine Belegung mit der minimal geforderten Qualität nicht durchführbar, wird der Patient abgewiesen. Um später den Einfluss der Umlagerungen bereits aufgenommenen Patienten zu untersuchen, wird eine zweite Strategie (NU) vorgeschlagen, die nur die Richtlinien 1 und 2 berücksichtigt.

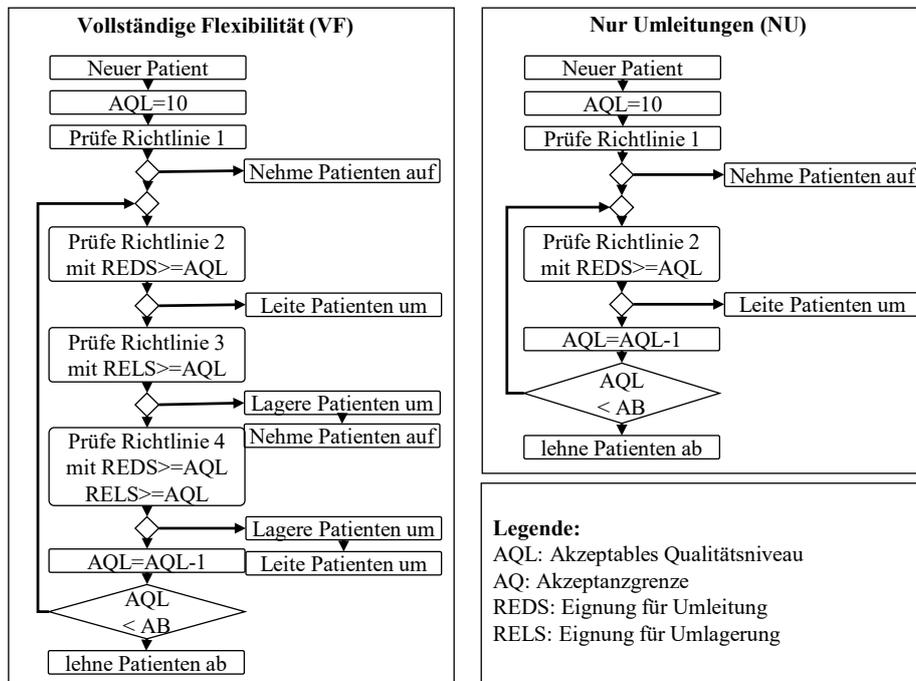


Abbildung 7.3.: Operative Strategien zur Patientenbelegung (Quelle: Eigene Darstellung)

7.4. Datengetriebene Wissensgewinnung

Um die Wissensgenerierung weiter zu verfeinern, werden die Generierung des klinischen Wissens, die Berechnung der Eignung und die Erstellung der Liste der geeigneten Stationen einzeln beschrieben. Abschließend wird das gesamte Verfahren statistisch evaluiert.

7.4.1. Data-Mining Verfahren zur Generierung der Behandlungspfade

Wie bereits diskutiert, ist die Reihenfolge der Behandlungsschritte weniger wichtig, als ihr Auftauchen in einem Pfad. Daher konzentriert sich die Wissensgenerierung auf eine Menge von Behandlungsschritten, die, um strenge Reihenfolgebeziehungen zu berücksichtigen, tageweise zu Mengen (DS) zusammengefasst werden. Dies führt zur folgenden detaillierten Definition eines Behandlungspfades (TS) als eine Menge von DS :

$$TS = \{DS_i | i \in 1..Länge\ von\ TS\} \quad (7.1)$$

$$DS_i = \{t_j | t_j\ \text{durchgeführt an Tag } i\} \quad (7.2)$$

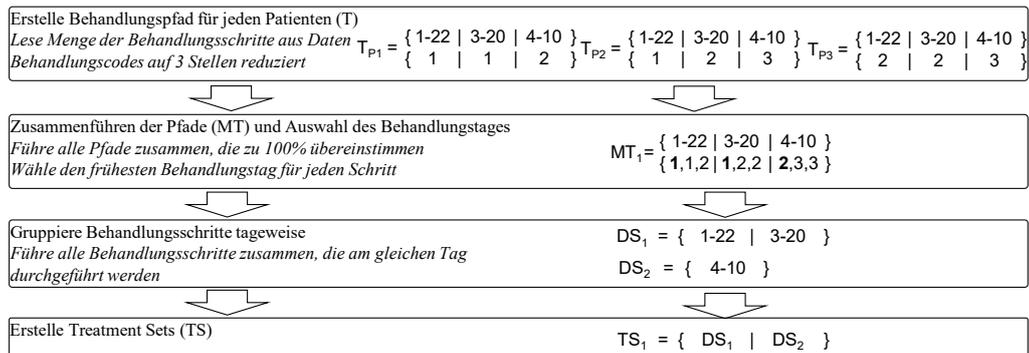


Abbildung 7.4.: Data-Mining Algorithmus und Beispiel (Quelle: Eigene Darstellung)

Im Weiteren wird ein Verfahren vorgestellt, welches aus Standarddaten (siehe Kapitel 4) einzigartige TS für jede Diagnose generiert. In einem ersten Schritt wird für jeden Patienten die individuelle Behandlungszusammensetzung (T) extrahiert und die Codes der einzelnen Behandlungsschritte auf drei Stellen reduziert. Anschließend werden alle T , die in ihrer Zusammensetzung gleich sind, zusammengefasst und die jeweiligen Behandlungstage der einzelnen Schritte gespeichert. Danach wird für jeden Behandlungsschritt der minimale Behandlungstag ausgewählt und alle Behandlungen mit dem gleichen Behandlungstag zu DS zusammengefasst, aus denen die TS gebildet werden. Der gesamte Algorithmus und ein Beispiel ist in Abb. 7.4 gegeben.

7.4.2. Datengetriebene Kompetenzberechnung für einzelne Behandlungsschritte

Die Hauptidee ist, wenn eine Station einen Behandlungsschritt oft durchführt, ist sie auch für diese Behandlung geeignet. Diese Annahme ist grundlegend von der sogenannten Volume-Outcome-Relationship der Gesundheitsökonomie gestützt [80, 109, 159]. Basierend auf der Berechnung der Behandlungsfrequenzen (Formel 7.3) und einer statistischen Analyse wurden fünf generelle Frequenzprofile von Behandlungen auf Stationen ermittelt (Abb. 7.5).

$$Dep : \text{Menge der Stationen} \quad (7.3)$$

$$t : \text{Menge der Behandlungsschritte} \quad (7.4)$$

$$f_{i,j} : \text{Häufigkeit von } i \in t \text{ in } j \in Dep \quad (7.5)$$

$$tn_{i,j} : \text{Anzahl von } i \in t \text{ in } j \in Dep \quad (7.6)$$

$$f_{i,j} = \frac{tn_{i,j}}{\sum_{k \in t} \sum_{m \in Dep} tn_{k,m}} \quad \forall i \in t \quad \forall j \in Dep \quad (7.7)$$

Basierend auf der berechneten Frequenz können die Stationen geordnet und absteigend Kompetenzwertungen vergeben werden. Bei einer Bewertung, die alleinig auf der Reihenfolge basiert, kommt es jedoch zu einem signifikanten Informationsverlust. Zum Beispiel in Profil 2 würden die Ähnlichkeiten der Frequenzen der Stationen nicht berücksichtigt. Der große Unterschied zwischen Station 1

7. Handlungsrichtlinien zur Unterstützung von operativen Entscheidungen

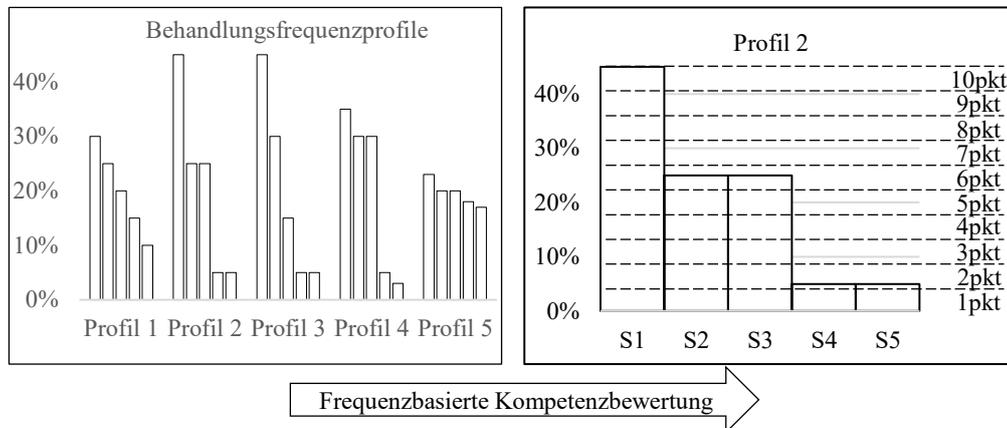


Abbildung 7.5.: Frequenzprofile von Behandlungen und darauf aufbauende Kompetenzbewertung
(Quelle: Eigene Darstellung)

und 2 sowie die Ähnlichkeiten zwischen den Stationen 2 und 3 würden nicht betrachtet werden. Um diesen Informationsverlusten entgegenzuwirken, werden die Bewertungen anhand eines normalisierten Verfahrens vergeben. Grundsätzlich werden alle Stationen mit einer Frequenz größer als 0 % als generell geeignet angesehen. Um Bewertungspunkte von 10 bis 1 zu verteilen, wird der Bereich zwischen der maximalen Frequenz und 0 % in zehn gleich große Abschnitte unterteilt. Aufgrund der Zugehörigkeit einer Station zu einem Bereich wird ein Punktwert vergeben. In Abb. 7.5 wird dieses Verfahren für das zweite Profil vorgestellt. Der Frequenzbereich zwischen 45 % und 0 % wird in zehn Bereiche eingeteilt. Station 1 erhält 10 Punkte. Die Stationen 2 und 3 befinden sich im gleichen Bereich und erhalten 6 Punkte. Abschließend werden für die letzten beiden Stationen 2 Punkte vergeben. Hier wird deutlich, dass die Informationen zu den Ähnlichkeiten und Unterschieden der Stationen erhalten bleiben. Diese Berechnung wird für alle Kombinationen von Behandlungen und Stationen wiederholt und es wird somit eine Eignungsmatrix erstellt.

7.4.3. Erstellung von Listen geeigneter Stationen

Basierend auf den *TS* und der Eignungsmatrix kann für jeden individuellen Fall eine Liste geeigneter Stationen erstellt werden. Dabei wird jedem Fall ein *TS* zugeordnet und für jedes enthaltene *DS* die durchschnittliche Eignung berechnet. Dieser basiert auf den Eignungen für die einzelnen Behandlungen. Abschließend wird der Durchschnitt über alle *DS* gebildet. Das Ergebnis dieses Verfahren ist beispielhaft in Abb. 7.6 dargestellt.

Diagnose: H40 | Behandlungen: 1-22, 3-20, 4-10

Station	DS ₁			DS ₂		Gesamtqualität
	Behandlung		Qualität	Behandlung	Qualität	
	1-22	3-20				4-10
S1	10	9	9,5	8	8	9
S2	5	9	7	10	10	8
S3	3	10	6,5	4	4	5,6
S4	2	3	2,5	3	3	2,6



Mögliche
Entscheidung Tag 1



Mögliche
Entscheidung Tag 2



Gesamt-
Entscheidung

Abbildung 7.6.: Beispiel einer Liste geeigneter Stationen Quelle: Eigene Darstellung

Diese Abbildung zeigt ein Beispiel für zwei *DS* und vier Stationen. Hier hat der medizinische Entscheidungsträger verschiedene Optionen, um einen Behandlungspfad zu planen. Die offensichtlichste Variante ist die Nutzung von Station 1 für den gesamten Patientenaufenthalt. Wenn Station 1 aufgrund der aktuellen Situation nicht verfügbar ist, kann die Behandlung auch auf Station 2 durchgeführt werden. Eine weitere komplexere Option wäre die Durchführung von *DS*₁ auf Station 1 und *DS*₂ auf Station 2. Dabei würde eine höchstmögliche Behandlungsqualität erreicht. Jedoch muss der Patient während seines Aufenthaltes verlegt werden. Diese exemplarische Liste kann direkt als Grundlage für operative Entscheidungen dienen.

7.4.4. Evaluation

Um Einsichten zu generieren, ob das vorgestellte Verfahren zur Wissensgenerierung geeignet ist, um die Aufnahme-strategien zu unterstützen, wird eine statistische Analyse, basierend auf dem Beispieldatensatz, durchgeführt. Bei Verwendung des Verfahrens werden 17.273 einzigartige *TS* generiert, welche die Behandlung von 1.054 unterschiedlichen Diagnosen abbilden. Die Anzahl von *TS* pro Diagnose variiert dabei in der Spanne von 1 bis 40. Der Boxplot in Abb. 7.7 a zeigt eine detaillierte Analyse der Anzahlen. Hier wird deutlich, dass die meisten Diagnosen eine überschaubare Anzahl an *TS* haben. Der Median liegt bei 7, das 0,25 Quantil bei 4 und das 0,75 Quantil bei 18.

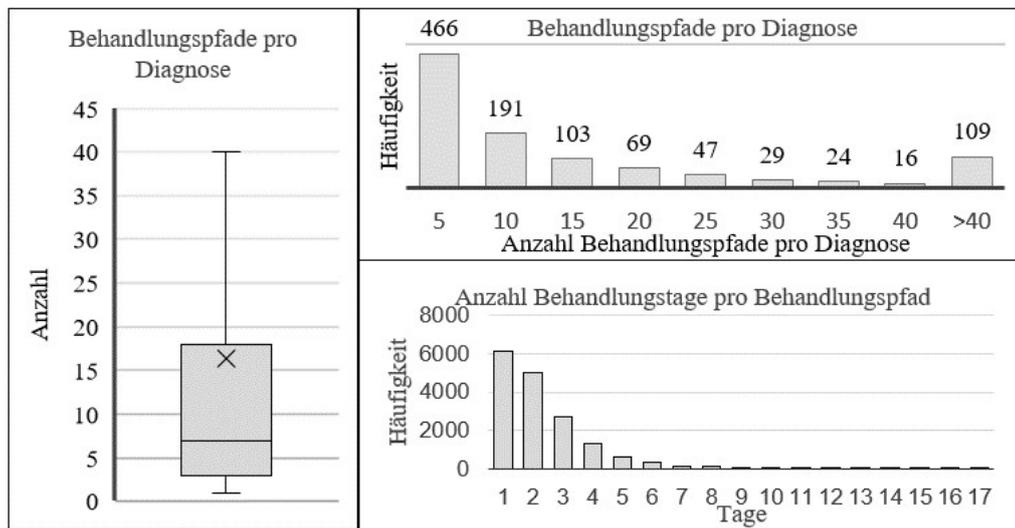


Abbildung 7.7.: Statistische Auswertung der Behandlungspfade (Quelle: Eigene Darstellung)

In Abb. 7.7 c ist die Länge der *TS*, basierend auf den enthaltenen *DS*, dargestellt. Hier wird gezeigt, dass die Mehrheit der *TS* (80 %) maximal zwei *DS* enthalten und längere *DS* eher ungewöhnlich sind. Somit ergeben sich selbst bei dauerhafter Anwendung der vorgeschlagenen Strategien eine akzeptable Anzahl an Verlegungen der Patienten. In Abb. 7.7 c zeigt sich, dass die Mehrheit der Diagnosen über eine angemessene und handhabbare Menge an *TS* verfügen

In der Eignungsmatrix werden 221 granulare Behandlungsschritte und 26 Stationen betrachtet. Dies ergibt 5.746 verschiedene Bewertungen. Bei Betrachtung aller

7. Handlungsrichtlinien zur Unterstützung von operativen Entscheidungen

Behandlungen ist der Median der geeigneten Stationen 3. Dies bedeutet, dass im Median für jede Behandlung 3 Stationen zur Verfügung stehen. Weiterhin existieren keine Behandlungen, die von allen Stationen gleichermaßen angeboten werden. Aber für 75 % aller Behandlungen existieren mindestens zwei geeignete Alternativen, was die Möglichkeit der erfolgreichen Nutzung von Alternativstationen erhöht.

Um den Einfluss von Verlegungen während des Aufenthaltes besser abschätzen zu können, wurde für die folgende Analyse der Behandlungspfad zeitlich in zwei Hälften unterteilt. Wenn ein Behandlungspfad zum Beispiel zehn Tage umfasst, sind die ersten fünf Tage in der ersten Hälfte erfasst und die restlichen Behandlungstage in der zweiten Hälfte. In Abb. 7.8 ist eine Analyse für die am weitesten verbreiteten Diagnosen in Deutschland gegeben. Wenn die Diagnose *I50* und alle *DS* betrachtet werden, können im Minimum eine, im Maximum neun und im Median vier Alternativstationen berechnet werden. Bei Betrachtung der unterschiedlichen Abschnitte des Pfades ändern sich die Werte. In der zweiten Hälfte der Behandlung, die typischerweise als die weniger kritische Phase betrachtet wird, erhöht sich die Anzahl der Alternativen. Ein ähnlicher Effekt lässt sich bei den Diagnosen *K40* und *M54* beobachten.

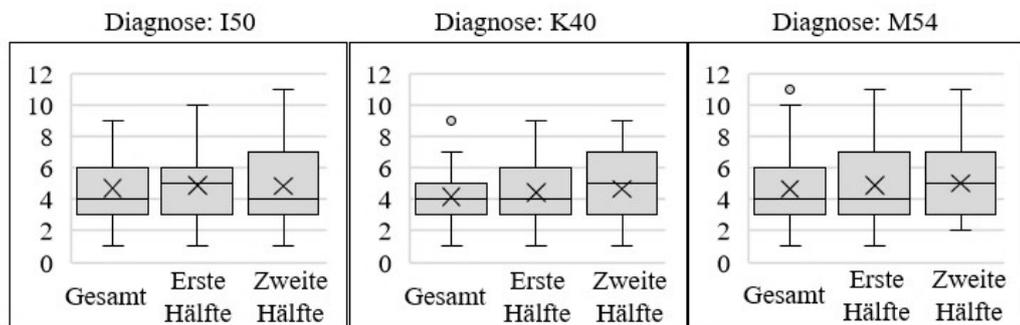


Abbildung 7.8.: Anzahl alternativer Stationen in verschiedenen Stadien der Behandlung (Quelle: Eigene Darstellung)

Diese Analyse hat gezeigt, dass das generierte Wissen als Input für Belegungsstrategien dienen kann. Mithilfe des Verfahrens können für jede Diagnose eine bis mehrere Alternativstationen bestimmt werden. Eine detaillierte Analyse einzelner Diagnosen zeigt, dass sich die Anzahl der Alternativen mit Voranschreiten der Behandlung erhöhen. Dies unterstreicht die Annahme, dass eine Ad-hoc Verlegung bereits belegter Patienten die Effizienz eines Krankenhauses verbessern kann.

7.5. Fallstudie

Um die diskutierten Strategien auf Basis möglicher Alternativstationen zu evaluieren, wird das bereits vorgestellte, verifizierte und evaluierte Simulationsmodell verwendet. An dem Modell wurden kleine Änderungen vorgenommen, ohne die Modellstruktur grundlegend zu bearbeiten. Die Ankunftsverteilungen werden durch Originalterminpläne der Patienten ersetzt. Weiterhin werden die Übergangswahrscheinlichkeiten zwischen den Stationen durch die Entscheidungsstrategien ersetzt. Für die Evaluation werden Patienten für sechs aufeinanderfolgende Monate betrachtet. Um die Analyse nicht zu verfälschen, startet das Simulationsmodell einen Monat früher. Somit wird mit einem bereits belegten Krankenhaus gestartet. Bei einem Start mit einem leeren Krankenhaus könnten die Ergebnisse dieser Evaluation fehlinterpretiert werden.

7.5.1. Szenarien und Kennzahlen

Um den vorgeschlagenen Ansatz zu bewerten, werden verschiedene Szenarien mithilfe von Simulationen untersucht. Generell basieren alle Analysen auf realen Patientendaten. Alle aufgezeichneten Patienten in den Daten werden verwendet, um Zeitpläne für reale Situationen des Krankenhauses mit allen relevanten Informationen zu erstellen. Für jeden Patienten werden Geschlecht, Diagnose, Tag der Aufnahme und Verweildauer bestimmt. Im Falle des Basisansatzes werden zusätzliche Informationen zu den Stationspfaden der einzelnen Patienten eingefügt. Für den vorgeschlagenen qualitätsbasierten Ansatz wird jeder Patient entsprechend seiner Diagnose mit einer bestimmten Menge an Behandlungsschritten verknüpft. Auf diese Weise werden die im Datensatz enthaltenen Patienten so wiedergegeben, wie sie in der Realität aufgetreten sind. Was die Verweildauer betrifft, gibt es eine wichtige Tatsache, die zu beachten ist. Der vorgeschlagene Ansatz ist grundsätzlich in der Lage, die den Aufenthalt eines Patienten zu verkürzen, da er minimale Behandlungstage für die Aufnahme- und Verlegungsentscheidung verwendet. Dennoch verbleibt ein Patient bis zum Ende seiner Verweildauer im Krankenhaus, bevor er entlassen wird. Da nicht bekannt ist, ob ein Patient sich von einer Behandlung erholen musste oder der späte Behandlungstag in den Daten auf organisatorische Probleme des Krankenhauses zurückzuführen ist, wird eine Verkürzung der Verweildauer nicht genutzt. Für die folgenden Ergebnisse wird

7. Handlungsrichtlinien zur Unterstützung von operativen Entscheidungen

daher von einer eher pessimistischen Abschätzung der Länge des Aufenthaltes ausgegangen. In einer ersten Reihe von Experimenten wird der vorgeschlagene Ansatz mit der aktuellen Vorgehensweise des Krankenhauses verglichen. Die Gesamtleistung des qualitätsbasierten Verfahrens wird bewertet und die Möglichkeit der Nutzung verschiedener Qualitätsakzeptanzgrenzen (MQN) wird untersucht. Im zweiten Teil der Evaluation wird die zukünftige Eignung des vorgestellten Verfahrens analysiert. Dabei werden die Patientenzahlen künstlich erhöht. Dies kann zum einen über einen generellen Anstieg und zum anderen über einen sprunghaften Anstieg realisiert werden. Die erste Variante spiegelt den demografischen Wandel in Deutschland wider. In der zweiten Variante kommt es zu einer kurzfristigen Belastungsspitze durch unerwartete Ereignisse. Hier werden ein epidemischer Ausbruch einer neuen Krankheit und eine Reihe schwerer Unfälle betrachtet. Die Besonderheit dieser Szenarien ist, dass sich die Patientenzahlen nicht gleichmäßig über alle Diagnosen erhöhen, sondern einzelne Krankheiten gehäuft vorkommen. Somit kommt es nur auf einzelnen Stationen zu Belastungsspitzen.

Bei einem epidemischen Ausbruch wie der Covid-19-Pandemie im Jahr 2020 kommt es im schlimmsten Fall zu einem exponentielles Wachstum neuer Patienten, die über einen langen Zeitraum eintreffen. Außerdem müssen sie isoliert behandelt werden, was zu einer Reihe von Problemen bei Entscheidungen in der Patientenflusssteuerung führt. Ganze Stationen müssen für Patienten mit der Krankheit reserviert werden, und alle ursprünglich für diese Station geplanten Patienten müssen verschoben oder in andere Abteilungen verlegt werden. Vor allem in den ersten Tagen des Ausbruchs würde dies zu vielen Problemen hinsichtlich der Kapazität der Stationen führen. Die zweite klassischere Art der Belastungssituation führt zu einer relativ hohen Zahl zusätzlicher Patienten innerhalb einer kurzen Zeitspanne. Die Reaktion auf eine solche Belastungssituation hängt davon ab, ob ein Krankenhaus in der Lage ist, flexible Entscheidungen zu treffen. Das besondere Merkmal dieser Belastungssituation ist ein punktuell auftretendes Auftreten einer großen Menge von Patienten, die mit der gleichen Diagnosegruppe die Ressourcen eines Krankenhauses beanspruchen. Daher sind nur bestimmte Abteilungen einem hohen Kapazitätsdruck ausgesetzt, während andere weiterhin im Rahmen ihrer Standardroutine arbeiten. Eine Veranschaulichung des unterschiedlichen Wachstums von zusätzlichen Patienten ist in Abb. 7.9 dargestellt.

Die in Tabelle 7.2 dargestellten Szenarien decken ein breites Spektrum von Situationen ab. Dies ermöglicht es, die Stärke und die Einsatzmöglichkeiten des vorgestellten Ansatzes aufzuzeigen. Dazu werden verschiedene Kennzahlen (KPI)

7. Handlungsrichtlinien zur Unterstützung von operativen Entscheidungen

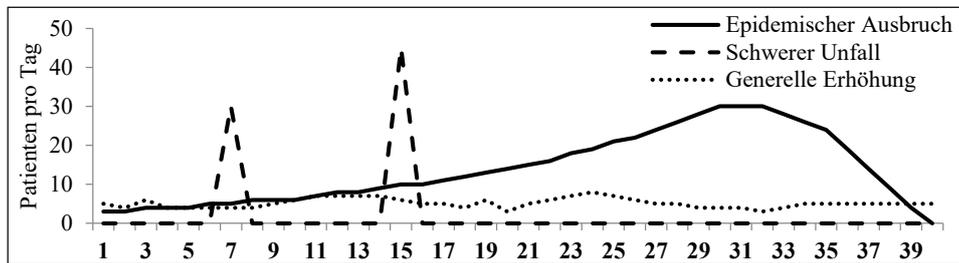


Abbildung 7.9.: Entwicklung der Patientenzahlen (Quelle: Eigene Darstellung)

Tabelle 7.2.: Szenarien der Fallstudie (Quelle: Eigene Darstellung)

Name	Beschreibung
SC1	Evaluation realer Daten mit verschiedenen Qualitätsniveaus
SC2	Generelle Erhöhung der Patientenzahlen
SC3	Sprunghafte Erhöhung der Patientenzahlen

verwendet. Die wichtigste KPI ist der Prozentsatz der aufgenommenen Patienten im Verhältnis zur Gesamtzahl der Patienten, die dem Krankenhaus vorgestellt werden, was als Aufnahmequote bezeichnet wird. Diese Quote kann als das allgemeine Dienstleistungsniveau des Krankenhauses angesehen werden. Um die Einnahmen zu steigern, versucht das Krankenhaus, die Aufnahmequote mit der vorhandenen Kapazität zu maximieren und somit die Zahl der aufgenommenen Patienten zu erhöhen. Eine maximale Aufnahmequote kann erreicht werden, wenn die minimal akzeptable Qualität auf 0 gesetzt wird, d. h. jedes verfügbare Bett ist für einen Patienten geeignet. Dies ist nicht in die Praxis übertragbar, da die individuelle Qualität zu niedrig sein könnte, um ein positives Behandlungsergebnis zu gewährleisten und die Gesamtqualität des Krankenhauses unter ein akzeptables Niveau sinken könnte. Die zweite Gruppe von KPIs ist qualitätsbasiert. Die erste Kennzahl beschreibt die durchschnittliche Gesamtqualität aller durchgeführten Behandlungen im Krankenhaus. Um die Qualität detaillierter zu bewerten, wird das 0,1 Perzentil der erbrachten Qualität verwendet. Anhand dieses Prozentsatzes kann man sagen, dass 10 % der Patienten eine Qualität erhalten, die unter diesem Wert liegt und umgekehrt 90 % aller Patienten eine höhere Behandlungsqualität erhalten. Um die Qualität weiter zu untersuchen, wurden die Patienten in zwei Gruppen eingeteilt. Die erste Gruppe erhält eine Behandlungsqualität von mindestens sieben

7. Handlungsrichtlinien zur Unterstützung von operativen Entscheidungen

Tabelle 7.3.: Kennzahlen zur Evaluation der Fallstudien (Quelle: Eigene Darstellung)

KPI	Description
Adm	Anzahl aufgenommener Patienten
AR	Aufnahmerate
REJ	Anzahl abgelehnter Patienten
REDC	Anzahl umgeleiteter Patienten
REDQA	durchschnittliche Qualitätsänderung bei Umleitungen
RELC	Anzahl umgelagerter Patienten
RELQA	durchschnittliche Qualitätsänderung bei Umlagerungen
PER	0,1 Perzentil der Behandlungsqualität
GQ	Anteil der Patienten mit guter Behandlungsqualität

Punkten (gute Qualität) und die zweite Gruppe erhält eine Behandlungsqualität, die zwischen der geforderten Mindestqualität und sieben Punkten liegt (akzeptable Qualität). Zur Bewertung der unterschiedlichen Szenarien sollte die Akzeptanzrate so hoch wie möglich sein, ohne dass die 0,1 Perzentile unter sieben Punkte fallen und der Prozentsatz der Patienten in der Gruppe mit guter Qualität nicht unter 94 % fallen. In einer Sekundäranalyse wurde die Nutzung der Flexibilität, die die Aufnahmestrategie bietet, bewertet. Hier werden die Anzahl der Umleitungen und deren Qualität untersucht. Anschließend werden die Umlagerungen als zusätzliche Flexibilisierung mit den gleichen Kennzahlen untersucht. Alle verwendeten KPIs sind in Tabelle 7.3 zusammengefasst.

7.5.2. Evaluation realer Daten mit verschiedenen Qualitätsniveaus

In Abbildung 7.10 und Tabelle 7.4 sind die Ergebnisse der Simulationsläufe für die VF-Strategie und die Vergleichsinstanz gegeben. Überraschenderweise kann die Vergleichsinstanz nicht alle Patienten aufnehmen, obwohl es in der Realität möglich war. Dies ist ein Indikator dafür, dass es im operativen Betrieb des Krankenhauses zu undokumentierten flexiblen Entscheidungen in Stresssituationen kommt. Mit 8,83 % ist der Unterschied zwischen den Daten und der Realität sehr groß. Mit Hilfe der vorgeschlagenen APS-Strategie kann diese Lücke geschlossen werden. Die minimal benötigte Qualität für die Behandlung eines Patienten bestimmt in

7. Handlungsrichtlinien zur Unterstützung von operativen Entscheidungen

Tabelle 7.4.: Evaluation der VF-Strategie (Quelle: Eigene Darstellung)

MQN	Adm	ER C	AR	Per	GQ
10	9530	7210	56,93 %	10	100 %
9	12588	4152	75,20 %	9,3	100 %
8	14614	2126	87,30 %	8,6	100 %
7	15769	971	94,20 %	8,2	100 %
6	16158	582	96,52 %	7,8	96,44 %
5	16561	179	98,93 %	7,6	95,10 %
4	16661	79	99,53 %	7,5	94,11 %
3	16701	39	99,77 %	7,5	93,63 %
2	16738	2	99,99 %	7,4	93,22 %
1	16738	2	99,99 %	7,4	93,13 %
0	16739	1	99,99 %	6,8	89,82 %
BA	15262	1478	91,17 %	6,25	87,67 %

dieser Strategie den Grad der Flexibilität. Je höher die erforderliche Qualität ist, umso geringer ist die Möglichkeit, einen Patienten auf einer Alternativstation zu behandeln. Um einen angemessenen Grad der Flexibilität zu bestimmen, werden erforderliche Qualitäten von eins bis zehn untersucht.

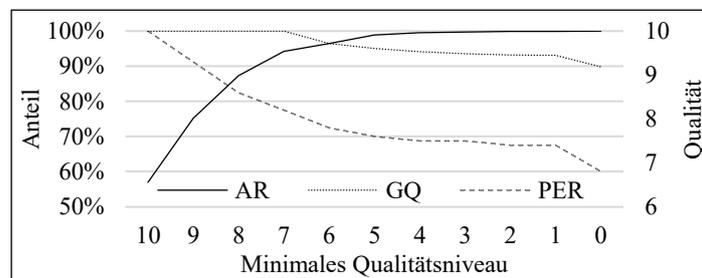


Abbildung 7.10.: Grafische Evaluation der VF-Strategie (Quelle: Eigene Darstellung)

Wenn die erforderliche Qualität auf 0 gesetzt wird, erreicht das Krankenhaus eine AR von 99,99 % und das 0,1 Perzentil der Qualität liegt bei 6,8. Beide Werte sind höher als in der Vergleichsinstanz. Dies bedeutet, dass vollständige operative Flexibilität auf Basis der vorgestellten Wissensgenerierung die Reaktion auf Engpasssituationen verbessern kann, ohne die Behandlungsqualität signifikant zu verringern. Sollte das Krankenhaus die Anzahl der abgelehnten Patienten der

7. Handlungsrichtlinien zur Unterstützung von operativen Entscheidungen

Tabelle 7.5.: Evaluation der Umleitungen und Umlagerungen (Quelle: Eigene Darstellung)

	MQN	REJ	REDC	REDQA	RELC	RELQA
6	582	969	1,73	820	-0,76	
5	179	1319	2,01	983	-0,55	
4	79	1435	2,16	923	-0,56	

Vergleichsinstanz erreichen wollen, kann die minimal erforderliche Qualität auf 7 Punkte gesetzt werden. Dabei erhöht sich das 0,1 Perzentil auf 8,2. Sinkt die erforderliche Qualität, wird eine Erhöhung der AR und eine Verringerung des 0,1 Perzentil erwartet. Bei einer Reduktion der geforderten Qualität von 7 auf 5 Punkte erhöht sich die AR um 4,73 %. Jedoch verringert sich das 0,1 Perzentil lediglich um 0,6 Punkte, was darauf hindeutet, dass Stationen, die eine Qualität nahe der minimal erforderlichen Qualität anbieten, nur in Stresssituationen als letzte Möglichkeit verwendet werden.

In Tabelle 7.5 werden die Umleitungen und Umlagerungen im Detail untersucht. Bei einer erforderlichen Qualität von 5 Punkten werden 179 Patienten abgewiesen. Damit verringert sich dieser Wert im Vergleich zur Vergleichsinstanz um 1.299 Patienten. Jedoch werden 1.319 Patienten vor der Aufnahme umgeleitet und 983 Patienten werden während des Aufenthaltes verlegt. Dies bedeutet, dass ein abgewiesener Patient nicht durch genau eine Umleitung oder Umlagerung ausgeglichen werden kann. Bei der Betrachtung der durchschnittlichen Behandlungsqualität fällt auf, dass sie bei Umleitungen um zwei Punkte sinkt. Im Gegensatz dazu steigt die Qualität bei Umlagerungen im Durchschnitt 0,55 Punkte. Dies bestätigt die Annahme, dass eine Flexibilität während des Behandlungsverlaufes die individuelle Behandlungsqualität erhöhen kann.

In Abbildung 7.11 ist ein Vergleich zwischen den beiden vorgestellten Entscheidungsstrategien gezeigt. Dabei sind für verschiedene Qualitätslevel die Abweisungen, Umleitungen und Umlagerungen abgetragen. Zusätzlich ist das 0,1 Perzentil der Behandlungsqualität dargestellt. Dabei ist auffällig, dass die Summe der Abweisungen, Umleitungen und Umlagerungen in der NU-Strategie immer größer ist als in der VF-Strategie. Wird eine minimale Qualität von 5 Punkten betrachtet, ist zu erkennen, dass die Anzahlen der Abweisungen und der Umleitungen sinkt. Beide Werte stehen dafür, dass mehr Patienten auf ihrer gewünschten Station aufgenommen werden können und somit tendenziell die bestmögliche Qualität erhalten,

7. Handlungsrichtlinien zur Unterstützung von operativen Entscheidungen

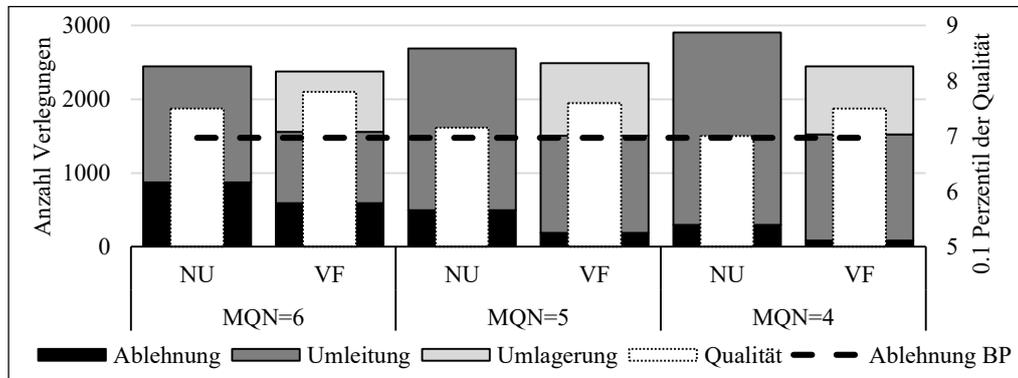


Abbildung 7.11.: Evaluation der VF- und NU-Strategie (Quelle: Eigene Darstellung)

Tabelle 7.6.: Evaluation erhöhter Patientenzahlen (Quelle: Eigene Darstellung)

Erhöhung	Adm	REJ	AR	PER	GQ
0 %	16661	79	99,53 %	7,5	94,11 %
10 %	18259	228	98,77 %	7,1	91,33 %
20 %	19801	347	98,28 %	7	90,39 %
30 %	21224	607	97,22 %	5,9	83,43 %

da die ersten Behandlungsschritte in der Regel essenziell für die Wiederherstellung der Gesundheit der Patienten sind. Zusammenfassend zeigt diese Abbildung, dass die erste Stufe der Flexibilität (Umleitung) die Leistung des Krankenhauses verbessern kann, und die zweite Stufe der Flexibilität verbessert zusätzlich zu erhöhten Aufnahmezahlen auch die durchschnittliche Behandlungsqualität.

7.5.3. Generelle Erhöhung der Patientenzahlen

Um die zukünftige Eignung des Verfahrens zu bewerten, wird die demografische Entwicklung der Bevölkerung in Deutschland als ein erster Indikator verwendet. Im Allgemeinen bedeutet dies, dass ein genereller Anstieg der Patientenzahlen in den nächsten Jahren erwartet wird. Demnach werden allgemeine Steigerungsraten von 10 %, 20 % und 30 % mehr Patienten bewertet. In Tabelle 7.6 sind die Ergebnisse mit unterschiedlichen Entwicklungen der Patientenzahlen dargestellt.

7. Handlungsrichtlinien zur Unterstützung von operativen Entscheidungen

Es liegt auf der Hand, dass mit steigender Patientenzahl auch die Akzeptanzrate sinkt. Sie verringert sich von 99,53 % auf 97,18 % bei 30 % mehr Patienten, was immer noch deutlich höher ist als in der Ausgangssituation. Es ist also möglich, die Patientenzahl um bis zu 30 % zu erhöhen, ohne dass sich die Situation für das Krankenhaus im Vergleich zur Benchmark-Instanz verschlechtert. Auch in Bezug auf die absolute Zahl der Ablehnungen übertrifft eine 30 %ige Erhöhung der Patientenzahlen die Vergleichsinstanz. Andererseits zeigt die Qualitätsauswertung, dass das 0,1 Perzentil von 7,5 auf 5,9 Punkte und der Anteil der Patienten mit einer guten Behandlungsqualität auf 83,43 % sinkt. Auch wenn sich die Werte der Kennzahlen verringern, liegen sie noch in einem akzeptablen Bereich. Betrachtet man die Nutzung der Flexibilität, so ist es interessant, dass alle relevanten KPIs steigen. Außerdem ist zu sehen, dass der positive Effekt von Verlagerungen mit steigender Patientenzahl abnimmt. Dennoch können diese Zahlen für das Krankenhaus noch akzeptabel sein. Der durchschnittliche Qualitätsverlust für Umleitungen steigt von 2,16 auf 2,40 und für Umlagerungen von -0,56 auf -0,21. Mit flexiblen Aufnahme-strategien sind die Krankenhäuser also in der Lage, deutlich mehr Behandlungen durchzuführen, ohne die wichtigsten KPIs signifikant zu verschlechtern. Bei einem Anstieg der Patientenzahlen um 20 % ist ein Anstieg der aufgenommenen Patienten um 21,9 % im Vergleich zur Benchmark-Instanz zu beobachten.

7.5.4. Sprunghafte Erhöhung der Patientenzahlen

Die Reaktionen auf unvorhergesehene Ereignisse, die zu Belastungsspitzen führen, werden in diesem Unterabschnitt bewertet. Das erste Szenario umfasst die pandemischen Ereignisse von Covid-19. Dabei geht es von einem exponentiellen Anstieg der Fälle bis zu einem bestimmten Punkt aus. Danach nimmt die Zahl der Fälle ab. In diesem Szenario werden zwei verschiedene Konfigurationen bewertet. Erstens ist das Simulationsmodell in der Lage, so viele Stationen wie nötig für Covid-19-Patienten zu reservieren. Im zweiten Szenario wird die Anzahl der Stationen für Covid-19-Patienten auf 5 beschränkt. Diese 5 Stationen wurden ausgewählt, weil die Daten darauf hindeuten, dass sie die am besten geeigneten Stationen für Atemwegserkrankungen sind. In Abb. 7.12 und 7.13 sind die Anzahl der behandelten Covid-19-Patienten und die aktuelle Anzahl der reservierten Stationen dargestellt. Zu Beginn des Ausbruchs schneiden beide Konfigurationen gleich gut ab. Sobald die 5 vordefinierten Stationen voll belegt sind, reserviert die uneingeschränkte Konfiguration zusätzliche Stationen und ist somit in der Lage,

7. Handlungsrichtlinien zur Unterstützung von operativen Entscheidungen

alle Covid-19-Patienten zu behandeln. Bei einer Beschränkung auf 5 Stationen werden insgesamt 81 Covid-19-Patienten abgewiesen. Bei der uneingeschränkten Konfiguration sinkt die Annahmequote auf 86 % und der Anteil qualitativ hochwertiger Behandlungen auf 70 %.

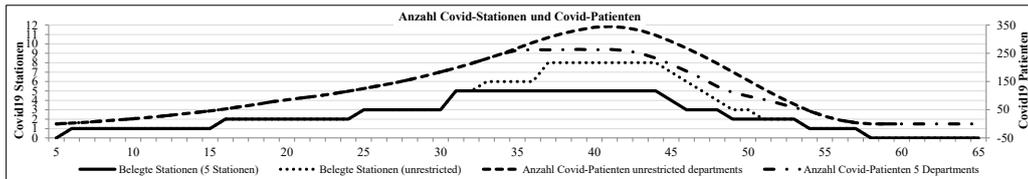


Abbildung 7.12.: Entwicklung der Patientenzahlen während einer Pandemie (Quelle: eigene Darstellung)

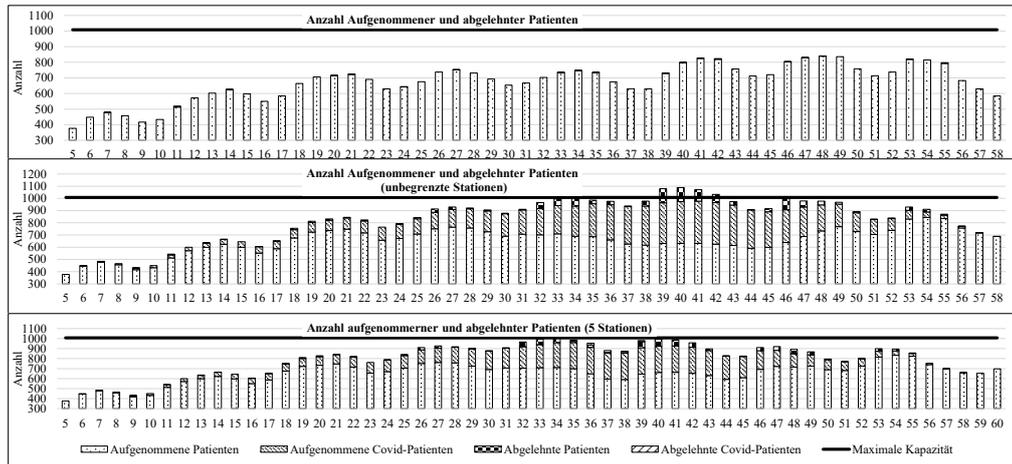


Abbildung 7.13.: Anzahl aufgenommener und abgelehnter Patienten im Pandemieszenario (Quelle: Eigene Darstellung)

Das Szenario hat negative Auswirkungen auf die Behandlung der regulären Patienten. Das Krankenhaus muss also einen Kompromiss zwischen der Behandlung von regulären und epidemischen Patienten finden. Bei einer Beschränkung auf 5 Stationen für Epidemiepatienten sinkt die Annahmequote für reguläre Patienten auf 90,73 % und der Anteil der Patienten mit einer guten Behandlungsqualität auf 79 %. Das bedeutet, dass der erste KPI immer noch über einem akzeptablen Wert liegt, während der zweite KPI deutlich sinkt. Dennoch können diese Werte

7. Handlungsrichtlinien zur Unterstützung von operativen Entscheidungen

in einem Pandemieszenario einen akzeptablen Kompromiss zwischen einer hohen Behandlungsqualität für normale Patienten und der Anzahl der behandelten Epidemienpatienten darstellen. Dies zeigt, dass die vorgeschlagene flexible Entscheidungsstrategie in der Lage ist, mit epidemischen Ausbrüchen umzugehen. Außerdem kann dieser Ansatz als Entscheidungshilfe genutzt werden, bevor ein Ausbruch seinen Höhepunkt erreicht. Es können verschiedene Szenarien mit einer unterschiedlichen Menge an Isolationsstationen berechnet werden. Dadurch ist das Krankenhaus in der Lage, die Anzahl der abgewiesenen regulären und epidemischen Patienten abzuschätzen. Somit können Patienten umgeplant oder in andere Krankenhäuser abgegeben werden. Somit sind die Krankenhäuser nicht gezwungen, fast alle regulären Patienten zu abzulehnen. Daher könnte es möglich sein, dass die normale Arbeit eines Krankenhauses fortgesetzt werden kann, ohne dass negative Auswirkungen auf die Zahl der behandelten Patienten und die wirtschaftliche Stabilität des Krankenhauses zu befürchten sind.

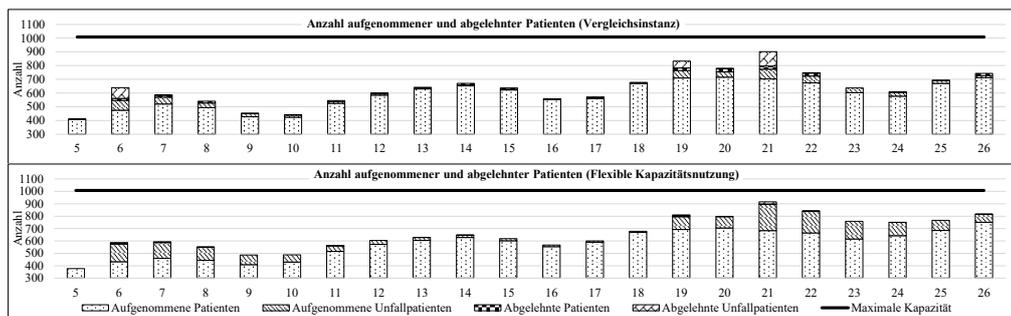


Abbildung 7.14.: Anzahl aufgenommener und abgelehnter Patienten im Unfallszenario (Quelle: Eigene Darstellung)

Bei der zweiten betrachteten Belastungssituation handelt es sich um einen schweren Unfall, der einen sprunghaften Anstieg der Patientenzahlen für bestimmte Diagnosen verursacht. Außerdem benötigen diese Patienten keine isolierte Behandlung. Für dieses Szenario werden drei aufeinanderfolgende schwere Unfälle betrachtet. Der erste ereignet sich am Tag 6 der Simulation, an dem die Belegungsrate eher niedrig ist. Der zweite Unfall erfolgt, wenn die Belegungsrate an Tag 19 ihren Höhepunkt erreicht und der dritte Unfall geschieht kurz nach dem zweiten (Tag 21) mit der Besonderheit, dass nicht alle ehemaligen Patienten des zweiten Unfalls aus dem Krankenhaus entlassen werden. Da die Zahl der Patienten sehr schnell ansteigt, wird dieses Szenario mit detaillierteren Kennzahlen wie

7. Handlungsrichtlinien zur Unterstützung von operativen Entscheidungen

die täglich aufgenommenen und abgewiesenen Patienten bewertet. Es ist offensichtlich, dass der aktuell verwendete Entscheidungsansatz nicht in der Lage ist, eine plötzliche Spitze von Krankenhauseinweisungen zu bewältigen und viele Unfallopfer abgewiesen werden. Wie bereits erörtert, ist das Krankenhaus selbst bei einer Belegungsrate von deutlich unter 100 % nicht in der Lage, diese Spitzen zu bewältigen. Beim ersten und zweiten Unfall wird fast die Hälfte aller Patienten des Unfalls abgewiesen. Beim dritten Unfall verschlimmert sich die Situation für das Krankenhaus, weil die meisten der neu eingetroffenen Patienten abgelehnt werden (Abb. 7.14). Im Gegensatz dazu ist die vorgestellte flexible Aufnahmeregel in der Lage, alle drei Unfälle zu bewältigen. Die Aufnahmequote sinkt nur um 1 %, und der Anteil der Patienten, die eine Behandlung mit einer Qualität von mindestens 7 Punkten erhalten, ist auf dem gleichen Niveau wie zuvor. Außerdem zeigt sich, dass die Flexibilität häufiger genutzt wird, um zusätzliche Patienten auf die Stationen zu verteilen. Es ist klar, dass flexible, transparente Aufnahmeregeln den Entscheidungsträgern helfen können, kurzfristige Entscheidungen zu treffen, die sich nicht negativ auf die Gesamtleistung des Krankenhauses auswirken. Im Einzelnen sind die vorgestellten objektiven Entscheidungsregeln mit einem gegebenen Qualitätslevel in der Lage, fast alle Patienten aus allen 3 Unfällen aufzunehmen. Insgesamt werden nur 30 Patienten aus den Unfällen abgewiesen. Dabei werden nach den ersten beiden Unfällen 7 und 6 Patienten abgewiesen. Nur beim dritten Unfall steigt die Ablehnung auf 17 Patienten an, was auf die noch vorhandenen Patienten aus den ersten beiden Unfällen zurückzuführen ist. Auch die Gesamtzahl der abgelehnten regulären Patienten steigt an. Aber die Ablehnungsquote liegt deutlich unter der Rate des Basisszenarios. Insbesondere bei Ereignissen, bei denen die Zeit zwischen dem Unfall und dem Beginn der Behandlung entscheidend ist, könnte dies zu einer verbesserten Versorgungsqualität für die Patienten führen. Der gesamte Belegungsverlauf ist in Abb. 7.14 dargestellt.

In den Experimenten wurde gezeigt, dass die vorgestellten flexiblen Handlungsrichtlinien in der Lage sind, den Entscheidungsträger im Krankenhaus während operativer Stresssituationen zu unterstützen. Dies ist ein starker Indikator dafür, dass objektive Handlungsanweisungen den Krankenhäusern helfen, ihre vorhandenen Kapazitäten effizienter zu nutzen. Dabei wird zusätzlich die Gesamtauslastung erhöht. Dies kann zu einer besseren wirtschaftlichen Situation des Krankenhauses führen.

8. Fazit

Krankenhäuser, die ihre Kosten- und Prozessstruktur nicht an geänderte Rahmenbedingungen, wie eine Änderung der Abrechnungsstruktur, eine Verringerung der Bettenkapazität und einer Erhöhung der Fallzahlen im Gesundheitswesen, anpassen, können existenziell bedroht sein. Effiziente Ansätze zur Planung und Steuerung des Patientenflusses sind notwendig, um bei gleichbleibender oder sinkender Kapazität eine hohe Auslastung mit gleichzeitig geringen Wartezeiten der Patienten zu ermöglichen. Gerade bei unveränderlichen Kapazitäten ist eine flexible Nutzung eben dieser von essenzieller Bedeutung, um die Auslastung und Effizienz eines Krankenhauses zu erhöhen und damit das langfristige wirtschaftliche Agieren sicherzustellen.

Durch die Berücksichtigung der komplexen interdependenten Strukturen von großen Krankenhäusern ist die Erstellung flexibler Planungs- und Steuerungsansätze im Krankenhaus möglich. Von entscheidender Bedeutung sind dabei die Wechselwirkungen der einzelnen Patientengruppen, das heißt die Konkurrenz um Ressourcen zwischen elektiven Patienten und Notfallpatienten. Auch die funktionalen Interdependenzen, also die Möglichkeit, dass eine Behandlung oder einzelne Teile davon von verschiedenen Stationen durchgeführt werden können, hat einen großen Einfluss auf die Leistungsfähigkeit eines Krankenhauses.

Um die Nutzung alternativer Stationen zu ermöglichen, müssen zunächst zwei grundlegende Fragen beantwortet werden. Zum einen, welche Behandlungen notwendig sind und zum anderen, welche Stationen in der Lage sind, diese Behandlungen durchzuführen. Die Beantwortung dieser Frage ist normalerweise in den klinischen Patientenpfaden, die eine grundlegende krankenhausspezifische Richtlinie zur Behandlung bestimmter Diagnosen darstellt, enthalten. Da die Erstellung der Patientenpfade aufgrund der Variabilität der Behandlungen sehr komplex und aufwendig ist, werden diese in der Regel nur für stark standardisierte Behandlungsabläufe für bestimmte Diagnosen verwendet. Jedoch können diese Fragen auch

mithilfe standardisierter Controlling-Daten des Krankenhauses beantwortet werden. Auf Basis selbst entwickelter Data-Mining Verfahren wird das Behandlungswissen extrahiert. Im Zusammenspiel mit den vorgestellten Interdependenzen bilden sie die Grundlage der vorgestellten datengetriebenen Planungs- und Steuerungsansätze im Patientenflussmanagement. Aufgrund der standardisierten Struktur der Daten und der Tatsache, dass jedes Krankenhaus in Deutschland verpflichtet ist, diese Daten aufzunehmen, lassen sich die in dieser Arbeit vorgestellten Verfahren ohne großen Aufwand auf andere Krankenhäuser übertragen.

In einem ersten Schritt wurde die generelle Einführung einer flexiblen Kapazitätsnutzung mithilfe generischer Simulationsmodelle evaluiert. Dabei werden verschiedene Szenarien, wie der Verleih von Kapazitäten und dem Clustern von Kapazitäten untersucht. Dabei wurde gezeigt, dass eine flexible Nutzung der Kapazitäten die Wartezeiten signifikant verringern kann. Hier werden die Wartezeiten für ITS-Betten nahezu vollständig eliminiert und die Wartezeiten auf Normalstationen um 50 % reduziert. Zusätzlich können mithilfe interdisziplinärer Stationscluster bis zu 96 % der Kapazitätsengpässe vermieden werden. Diese generellen Erkenntnisse werden in operative Planungs- und Steuerungsansätze überführt.

Für die proaktive Vermeidung von Kapazitätsengpässen wurde ein lineares Optimierungsmodell entwickelt, das auf Basis eines initialen Terminplanes und der antizipierten Nachfrage von Notfallpatienten eine Neuplanung der Aufnahmetermine der elektiven Patienten vornimmt. Dabei werden nahezu alle Kapazitätsengpässe vermieden und die Anzahl der Terminverschiebungen bewegt sich im akzeptablen Rahmen. Die Integrierung von Notfallpatienten in den Planungsansatz führt auch dazu, dass eine detaillierte Planung und eine bessere Ausnutzung der Kapazitäten ermöglicht wird. In diesem Fall existiert keine feste Anzahl an Betten, die für Notfallpatienten reserviert werden, sondern die Anzahl der reservierten Betten wird in Abhängigkeit der Prognose der Notfallpatienten vom Optimierungsmodell bestimmt.

Trotz der Planung unter Berücksichtigung von Notfallpatienten können nicht alle Engpässe im operativen Betrieb verhindert werden. Aus diesem Grund wurden flexible operative Richtlinien entworfen, die als Entscheidungsgrundlage im operativen Betrieb verwendet werden können. Diese Entscheidungen basieren dabei auf dem aus den Daten extrahierten Wissen über die Behandlungsverläufe und die jeweiligen geeigneten Stationen. In der Evaluation wird gezeigt, dass nahezu alle operativen Engpässe schnell und qualitativ hochwertig aufgelöst werden können.

Mithilfe der vorgestellten Komponenten zum krankenhausesweiten Patientenflussmanagement konnten die Effizienz und die Auslastung des Krankenhauses erhöht werden, ohne die Behandlungsqualität negativ zu beeinflussen. Somit erfüllen diese Komponenten das Hauptziel dieser Arbeit. Dabei liefern die Erkenntnisse dieser Arbeit die theoretische und praktische Grundlage für die Entwicklung praxistauglicher Entscheidungsunterstützungssysteme.

Die Natur einer wissenschaftlichen Arbeit ist es, neue theoretische und praktische Denkanstöße für die Praxis und Forschung zu liefern. Der Weg zu einem in der Praxis anwendbaren Entscheidungsunterstützungssystem ist lang. Basierend auf den Ergebnissen dieser Arbeit muss eine enge Zusammenarbeit mit Entscheidungsträgern im Krankenhaus etabliert werden, um die Verfahren weiter zu entwickeln und ein in der Praxis einsatzfähiges System zu entwickeln.

Da die vorgeschlagenen Verfahren an das Gesundheitswesen in Deutschland angepasst sind, können in weiterer Forschung die Einsatzmöglichkeiten der Verfahren in anderen Gesundheitssystemen mit unterschiedlichen Rahmenbedingungen untersucht werden.

Somit stellt diese Arbeit den Startpunkt für weitere vielfältige Forschung sowohl im Bereich des Praxistransfers, als auch in der methodischen Forschung dar. In einem nächsten Schritt sollten die Ergebnisse dieser Arbeit in enger Zusammenarbeit mit den Entscheidungsträgern im Krankenhaus zu einem einsatzfähigen Entscheidungsunterstützungssystem erweitert werden.

Literaturverzeichnis

- [1] Abu Doush, I., Al-Betar, M.A., Awadallah, M.A., Hammouri, A.I., Al-Khatib, R.M., ElMustafa, S., ALkhraisat, H.: Harmony Search Algorithm for Patient Admission Scheduling Problem. *Journal of Intelligent Systems* **0**(0) (2018). DOI 10.1515/jisys-2018-0094. URL <http://www.degruyter.com/view/j/jisys.ahead-of-print/jisys-2018-0094/jisys-2018-0094.xml>
- [2] Adeyemi, S., Chausalet, T., Demir, E.: Nonproportional random effects modelling of a neonatal unit operational patient pathways. *Stat Methods Appl* **20**(4), 507–518 (2011). DOI 10.1007/s10260-011-0174-z. URL <http://link.springer.com/10.1007/s10260-011-0174-z>
- [3] Alvarado, M.M., Cotton, T.G., Ntaimo, L., Pérez, E., Carpentier, W.R.: Modeling and simulation of oncology clinic operations in discrete event system specification. *SIMULATION* **94**(2), 105–121 (2018). DOI 10.1177/0037549717708246. URL <http://journals.sagepub.com/doi/10.1177/0037549717708246>
- [4] Andersen, A.R., Nielsen, B.F., Reinhardt, L.B.: Optimization of hospital ward resources with patient relocation using Markov chain modeling. *European Journal of Operational Research* **260**(3), 1152–1163 (2017)
- [5] Aringhieri, R., Landa, P., Mancini, S.: A Hierarchical Multi-objective Optimisation Model for Bed Levelling and Patient Priority Maximisation. In: A. Sforza, C. Sterle (eds.) *Optimization and Decision Science: Methodologies and Applications*, vol. 217, pp. 113–120. Springer International Publishing, Cham (2017). DOI 10.1007/978-3-319-67308-0_12. URL http://link.springer.com/10.1007/978-3-319-67308-0_12
- [6] Arnold, D. (ed.): *Handbuch Logistik: mit ... 77 Tabellen*. Engineering Online Library. Springer, Berlin Heidelberg (2002)

- [7] Asaduzzaman, M., Chausalet, T.J., Robertson, N.J.: A loss network model with overflow for capacity planning of a neonatal unit. *Ann Oper Res* **178**(1), 67–76 (2010). DOI 10.1007/s10479-009-0548-x. URL <http://link.springer.com/10.1007/s10479-009-0548-x>
- [8] Atkinson, J.A., Wells, R., Page, A., Dominello, A., Haines, M., Wilson, A.: Applications of system dynamics modelling to support health policy. *Public Health Research & Practice* **25**(3) (2015). DOI 10.17061/phrp2531531
- [9] Bai, M., Storer, R.H., Tonkay, G.L.: A sample gradient-based algorithm for a multiple-OR and PACU surgery scheduling problem. *IIE Transactions* **49**(4), 367–380 (2017). DOI 10.1080/0740817X.2016.1237061. URL <https://www.tandfonline.com/doi/full/10.1080/0740817X.2016.1237061>
- [10] Bakker, M., Tsui, K.L.: Dynamic resource allocation for efficient patient scheduling: A data-driven approach. *Journal of Systems Science and Systems Engineering* **26**(4), 448–462 (2017). DOI 10.1007/s11518-017-5347-3. URL <http://link.springer.com/10.1007/s11518-017-5347-3>
- [11] Barado, J., Guergué, J.M., Esparza, L., Azcárate, C., Mallor, F., Ochoa, S.: A mathematical model for simulating daily bed occupancy in an intensive care unit*. *Critical Care Medicine* **40**(4), 1098–1104 (2012). DOI 10.1097/CCM.0b013e3182374828. URL <http://journals.lww.com/00003246-201204000-00007>
- [12] Bartz, M.: *Patientenpfade Ein Instrument zur Prozessoptimierung im Krankenhaus*. VDM Verlag Dr. Müller, Saarbrücken (2006)
- [13] Barz, C., Rajaram, K.: Elective Patient Admission and Scheduling under Multiple Resource Constraints. *Production and Operations Management* **24**(12), 1907–1930 (2015). DOI 10.1111/poms.12395. URL <http://doi.wiley.com/10.1111/poms.12395>
- [14] Bastos, L.S., Marchesi, J.F., Hamacher, S., Fleck, J.L.: A mixed integer programming approach to the patient admission scheduling problem. *European Journal of Operational Research* (2018). DOI 10.1016/j.ejor.2018.09.003. URL <https://linkinghub.elsevier.com/retrieve/pii/S0377221718307495>

- [15] Berger, R.: Roland Berger Krankenhausstudie 2019 (2019). URL www.rolandberger.com/publications/publication_pdf/roland_berger_krankenhausstudie_2019.pdf
- [16] Berger, R.: Verspielte Zukunft? Warum Deutschlands Kliniken jetzt investieren müssten, es aber nicht können. Roland Berger Krankenhausstudie p. 16 (2021)
- [17] Best, T.J., Sandıkçı, B., Eisenstein, D.D., Meltzer, D.O.: Managing Hospital Inpatient Bed Capacity Through Partitioning Care into Focused Wings. *M&SOM* **17**(2), 157–176 (2015). DOI 10.1287/msom.2014.0516. URL <http://pubsonline.informs.org/doi/10.1287/msom.2014.0516>
- [18] Bhattacharjee, P., Ray, P.K.: Patient flow modelling and performance analysis of healthcare delivery processes in hospitals: A review and reflections. *Computers & Industrial Engineering* **78**, 299–312 (2014). DOI 10.1016/j.cie.2014.04.016. URL <https://linkinghub.elsevier.com/retrieve/pii/S0360835214001272>
- [19] Bilgin, B., Demeester, P., Misir, M., Vancroonenburg, W., Vanden Berghe, G.: One hyper-heuristic approach to two timetabling problems in health care. *Journal of Heuristics* **18**(3), 401–434 (2012). DOI 10.1007/s10732-011-9192-0. URL <http://link.springer.com/10.1007/s10732-011-9192-0>
- [20] Bolaji, A.L., Bamigbola, A.F., Shola, P.B.: Late acceptance hill climbing algorithm for solving patient admission scheduling problem. *Knowledge-Based Systems* **145**, 197–206 (2018). DOI 10.1016/j.knosys.2018.01.017. URL <http://linkinghub.elsevier.com/retrieve/pii/S095070511830025X>
- [21] Brailsford, S.C., Harper, P.R., Patel, B., Pitt, M.: An analysis of the academic literature on simulation and modelling in health care. *Journal of Simulation* **3**(3), 130–140 (2009). DOI 10.1057/jos.2009.10. URL <https://www.tandfonline.com/doi/full/10.1057/jos.2009.10>
- [22] Bruballa, E., Wong, A., Rexachs, D., Luque, E., Epelde, F.: Scheduling model for non-critical patients admission into a hospital emergency department. In: 2017 Winter Simulation Conference (WSC), pp. 2917–2928.

- IEEE, Las Vegas, NV (2017). DOI 10.1109/WSC.2017.8248014. URL <http://ieeexplore.ieee.org/document/8248014/>
- [23] de Bruin, A.M., Bekker, R., van Zanten, L., Koole, G.M.: Dimensioning hospital wards using the Erlang loss model. *Ann Oper Res* **178**(1), 23–43 (2010). DOI 10.1007/s10479-009-0647-8. URL <http://link.springer.com/10.1007/s10479-009-0647-8>
- [24] de Bruin, A.M., van Rossum, A.C., Visser, M.C., Koole, G.M.: Modeling the emergency cardiac in-patient flow: an application of queuing theory. *Health Care Manage Sci* **10**(2), 125–137 (2007). DOI 10.1007/s10729-007-9009-8. URL <https://link.springer.com/10.1007/s10729-007-9009-8>
- [25] Burke, E.K., Curtois, T., Qu, R., Vanden Berghe, G.: A scatter search methodology for the nurse rostering problem. *Journal of the Operational Research Society* **61**(11), 1667–1679 (2010). DOI 10.1057/jors.2009.118. URL <https://www.tandfonline.com/doi/full/10.1057/jors.2009.118>
- [26] Burke, E.K., De Causmaecker, P., Berghe, G.V., Van Landeghem, H.: The State of the Art of Nurse Rostering. *Journal of Scheduling* **7**(6), 441–499 (2004). DOI 10.1023/B:JOSH.0000046076.75950.0b. URL <http://link.springer.com/10.1023/B:JOSH.0000046076.75950.0b>
- [27] Busby, C.R., Carter, M.W.: Data-driven generic discrete event simulation model of hospital patient flow considering surge. In: 2017 Winter Simulation Conference (WSC), pp. 3006–3017. IEEE, Las Vegas, NV (2017). DOI 10.1109/WSC.2017.8248022. URL <http://ieeexplore.ieee.org/document/8248022/>
- [28] Cardoen, B., Demeulemeester, E., Beliën, J.: Operating room planning and scheduling: A literature review. *European Journal of Operational Research* **201**(3), 921–932 (2010). DOI 10.1016/j.ejor.2009.04.011. URL <https://linkinghub.elsevier.com/retrieve/pii/S0377221709002616>
- [29] Carmen, R., Defraeye, M., Van Nieuwenhuyse, I.: A Decision Support System for Capacity Planning in Emergency Departments. *International Journal of Simulation Modelling* **14**(2), 299–312 (2015). DOI 10.2507/IJSIMM14(2)10.308. URL http://www.ijssimm.com/Full_Papers/Fulltext2015/text14-2_299-312.pdf

- [30] Cayirli, T., Dursun, P., Gunes, E.D.: An integrated analysis of capacity allocation and patient scheduling in presence of seasonal walk-ins. *Flexible Services and Manufacturing Journal* (2018). DOI 10.1007/s10696-017-9304-8. URL <http://link.springer.com/10.1007/s10696-017-9304-8>
- [31] Ceschia, S., Schaerf, A.: Local search and lower bounds for the patient admission scheduling problem. *COR* **38**(10), 1452–1463 (2011). DOI 10.1016/j.cor.2011.01.007. URL <http://linkinghub.elsevier.com/retrieve/pii/S0305054811000116>
- [32] Ceschia, S., Schaerf, A.: Modeling and solving the dynamic patient admission scheduling problem under uncertainty. *Artificial Intelligence in Medicine* **56**(3), 199–205 (2012). DOI 10.1016/j.artmed.2012.09.001. URL <http://linkinghub.elsevier.com/retrieve/pii/S0933365712001169>
- [33] Ceschia, S., Schaerf, A.: Patient Admission Scheduling with Operating Room Constraints. In: *Proc. of the 9th Int. Conf. on the Practice and Theory of Automated Timetabling (PATAT-2012)* (2012)
- [34] Ceschia, S., Schaerf, A.: Dynamic patient admission scheduling with operating room constraints, flexible horizons, and patient delays. *J Sched* **19**(4), 377–389 (2016). DOI 10.1007/s10951-014-0407-8. URL <http://link.springer.com/10.1007/s10951-014-0407-8>
- [35] Chalgham, M., Khatrouch, I., Masmoudi, M., Walha, O.C., Dammak, A.: Inpatient admission management using multiple criteria decision-making methods. *Operations Research for Health Care* **23**(100173), 1–13 (2019). DOI 10.1016/j.orhc.2018.10.001. URL <https://linkinghub.elsevier.com/retrieve/pii/S2211692317301856>
- [36] Chan, Y.C., Wong, E.W.M., Joynt, G., Lai, P., Zukerman, M.: Overflow models for the admission of intensive care patients. *Health Care Manag Sci* **21**(4), 554–572 (2018). DOI 10.1007/s10729-017-9412-8. URL <http://link.springer.com/10.1007/s10729-017-9412-8>
- [37] Cochran, J.K., Roche, K.: A queuing-based decision support methodology to estimate hospital inpatient bed demand. *Journal of the Operational Research Society* **59**(11), 1471–1482 (2008). DOI 10.1057/palgrave.jors.2602499. URL <https://www.tandfonline.com/doi/full/10.1057/palgrave.jors.2602499>

- [38] Conforti, D., Guerriero, F., Guido, R.: Optimization models for radiotherapy patient scheduling. *4OR* **6**(3), 263–278 (2008). DOI 10.1007/s10288-007-0050-8. URL <http://link.springer.com/10.1007/s10288-007-0050-8>
- [39] Conforti, D., Guerriero, F., Guido, R., Cerinic, M.M., Conforti, M.L.: An optimal decision making model for supporting week hospital management. *Health Care Manag Sci* **14**(1), 74–88 (2011). DOI 10.1007/s10729-010-9144-5. URL <http://link.springer.com/10.1007/s10729-010-9144-5>
- [40] Costa, A.X., Ridley, S.A., Shahani, A.K., Harper, P.R., De Senna, V., Nielsen, M.S.: Mathematical modelling and simulation for planning critical care capacity*: Planning critical care capacity. *Anaesthesia* **58**(4), 320–327 (2003). DOI 10.1046/j.1365-2044.2003.03042.x. URL <http://doi.wiley.com/10.1046/j.1365-2044.2003.03042.x>
- [41] Coté, M.: Understanding Patient Flow. *Decision Line* **33**, 8–10 (2000)
- [42] Côté, M.J.: Patient flow and resource utilization in an outpatient clinic. *Socio-Economic Planning Sciences* **33**(3), 231–245 (1999). DOI [https://doi.org/10.1016/S0038-0121\(99\)00007-5](https://doi.org/10.1016/S0038-0121(99)00007-5). URL <https://www.sciencedirect.com/science/article/pii/S0038012199000075>
- [43] Dai, J.G., Shi, P.: Inpatient Overflow: An Approximate Dynamic Programming Approach. *M&SOM* **21**(4), 894–911 (2019). DOI 10.1287/msom.2018.0730. URL <http://pubsonline.informs.org/doi/10.1287/msom.2018.0730>
- [44] Davis, S., Fard, N.: Theoretical bounds and approximation of the probability mass function of future hospital bed demand. *Health Care Management Science* (2018). DOI 10.1007/s10729-018-9461-7. URL <http://link.springer.com/10.1007/s10729-018-9461-7>
- [45] Demeester, P., Souffriau, W., De Causmaecker, P., Vanden Berghe, G.: A hybrid tabu search algorithm for automatically assigning patients to beds. *AIIM* **48**(1), 61–70 (2010). DOI 10.1016/j.artmed.2009.09.001. URL <http://linkinghub.elsevier.com/retrieve/pii/S0933365709001341>
- [46] Devapriya, P., Strömblad, C.T.B., Bailey, M.D., Frazier, S., Bulger, J., Kemberling, S.T., Wood, K.E.: StratBAM: A Discrete-Event Simulation Model to Support Strategic Hospital Bed Capacity Decisions. *J*

- Med Syst **39**(10), 130 (2015). DOI 10.1007/s10916-015-0325-0. URL <http://link.springer.com/10.1007/s10916-015-0325-0>
- [47] Diamant, A., Milner, J., Queresby, F.: Dynamic Patient Scheduling for Multi-Appointment Health Care Programs. *Production and Operations Management* **27**(1), 58–79 (2018). DOI 10.1111/poms.12783. URL <http://doi.wiley.com/10.1111/poms.12783>
- [48] Domschke, W. (ed.): *Logistik. 1: Transport: Grundlagen, lineare Transport- und Umladeprobleme / von Wolfgang Domschke, 5., überarb. Aufl. edn.* Oldenbourg, München Wien (2007)
- [49] Domschke, W., Drexl, A., Klein, R., Scholl, A.: *Einführung in Operations Research.* Springer Berlin Heidelberg, Berlin, Heidelberg (2015). DOI 10.1007/978-3-662-48216-2. URL <https://link.springer.com/10.1007/978-3-662-48216-2>
- [50] Drucker, P.F.: They're Not Employees, They're People. *Harvard Business Review* **80**(2), 70–77 (2002)
- [51] Eldabi, T., Paul, R.J., Young, T.: Simulation modelling in healthcare: reviewing legacies and investigating futures. *Journal of the Operational Research Society* **58**(2), 262–270 (2007). DOI 10.1057/palgrave.jors.2602222. URL <https://www.tandfonline.com/doi/full/10.1057/palgrave.jors.2602222>
- [52] Freeman, N., Zhao, M., Melouk, S.: An iterative approach for case mix planning under uncertainty. *Omega* **76**, 160–173 (2018). DOI 10.1016/j.omega.2017.04.006. URL <http://linkinghub.elsevier.com/retrieve/pii/S0305048316304029>
- [53] Gartner, D., Kolisch, R.: Scheduling the hospital-wide flow of elective patients. *European Journal of Operational Research* **233**(3), 689–699 (2014). DOI 10.1016/j.ejor.2013.08.026. URL <https://linkinghub.elsevier.com/retrieve/pii/S0377221713006917>
- [54] Gartner, D., Padman, R.: Flexible hospital-wide elective patient scheduling. *Journal of the Operational Research Society* pp. 1–15 (2019). DOI 10.1080/01605682.2019.1590509. URL <https://www.tandfonline.com/doi/full/10.1080/01605682.2019.1590509>

- [55] Gebhard, M.: Hierarchische Produktionsplanung bei Unsicherheit. Gabler, Wiesbaden (2009). DOI 10.1007/978-3-8349-8227-8. URL <http://link.springer.com/10.1007/978-3-8349-8227-8>
- [56] Gedik, R., Zhang, S., Rainwater, C.: Strategic level proton therapy patient admission planning: a Markov decision process modeling approach. *Health Care Management Science* **20**(2), 286–302 (2017). DOI 10.1007/s10729-016-9354-6. URL <http://link.springer.com/10.1007/s10729-016-9354-6>
- [57] Ghasemi, M., Amyot, D.: Process mining in healthcare: a systematised literature review. *IJEH* **9**(1), 60 (2016). DOI 10.1504/IJEH.2016.078745. URL <http://www.inderscience.com/link.php?id=78745>
- [58] Günal, M.M., Pidd, M.: Discrete event simulation for performance modelling in health care: a review of the literature. *JOS* **4**(1), 42–51 (2010). DOI 10.1057/jos.2009.25. URL <https://www.tandfonline.com/doi/full/10.1057/jos.2009.25>
- [59] Gocgun, Y.: Simulation-based approximate policy iteration for dynamic patient scheduling for radiation therapy. *Health Care Management Science* **21**(3), 317–325 (2018). DOI 10.1007/s10729-016-9388-9. URL <http://link.springer.com/10.1007/s10729-016-9388-9>
- [60] Goldratt, E.M., Cox, J.: *The Goal*. North River Press (2004)
- [61] Gorunescu, F., McClean, S., Millard, P.: A queueing model for bed-occupancy management and planning of hospitals. *Journal of the Operational Research Society* **53** (2002)
- [62] Gove, D., Hewett, D., Shahani, A.: Towards a model for hospital case-load decision support. *Math Med Biol* **12**(3-4), 329–338 (1995). DOI 10.1093/imammb/12.3-4.329. URL <https://academic.oup.com/imammb/article-lookup/doi/10.1093/imammb/12.3-4.329>
- [63] Green, L.V.: Capacity Planning and Management in Hospitals. In: M.L. Brandeau, F. Sainfort, W.P. Pierskalla (eds.) *Operations Research and Health Care*, vol. 70, pp. 15–41. Kluwer Academic Publishers, Boston (2005). DOI 10.1007/1-4020-8066-2_2. URL http://link.springer.com/10.1007/1-4020-8066-2_2. Series Title: International Series in Operations Research & Management Science

- [64] Green, L.V., Nguyen, V.: Strategies for Cutting Hospital Beds: The Impact on Patient Service. *Health Services Research* **36**(2) (2001)
- [65] Griffin, J., Xia, S., Peng, S., Keskinocak, P.: Improving patient flow in an obstetric unit. *Health Care Manag Sci* **15**(1), 1–14 (2012). DOI 10.1007/s10729-011-9175-6. URL <http://link.springer.com/10.1007/s10729-011-9175-6>
- [66] Guido, R., Groccia, M.C., Conforti, D.: An efficient metaheuristic for offline patient-to-bed assignment problems. *European Journal of Operational Research* **268**(2), 486–503 (2018). DOI 10.1016/j.ejor.2018.02.007. URL <http://linkinghub.elsevier.com/retrieve/pii/S0377221718301218>
- [67] Guido, R., Solina, V., Conforti, D.: Offline Patient Admission Scheduling Problems. In: A. Sforza, C. Sterle (eds.) *Optimization and Decision Science: Methodologies and Applications*, vol. 217, pp. 129–137. Springer International Publishing, Cham (2017). DOI 10.1007/978-3-319-67308-0_14. URL http://link.springer.com/10.1007/978-3-319-67308-0_14
- [68] Gunal, M.M.: A guide for building hospital simulation models. *Health Systems* **1**(1), 17–25 (2012). DOI 10.1057/hs.2012.8. URL <https://www.tandfonline.com/doi/full/10.1057/hs.2012.8>
- [69] Hall, R., Belson, D., Murali, P.: Modelling Patient Flows through the Healthcare System. In: *Patient Flow: Reducing Delay in Healthcare Delivery*. Springer Science and Business Media, New York, NY (2013)
- [70] Hammouri, A.I., Alrifai, B.: Investigating Biogeography-Based Optimisation for Patient Admission Scheduling. *Journal of Theoretical & Applied Information Technology* **70**(3) (2014)
- [71] Harper, P.: Planning health services with explicit geographical considerations: a stochastic location?allocation approach. *Omega* **33**(2), 141–152 (2005). DOI 10.1016/j.omega.2004.03.011. URL <https://linkinghub.elsevier.com/retrieve/pii/S0305048304000593>
- [72] Harper, P.R.: A Framework for Operational Modelling of Hospital Resources. *Health Care Management Science* **5** (2002)

- [73] Harper, P.R., Shahani, A.K.: Modelling for the planning and management of bed capacities in hospitals. *J Oper Res Soc* **53**(1), 11–18 (2002). DOI 10.1057/palgrave/jors/2601278. URL <http://www.palgrave-journals.com/doi/10.1057/palgrave/jors/2601278>
- [74] Harris, R.: Hospital bed requirements planning. *European Journal of Operational Research* **25**(1), 121–126 (1986). DOI 10.1016/0377-2217(86)90121-9. URL <https://linkinghub.elsevier.com/retrieve/pii/0377221786901219>
- [75] Helbig, K.: Zeitplanung für Patientenpfade unter Berücksichtigung von Betten-, Behandlungskapazitäten und Fairnesskriterien. In: 15. Interuniversitäres Doktorandenseminar Wirtschaftsinformatik der Universitäten Chemnitz, Dresden, Freiberg, Halle-Wittenberg, Jena und Leipzig, p. 83 (2011)
- [76] Helbig, K.: Ein datengetriebenes System auf Basis klinischer Pfade zur Entscheidungsunterstützung für Ressourcenplanung in Krankenhäusern: Prozess-Mining, Optimierung und Simulation. Ph.D. thesis, Martin-Luther-Universität Halle-Wittenberg, Halle (2016)
- [77] Helbig, K., Mellouli, T., Stoeck, T., Gragert, M., Jahn, P.: Simulation stationsübergreifender Patientenflüsse zur Evaluation flexibler Bettenbelegungsszenarien aufgrund der Jahresdatenanalyse eines Universitätsklinikums. In: Tagungsband der Multikonferenz Wirtschaftsinformatik 2014, pp. 749–762. Paderborn (2014)
- [78] Helbig, K., Römer, M., Mellouli, T.: A Clinical Pathway Mining Approach to Enable Scheduling of Hospital Relocations and Treatment Services. In: H.R. Motahari-Nezhad, J. Recker, M. Weidlich (eds.) *Business Process Management*, vol. 9253, pp. 242–250. Springer International Publishing, Cham (2015). DOI 10.1007/978-3-319-23063-4_17. URL http://link.springer.com/10.1007/978-3-319-23063-4_17. Series Title: Lecture Notes in Computer Science
- [79] Helbig, K., Stoeck, T., Mellouli, T.: A Generic Simulation-Based DSS for Evaluating Flexible Ward Clusters in Hospital Occupancy Management. In: *Proceedings of the 48th Annual Hawaii International Conference on System Sciences*, pp. 2923–2932. IEEE (2015). DOI 10.1109/HICSS.2015.354. URL <http://ieeexplore.ieee.org/document/7070169/>

- [80] Hentschker, C., Mennicken, R.: The Volume-Outcome Relationship Revisited: Practice Indeed Makes Perfect. *Health Serv Res* **53**(1), 15–34 (2018). DOI 10.1111/1475-6773.12696. URL <https://onlinelibrary.wiley.com/doi/10.1111/1475-6773.12696>
- [81] Hershey, J.C., Weiss, E.N., Cohen, M.A.: A Stochastic Service Network Model with Application to Hospital Facilities. *Operations Research* **29**(1), 1–22 (1981). DOI 10.1287/opre.29.1.1. URL <http://pubsonline.informs.org/doi/10.1287/opre.29.1.1>
- [82] Hevner, A., Chatterjee, S.: Design Science Research in Information Systems. In: *Design Research in Information Systems*, vol. 22, pp. 9–22. Springer US, Boston, MA (2010). DOI 10.1007/978-1-4419-5653-8_2. URL http://link.springer.com/10.1007/978-1-4419-5653-8_2. Series Title: *Integrated Series in Information Systems*
- [83] Holler, T., Conen, D.: Kostenbasierte Behandlungspfade. In: *Erfolgreiches Changemanagement im Krankenhaus*, pp. 167–179. Springer Berlin Heidelberg (2006). DOI 10.1007/3-540-37208-3_11. URL http://link.springer.com/10.1007/3-540-37208-3_11
- [84] Holler, T., Conen, D.: Prozessorientierung – Analyse und Optimierung von Wertschöpfungsprozessen. In: D.M. Albrecht, A. Töpfer (eds.) *Handbuch Changemanagement im Krankenhaus*, pp. 217–228. Springer Berlin Heidelberg, Berlin, Heidelberg (2017). DOI 10.1007/978-3-642-20362-6_14. URL http://link.springer.com/10.1007/978-3-642-20362-6_14
- [85] Huang, Z., Dong, W., Ji, L., Gan, C., Lu, X., Duan, H.: Discovery of clinical pathway patterns from event logs using probabilistic topic models. *Journal of Biomedical Informatics* **47**(1), 39–57 (2014). DOI 10.1016/j.jbi.2013.09.003. URL <https://linkinghub.elsevier.com/retrieve/pii/S1532046413001445>
- [86] Huang, Z., Lu, X., Duan, H.: On mining clinical pathway patterns from medical behaviors. *Artificial Intelligence in Medicine* **56**(1), 35–50 (2012). DOI 10.1016/j.artmed.2012.06.002. URL <https://linkinghub.elsevier.com/retrieve/pii/S0933365712000656>
- [87] Hulshof, P.J.H., Kortbeek, N., Boucherie, R.J., Hans, E.W., Bakker, P.J.M.: Taxonomic classification of planning decisions in health care: a structured

- review of the state of the art in OR/MS. *Health Systems* **1**(2), 129–175 (2012). DOI 10.1057/hs.2012.18. URL <https://www.tandfonline.com/doi/full/10.1057/hs.2012.18>
- [88] Izady, N., Mohamed, I.: A Clustered Overflow Configuration of Inpatient Beds in Hospitals. *M&SOM* **23**(1), 139–154 (2021). DOI 10.1287/msom.2019.0820. URL <http://pubsonline.informs.org/doi/10.1287/msom.2019.0820>
- [89] Jacobson, S.H., Hall, S.N., Swisher, J.R.: Discrete-Event Simulation Of Health Care Systems. In: *Patient Flow: Reducing Delay in Healthcare Delivery*, pp. 211–252. Springer (2006)
- [90] Jun, J., Jacobson, S., Swisher, J.: Application of discrete-event simulation in health care clinics: A survey. *Journal of the Operational Research Society* **50**, 15 (1999)
- [91] für Justiz, B.: Gesetz über die Entgelte für voll- und teilstationäre Krankenhausleistungen (2002). URL <https://www.gesetze-im-internet.de/khentgg/BJNR142200002.html>
- [92] Kadri, F., Chaabane, S., Tahon, C.: A simulation-based decision support system to prevent and predict strain situations in emergency department systems. *Simulation Modelling Practice and Theory* **42**, 32–52 (2014). DOI 10.1016/j.simpat.2013.12.004. URL <https://linkinghub.elsevier.com/retrieve/pii/S1569190X13001767>
- [93] Kaymak, U., Mans, R., van de Steeg, T., Dierks, M.: On Process Mining in Health Care. In: *IEEE International Conference on Systems, Man, and Cybernetics*, p. 6 (2012)
- [94] Kelton, D.: Statistical Analysis of Simulation Output. In: *Proceedings of the 1997 Winter Simulation Conference* (1997). URL <https://dl.acm.org/doi/pdf/10.1145/268437.268443>
- [95] Keskinocak, P., Savva, N.: A Review of the Healthcare-Management (Modeling) Literature Published in *Manufacturing & Service Operations Management*. *M&SOM* **22**(1), 59–72 (2020). DOI 10.1287/msom.2019.0817. URL <http://pubsonline.informs.org/doi/10.1287/msom.2019.0817>

- [96] Kifah, S., Abdullah, S.: An adaptive non-linear great deluge algorithm for the patient-admission problem. *Information Sciences* **295**, 573–585 (2015). DOI 10.1016/j.ins.2014.10.004. URL <http://linkinghub.elsevier.com/retrieve/pii/S0020025514009839>
- [97] Kim, S.C., Horowitz, I., Young, K.K., Buckley, T.A.: Analysis of capacity management of the intensive care unit in a hospital. *European Journal of Operational Research* **115**(1), 36–46 (1999). DOI 10.1016/S0377-2217(98)00135-0. URL <https://linkinghub.elsevier.com/retrieve/pii/S0377221798001350>
- [98] Klein, R.W., Dittus, R.S., Roberts, S.D., Wilson, J.R.: Simulation Modeling and Health-care Decision Making. *Med Decis Making* **13**(4), 347–354 (1993). DOI 10.1177/0272989X9301300411. URL <http://journals.sagepub.com/doi/10.1177/0272989X9301300411>
- [99] Kolker, A.: Interdependency of Hospital Departments and Hospital-Wide Patient Flows. In: *Patient Flow: Reducing Delay in Healthcare Delivery*, p. 21. Springer, New York (2013)
- [100] für das Entgeltsystem im Krankenhaus GmbH, I.: aG-DRG German Diagnosis Related Groups (2021). URL https://www.g-drg.de/content/download/11047/file/DefHandbuch_aGDRG_2022_Band1.pdf
- [101] Kuo, Y.H., Leung, J.M., Graham, C.A., Tsoi, K.K., Meng, H.M.: Using simulation to assess the impacts of the adoption of a fast-track system for hospital emergency services. *Journal of Advanced Mechanical Design, Systems, and Manufacturing* **12**(3), JAMDSM0073–JAMDSM0073 (2018). DOI 10.1299/jamdsm.2018jamdsm0073. URL https://www.jstage.jst.go.jp/article/jamdsm/12/3/12_2018jamdsm0073/_article
- [102] Lamothe, L., Dufour, Y.: Systems of interdependency and core orchestrating themes at health care unit level. *Public Management Review* **9**(1), 67–85 (2007). DOI 10.1080/14719030601181225. URL <https://doi.org/10.1080/14719030601181225>. Publisher: Routledge_eprint: <https://doi.org/10.1080/14719030601181225>
- [103] Landa, P., Sonnessa, M., Tanfani, E., Testi, A.: Multiobjective bed management considering emergency and elective patient flows. *International Transactions in Operational Research* **25**(1), 20 (2018)

- [104] Launay, C., Rivière, H., Kabeshova, A., Beauchet, O.: Predicting prolonged length of hospital stay in older emergency department users: Use of a novel analysis method, the Artificial Neural Network. *European Journal of Internal Medicine* **26**(7), 478–482 (2015). DOI 10.1016/j.ejim.2015.06.002. URL <http://linkinghub.elsevier.com/retrieve/pii/S0953620515002071>
- [105] Lauterbach, K., Bollschweiler, E., Lauterbach-Lüngen-Schrappé: *Gesundheitsökonomie, Management und Evidence-based Medicine: Handbuch für Praxis, Politik und Studium*. Schattauer, Stuttgart (2010)
- [106] Law, A.M.: *Simulation Modeling and Analysis*, 5 edn. McGraw-Hill Education, New York (2015)
- [107] Levine, W.C., Dunn, P.F.: Optimizing operating room scheduling. *Anesthesiology clinics* **33**(4), 697–711 (2015). Publisher: Elsevier
- [108] Littig, S.J., Isken, M.W.: Short term hospital occupancy prediction. *Health Care Manage Sci* **10**(1), 47–66 (2007). DOI 10.1007/s10729-006-9000-9. URL <http://link.springer.com/10.1007/s10729-006-9000-9>
- [109] Luft, H.S., Hunt, S.S., Maerki, S.C.: The Volume-Outcome Relationship: Practice-Makes-Perfect or Selective-Referral Patterns? *Health Services Research* **22**(2) (1987)
- [110] Luo, L., Liu, C., Feng, L., Zhao, S., Gong, R.: A random forest and simulation approach for scheduling operation rooms: Elective surgery cancelation in a Chinese hospital urology department. *The International Journal of Health Planning and Management* (2018). DOI 10.1002/hpm.2552. URL <http://doi.wiley.com/10.1002/hpm.2552>
- [111] Luo, L., Luo, L., Zhang, X., He, X.: Hospital daily outpatient visits forecasting using a combinatorial model based on ARIMA and SES models. *BMC Health Services Research* **17**(1) (2017). DOI 10.1186/s12913-017-2407-9. URL <http://bmchealthservres.biomedcentral.com/articles/10.1186/s12913-017-2407-9>
- [112] Lusby, R.M., Schwierz, M., Range, T.M., Larsen, J.: An adaptive large neighborhood search procedure applied to the dynamic patient admission scheduling problem. *Artificial Intelligence in Medicine* **74**, 21–31

- (2016). DOI 10.1016/j.artmed.2016.10.002. URL <http://linkinghub.elsevier.com/retrieve/pii/S09333365716300926>
- [113] Mackay, M., Lee, M.: Choice of models for the analysis and forecasting of hospital beds. *Health Care Management Science* **8**(3), 221–230 (2005)
- [114] Manktelow, M., Iftikhar, A., Bucholc, M., McCann, M., O’Kane, M.: Clinical and operational insights from data-driven care pathway mapping: a systematic review. *BMC Med Inform Decis Mak* **22**(1), 43 (2022). DOI 10.1186/s12911-022-01756-2. URL <https://bmcmmedinformdecismak.biomedcentral.com/articles/10.1186/s12911-022-01756-2>
- [115] Manson, N.: Is operations research really research? *ORiON* **22**(2) (2006). DOI 10.5784/22-2-40. URL <http://orion.journals.ac.za/pub/article/view/40>
- [116] Marckmann, G.: Zwischen Skylla und Charybdis: Reformoptionen im Gesundheitswesen aus ethischer Perspektive. *Gesundh ökon Qual manag* **12**(2), 96–100 (2007). DOI 10.1055/s-2007-962907. URL <http://www.thieme-connect.de/DOI/DOI?10.1055/s-2007-962907>
- [117] Marynissen, J., Demeulemeester, E.: Literature review on integrated hospital scheduling problems. Publisher: KU Leuven, Faculty of Economics and Business (FEB), Department of Decision ... (2016). Publisher: KU Leuven, Faculty of Economics and Business (FEB), Department of Decision ...
- [118] Marynissen, J., Demeulemeester, E.: Literature review on multi-appointment scheduling problems in hospitals. *European Journal of Operational Research* **272**(2), 407–419 (2019). DOI 10.1016/j.ejor.2018.03.001. URL <https://linkinghub.elsevier.com/retrieve/pii/S0377221718302108>
- [119] Maschler, J., Hackl, T., Riedler, M., Raidl, G.R.: An Enhanced Iterated Greedy Metaheuristic for the Particle Therapy Patient Scheduling Problem. *MIC/MAEB* p. 10 (2017)
- [120] Maschler, J., Raidl, G.R.: Particle therapy patient scheduling with limited starting time variations of daily treatments. *International Transactions in Operational Research* (2018). DOI 10.1111/itor.12579. URL <http://doi.wiley.com/10.1111/itor.12579>

- [121] Masmoudi, M., Chalgham, M., Ben Houria, Z.: Fuzzy Decision Making for Inpatient Boarding: Case of a Tunesian Hospital. *International Journal of Industrial Engineering: Theory, Applications and Practice* **25**(3) (2018)
- [122] Masterson, B.J., Mihara, T.G., Miller, G., Randolph, S.C., Forkner, M.E., Crouter, A.L.: Using Models and Data to Support Optimization of the Military Health System: A Case Study in an Intensive Care Unit. *Health Care Management Science* **7**(3), 217–224 (2004). DOI 10.1023/B:HCMS.0000039384.92373.c4. URL <http://link.springer.com/10.1023/B:HCMS.0000039384.92373.c4>
- [123] Mellouli, T., Stoeck, T.: AI/OR Synergies of Process Mining with optimal Plnning of Patient Pathways for Effective Hospital-Wide Decision Support. In: M. Masmoudi, B. Jarboui, P. Siarry (eds.) *Artificial Intelligence and Data Mining in Healthcare*, 1 edn. Springer International Publishing (2021)
- [124] Mielczarek, B.: Review of modelling approaches for healthcare simulation. *Operations Research and Decisions* **26**(1), 55–72 (2016). DOI 10.5277/ORD160104. URL <http://www.orduser.pwr.wroc.pl/DownloadFile.aspx?aid=1196>. Medium: PDF Publisher: Wrocław University of Technology, Wrocław University of Economics, Polish Operational and Systems Research Society
- [125] M.J. Coté: A note on Bed allocation techniques based on census data. *Socio-Economic Planning Sciences* **39**(2) (2005)
- [126] Mustafee, N., Katsaliaki, K., Taylor, S.J.: Profiling Literature in Healthcare Simulation. *SIMULATION* **86**(8-9), 543–558 (2010). DOI 10.1177/0037549709359090. URL <http://journals.sagepub.com/doi/10.1177/0037549709359090>
- [127] Nguyen, J., Six, P., Antonioli, D., Glemain, P., Potel, G., Lombrail, P., Le Beux, P.: A simple method to optimize hospital beds capacity. *International Journal of Medical Informatics* **74**(1), 39–49 (2005). DOI 10.1016/j.ijmedinf.2004.09.001. URL <https://linkinghub.elsevier.com/retrieve/pii/S1386505604001856>
- [128] Nguyen, J.M., Six, P., Parisot, R., Antonioli, D., Nicolas, F., Lombrail, P.: A universal method for determining intensive care unit bed requirements. In-

- tensive Care Med **29**(5), 849–852 (2003). DOI 10.1007/s00134-003-1725-z. URL <http://link.springer.com/10.1007/s00134-003-1725-z>
- [129] Ogulata, S.N., Koyuncu, M., Karakas, E.: Personnel and Patient Scheduling in the High Demanded Hospital Services: A Case Study in the Physiotherapy Service. *Journal of Medical Systems* **32**(3), 221–228 (2008). DOI 10.1007/s10916-007-9126-4. URL <http://link.springer.com/10.1007/s10916-007-9126-4>
- [130] Papi, M., Pontecorvi, L., Setola, R., Clemente, F.: Stochastic Dynamic Programming in Hospital Resource Optimization. In: A. Sforza, C. Sterle (eds.) *Optimization and Decision Science: Methodologies and Applications*, vol. 217, pp. 139–147. Springer International Publishing, Cham (2017). DOI 10.1007/978-3-319-67308-0_15. URL http://link.springer.com/10.1007/978-3-319-67308-0_15
- [131] Patrick, J., Puterman, M.L., Queyranne, M.: Dynamic Multipriority Patient Scheduling for a Diagnostic Resource. *Operations Research* **56**(6), 1507–1525 (2008). DOI 10.1287/opre.1080.0590. URL <http://pubsonline.informs.org/doi/abs/10.1287/opre.1080.0590>
- [132] Paulussen, T.O., Jennings, N.R., Decker, K.S., Heinzl, A.: Distributed Patient Scheduling in Hospitals. In: *Proceedings of the 18th international joint conference on Artificial Intelligence*, p. 6 (2003)
- [133] Pegden, C.D.: Simio: A new simulation system based on intelligent objects. In: *2007 Winter Simulation Conference*, pp. 2293–2300. IEEE, Washington, DC, USA (2007). DOI 10.1109/WSC.2007.4419867. URL <http://ieeexplore.ieee.org/document/4419867/>
- [134] Pegden, C.D.: Introduction to SIMIO. In: *Proceedings of the 2008 Winter Simulation Conference* (2008)
- [135] Perer, A., Wang, F., Hu, J.: Mining and exploring care pathways from electronic medical records with visual analytics. *Journal of Biomedical Informatics* **56**(1), 369–378 (2015). DOI 10.1016/j.jbi.2015.06.020. URL <https://linkinghub.elsevier.com/retrieve/pii/S1532046415001306>
- [136] Persson, M., Persson, J.A.: Health economic modeling to support surgery management at a Swedish hospital. *Omega* **37**(4), 853–863 (2009). DOI 10.

- 1016/j.omega.2008.05.007. URL <http://linkinghub.elsevier.com/retrieve/pii/S0305048308000522>
- [137] Rabin, E., Kocher, K., McClelland, M., Pines, J., Hwang, U., Rathlev, N., Asplin, B., Trueger, N.S., Weber, E.: Solutions To Emergency Department ‘Boarding’ And Crowding Are Underused And May Need To Be Legislated. *Health Affairs* **31**(8), 1757–1766 (2012). DOI 10.1377/hlthaff.2011.0786. URL <http://www.healthaffairs.org/doi/10.1377/hlthaff.2011.0786>
- [138] Range, T.M., Lusby, R.M., Larsen, J.: A column generation approach for solving the patient admission scheduling problem. *European Journal of Operational Research* **235**(1), 252–264 (2014). DOI 10.1016/j.ejor.2013.10.050. URL <http://linkinghub.elsevier.com/retrieve/pii/S0377221713008734>
- [139] Ridge, J., Jones, S., Nielsen, M., Shahani, A.: Capacity planning for intensive care units. *European Journal of Operational Research* **105**(2), 346–355 (1998). DOI 10.1016/S0377-2217(97)00240-3. URL <https://linkinghub.elsevier.com/retrieve/pii/S0377221797002403>
- [140] Roche, K.T., Rivera, D.E., Cochran, J.K.: A control engineering framework for managing whole hospital occupancy. *Mathematical and Computer Modelling* **55**(3-4), 1401–1417 (2012). DOI 10.1016/j.mcm.2011.10.018. URL <https://linkinghub.elsevier.com/retrieve/pii/S0895717711006108>
- [141] Rogge, A.: Die Steuerung des Leistungsprozesses im Krankenhaus. In: U. Vetter, L. Hoffmann (eds.) *Leistungsmanagement im Krankenhaus: G-DRGs*, pp. 107–116. Springer-Verlag, Berlin/Heidelberg (2005). DOI 10.1007/3-540-27366-2_11. URL http://link.springer.com/10.1007/3-540-27366-2_11
- [142] Rojas, E., Munoz-Gama, J., Sepulveda, M., Capurro, D.: Process mining in healthcare: A literature review. *Journal of Biomedical Informatics* p. 13 (2016)
- [143] Sachsen-Anhalt, L.: Landesrecht Sachsen-Anhalt - Landesregierung | Verwaltungsvorschrift (Sachsen-Anhalt) | Beschluss der Landesregierung über den Krankenhausplan ab 1. 12. 2019 | i. d. F. v. 15.06.2021 | gültig ab

- 01.01.2021 (2019). URL <https://www.landesrecht.sachsen-anhalt.de/bsst/document/VVST-VVST000011902>
- [144] Schäfer, F., Walther, M., Hübner, A., Kuhn, H.: Operational patient-bed assignment problem in large hospital settings including overflow and uncertainty management. *Flexible Services and Manufacturing Journal* (2019). DOI 10.1007/s10696-018-9331-0. URL <http://link.springer.com/10.1007/s10696-018-9331-0>
- [145] Schmola, G.: Aufnahmemanagement im Krankenhaus. In: M.A. Pfannstiel, C. Rasche, H. Mehlich (eds.) *Dienstleistungsmanagement im Krankenhaus*, pp. 137–160. Springer Fachmedien Wiesbaden, Wiesbaden (2016). DOI 10.1007/978-3-658-08429-5_7. URL http://link.springer.com/10.1007/978-3-658-08429-5_7
- [146] Schneeweiß, C.: *Planung*. Springer-Lehrbuch. Springer Berlin Heidelberg, Berlin, Heidelberg (1992). DOI 10.1007/978-3-642-58110-6. URL <http://link.springer.com/10.1007/978-3-642-58110-6>
- [147] Schneeweiss, C.: *Distributed Decision Making*. Springer Berlin Heidelberg, Berlin, Heidelberg (2003). DOI 10.1007/978-3-540-24724-1. URL <http://link.springer.com/10.1007/978-3-540-24724-1>
- [148] Schneider, A.J.T., Besselink, P.L., Zonderland, M.E., Boucherie, R.J.: Allocating Emergency Beds Improves the Emergency Admission Flow. *Interfaces* **48**(4), 12 (2018)
- [149] Scholl, A.: *Robuste Planung und Optimierung Grundlagen - Konzepte und Methoden - Experimentelle Untersuchungen*. Physica-Verlag, Heidelberg (2001)
- [150] Schumann, C., Schieber, A., Hilbert, A.: Moderne Entscheidungsunterstützung im Krankenhaus – Business Intelligence meets Healthcare. *HMD* **53**(3), 287–297 (2016). DOI 10.1365/s40702-015-0181-x. URL <http://link.springer.com/10.1365/s40702-015-0181-x>
- [151] Schwarz, K., Römer, M., Mellouli, T.: A data-driven hierarchical MILP approach for scheduling clinical pathways: a real-world case study from a German university hospital. *Bus Res* **12**(2), 597–636 (2019). DOI 10.1007/s40685-019-00102-z. URL <http://link.springer.com/10.1007/s40685-019-00102-z>

- [152] Shahani, A.K., Ridley, S.A., Nielsen, M.S.: Modelling patient flows as an aid to decision making for critical care capacities and organisation. *Anaesthesia* **63**(10), 1074–1080 (2008). DOI 10.1111/j.1365-2044.2008.05577.x. URL <https://onlinelibrary.wiley.com/doi/10.1111/j.1365-2044.2008.05577.x>
- [153] Shannon, R.E.: Introduction to the Art and Science of Simulation. In: *Proceedings of the 1998 Winter Simulation Conference (1998)*. URL https://repository.lib.ncsu.edu/bitstream/handle/1840.4/6120/1998_0002.pdf?sequence=1&isAllowed=y
- [154] Smith, J.S., Sturrock, D.T.: *Simio and Simulation: Modeling, Analysis, Applications*, 6 edn. Simio LLC (2021)
- [155] Song, H., Tucker, A.L., Graue, R., Moravick, S., Yang, J.J.: Capacity Pooling in Hospitals: The Hidden Consequences of Off-Service Placement. *Management Science* **66**(9), 3825–3842 (2020). DOI 10.1287/mnsc.2019.3395. URL <http://pubsonline.informs.org/doi/10.1287/mnsc.2019.3395>
- [156] Song, M., Günther, C.W., van der Aalst, W.M.P.: Trace Clustering in Process Mining. In: D. Ardagna, M. Mecella, J. Yang (eds.) *Business Process Management Workshops*, vol. 17, pp. 109–120. Springer Berlin Heidelberg, Berlin, Heidelberg (2009). DOI 10.1007/978-3-642-00328-8_11. URL http://link.springer.com/10.1007/978-3-642-00328-8_11. Series Title: *Lecture Notes in Business Information Processing*
- [157] Stoeck, T., Mellouli, T.: A two-dimensional categorization scheme for simulation/optimization based decision support in hospitals applied to overall bed management in interdependent wards under flexibility. In: M. Masmoudi, B. Jarboui, P. Siarry (eds.) *Operations Research and Simulation in Healthcare*, 1 edn. Springer International Publishing (2021)
- [158] Suhl, L., Mellouli, T.: *Optimierungssysteme*. Springer Berlin Heidelberg (2006)
- [159] Trinh, Q.D., Bjartell, A., Freedland, S.J., Hollenbeck, B.K., Hu, J.C., Shariat, S.F., Sun, M., Vickers, A.J.: A Systematic Review of the Volume–Outcome Relationship for Radical Prostatectomy. *European Urology* **64**(5), 786–798

- (2013). DOI 10.1016/j.eururo.2013.04.012. URL <https://linkinghub.elsevier.com/retrieve/pii/S0302283813003758>
- [160] Turgeman, L., May, J.H., Sciulli, R.: Insights from a machine learning model for predicting the hospital Length of Stay (LOS) at the time of admission. *Expert Systems with Applications* **78**, 376–385 (2017). DOI 10.1016/j.eswa.2017.02.023. URL <http://linkinghub.elsevier.com/retrieve/pii/S0957417417301057>
- [161] Turhan, A.M., Bilgen, B.: Mixed integer programming based heuristics for the Patient Admission Scheduling problem. *Computers & Operations Research* **80**, 38–49 (2017). DOI 10.1016/j.cor.2016.11.016. URL <http://linkinghub.elsevier.com/retrieve/pii/S0305054816302805>
- [162] Tuschen, K., Trefz, U.: *Krankenhausentgeltgesetz: Kommentar mit einer umfassenden Einführung in die Vergütung stationärer Krankenhausleistungen*, 1 edn. Kohlhammer, Stuttgart (2004)
- [163] Vanberkel, P.T., Boucherie, R.J., Hans, E.W., Hurink, J.L., Litvak, N.: A Survey of Health Care Models that encompass multiple Departments. *International Journal of Health Management and Information* **1**(1), 33 (2010)
- [164] Vancroonenburg, W., Causmaecker, P.D., Spieksma, F., Berghe, G.V.: Scheduling elective patient admissions considering room assignment and operating theatre capacity constraints. In: *Proceedings of the 5th International Conference on Applied Operational Research*, pp. 153–158 (2013)
- [165] Vancroonenburg, W., De Causmaecker, P., Vanden Berghe, G.: Patient-to-room assignment planning in a dynamic context. In: *Proceedings of the 9th International Conference on the Practice and Theory of Automated Timetabling (PATAT-2012)*, pp. 193–208 (2012)
- [166] Vancroonenburg, W., Goossens, D., Spieksma, F.: On the complexity of the patient assignment problem. Tech. rep. (2011). URL <http://allserv.kahosl.be/~wimvc/pas-complexity-techreport.pdf>
- [167] van de Vrugt, N.M., Schneider, A.J., Zonderland, M.E., Stanford, D.A., Boucherie, R.J.: Operations Research for Occupancy Modeling at Hospital Wards and Its Integration into Practice. In: C. Kahraman, Y.I. Topcu (eds.) *Operations Research Applications in Health Care Management*, vol. 262, pp. 101–137. Springer International Publishing, Cham (2018).

- DOI 10.1007/978-3-319-65455-3_5. URL http://link.springer.com/10.1007/978-3-319-65455-3_5. Series Title: International Series in Operations Research & Management Science
- [168] Walczak, S., Pofahl, W.E., Scorpio, R.J.: A decision support tool for allocating hospital bed resources and determining required acuity of care. *Decision support systems* **34**(4), 445–456 (2003)
- [169] Wicke, C., Teichmann, R., Holler, T., Rehder, F., Becker, H.D.: Entwicklung und Einsatz von Patientenpfaden in der Allgemeinchirurgie. *Der Chirurg* **75**(9), 907–915 (2004). DOI 10.1007/s00104-004-0831-y
- [170] Yeon, N., Lee, T., Jang, H.: Outpatients appointment scheduling with multi-doctor sharing resources. In: *Proceedings of the 2010 Winter Simulation Conference*, pp. 3318–3329. IEEE, Baltimore, MD, USA (2010). DOI 10.1109/WSC.2010.5679023. URL <http://ieeexplore.ieee.org/document/5679023/>
- [171] Zaage, J., Heinke, M.: Zeitgemäßes Belegungs- und Entlassungsmanagement. *Trauma Berufskrankh* **20**(S4), 260–264 (2018). DOI 10.1007/s10039-018-0373-z

Anhang

**A. A Two-Dimensional Categorization Scheme
for Simulation / Optimization-Based Decision
Support in Hospitals Applied to Overall Bed
Management in Interdependent Wards Under
Flexibility**

Stoeck, T und Mellouli, T (2021)

In: M. Masmoudi, B. Jarboui, P. Siarry (eds.) Operations Research and Simulation
in Healthcare, 1 edn. Springer International Publishing (2021)

Chapter 1

A Two-Dimensional Categorization Scheme for Simulation/Optimization-Based Decision Support in Hospitals Applied to Overall Bed Management in Interdependent Wards Under Flexibility



Thomas Stoeck and Taïeb Mellouli

Abstract Hospitals are facing unprecedented challenges and economic pressure and therefore forced to find new ways to make their processes more effective and use their resources more efficiently. Our research is based on evaluating flexible usage of narrow resources across departments and wards without resort to high investment. Overall bed management in hospitals is considered for this evaluation.

Focusing on decision support in hospitals, six types of interdependencies concerning, e.g., resource capacities and processes, are discussed. To cope with such complexities, we introduce abstraction levels of demand side around patient pathways as well as supply side concerning resources. Based on this differentiation, we propose a new two-dimensional categorization scheme of resource-related decision problems based on the scope of planning in terms of levels of organizational and functional unit, namely single/multiple pathways, single/multiple wards, and hospital wide, combined with the detailed level of resource planning in terms of granularity for (daily) bed capacities and treatments. An extensive literature review is presented within this scheme in order to link the state-of-the-art to our proposed research.

In simulation studies based on yearly data of a university hospital, we show that some types of interdependencies should be considered in order to get valid results of patient flows. Toward flexibility in resource management, a scenario of temporarily sharing beds of nearby wards showed considerable savings in patient rejection and lengths of stays. This flexibility is evaluated in combination with clustering of wards based on their similarity w.r.t. offered kinds of patient treatments. A case study of hierarchical optimization efficiently integrates daily planning of patient pathways

T. Stoeck (✉) · T. Mellouli

Department of Business Information Systems and Operations Research, Martin-Luther-University Halle-Wittenberg, Halle, Germany

e-mail: thomas.stoeck@wiwi.uni-halle.de; mellouli@wiwi.uni-halle.de

© Springer Nature Switzerland AG 2021

M. Masmoudi et al. (eds.), *Operations Research and Simulation in Healthcare*, https://doi.org/10.1007/978-3-030-45223-0_1

1

as input/instruction for a detailed hourly optimization of treatments. As a general result, it is shown that thinking about flexibility can turn the disadvantages from interdependencies in a capsuled way to advantages in a broader context.

1.1 Introduction

The healthcare system and hospitals are facing unprecedented challenges and particularly a serious economic pressure. In order to survive in this difficult market, hospitals are forced to find new ways to make their processes more effective and use their existing resources more efficiently. Especially, the hospital-wide bed management has a huge impact on the performance of a hospital. A bed is seen as a central resource of a hospital because it is subsuming all following resources like physicians, nurses, operating rooms, and equipment. Without an appropriate bed for patient admission, none of the other resources can be planned or used. Patient numbers are rising because of the demographic change of the society and higher rates of elderly people, while bed capacity is constant or decreasing.

To face these new challenges, a hospital has at least two opportunities. The first opportunity consists of an efficient use of existing bed capacities, which is sometimes crucial to the economic survival of hospitals. Here, computer-assisted decision support systems may help by simulating scenarios of patient flows under high bed utilization (scenarios with higher elective patients' admission and endogenous, stochastically determined emergency patients' rates) and by optimization of operations, patient admission, and pathways under highest rate of resource utilization. However, this may be not enough in case of tight/narrow resources. The second but costly alternative action for a hospital is to invest in new beds and infrastructure in order to increase its capacity, which results in very high costs for acquisition and maintenance. Furthermore, staff costs would rise because the number of beds and the amount of needed staff are linked. Due to enormous economic pressure, this is mostly not possible for hospitals.

Our research is motivated by finding new ways to resolve these challenges and difficulties in case of very narrow hospital resources without resort to high hospital investment. We hereby clearly reject the second opportunity as much as possible and enlarge the applicability of the first opportunity by the idea of flexible use of tight resources in a hospital-wide view. We augment the first opportunity (decision support systems by simulation and optimization) with operational flexibility strategies that especially implement flexibility of resource usage respecting all expert rules and constraints governed by hospital organizational and medical needs. As good overall performance of hospitals directly depends on overall good resource planning, we study interdependencies influencing decision support problems and recognize and discuss different kinds of them.

Optimization and simulation constitute a broad and rich scientific area in healthcare research. With a huge body of literature, an effective categorization scheme is important for organizing current and future research, and additionally,

for recognizing possible research gaps and interesting research questions. Based on our work on synergies between AI methods and optimization [1], we develop a two-dimensional categorization scheme and classify different decision support areas in the recent scientific literature. As a preparation, we present and discuss six different kinds of interdependencies and abstraction levels of resources and patient pathways.

In the practical part of the chapter, we present two different types of case studies using simulation and optimization and then classify the considered decision support problems within our two-dimensional categorization scheme. The considered case studies propose practically feasible ways to implement flexibility strategies aiming at an effective usage of shared or compatible resources. It is shown that disadvantages of interdependencies can be overcome by such flexibility strategies that can be effectively implemented across different organizational units and problem areas. In a retrospective view considering both theory and practice, flexibility strategies in a hospital-wide bed management are evaluated with respect to findings of the current state of implementation and extended for future research steps.

Outline of Chapter The remainder of the book chapter is organized as follows. In the following second section, decision support in hospitals is considered in an overall planning context considering the complexities of the demand side through patient flows and supply side of bed and resource management. We recognize and discuss six different kinds of interdependencies explaining kinds of these complexities surrounding decision support and planning problems in hospitals. In order to manage these interdependencies, we introduce in the third section abstraction levels both of patient flows together with the scope planning and inner hospital resources together with their detailed level of consideration. Based on this differentiation, we propose a new two-dimensional categorization scheme for resource-related decision problems in hospitals. In this scheme presented in the fourth section, a first dimension considers the scope of planning in terms of levels of organizational and functional unit, namely single/multiple pathways, single/multiple wards, and hospital wide, while the second dimension encompasses the detailed level of resource planning in terms of granularity for daily bed capacities and treatments and their aggregation at a weekly, monthly, and yearly basis. Based on this scheme and an extensive literature search, different problem areas of decision support in hospitals are discussed and classified.

In the practical part of this chapter in the fifth section, we present real-life case studies of overall bed management and treatment planning based on own experiments and evaluations using both simulation techniques [2, 3] and mathematical optimization [4]. Our simulation and optimization components operate on concrete types of patient pathways that can be gained by data and process mining components, including special clinical pathway mining algorithms [5]. These case studies promote a possible effective implementation of flexibility in resource usage in overall hospital decision support. Considered flexibility strategies range from sharing beds of nearby wards to clustering strategies of wards based on similarity of treatments offered by clustered wards. Scenario experimentations and evaluations based on real data of a university hospital in our works [2–4] validate our suggestion

that an overall bed management in interdependent wards is crucial for decision support in hospitals.

Furthermore, experimental results show that implementing flexibility in resource usage contributes a winning strategy for hospitals. The crucial importance of flexibility in hospital decision support together with ideas about clustering and quasi-cluster is presented in the first African conference on operations research [6]. In the sixth section, flexibility strategies are considered in their own, and their impact is discussed based on the state of experimentation and evaluation. After showing some research issues in this respect, the chapter is closed by concluding remarks in the seventh section concerning both theoretical and practical findings of our research and development work discussed in this chapter.

1.2 Decision Support in Hospitals with Respect to Overall Planning

Decision support is a broad field, which receives a lot of attention in the scientific literature. In order to discuss hospital decision support and its implication, we describe the basic processes of a hospital with respect to decision support and the possible interdependencies influencing decision support in hospitals will be discussed.

1.2.1 Processes in Hospital Decision Support

In general, decision support through specialized application systems supports the decision maker with models, methods, and problem-related data. Characteristic of decision support systems is the distinctive model and method orientation [7]. For the use in healthcare or in hospitals, an extension of the well-known definition is necessary. Although hospitals are forced to work in a more efficient way due to changing economic conditions, they differ in essential points from classical enterprises. Especially in a hospital, a distinction between core and support processes is made [9]. Unfortunately these processes, as classically presented and classified, are only considered at an organizational point of view that does not reflect the complexity of planning tasks in a hospital. The distinction between core and support processes in [9] neglects the connection between core medical processes and supporting tasks like resource or staff processes from a planning point of view. Because of that we will focus on a missing process consideration in classical approaches by delivering a point of view where planning is a central activity or process in a hospital.

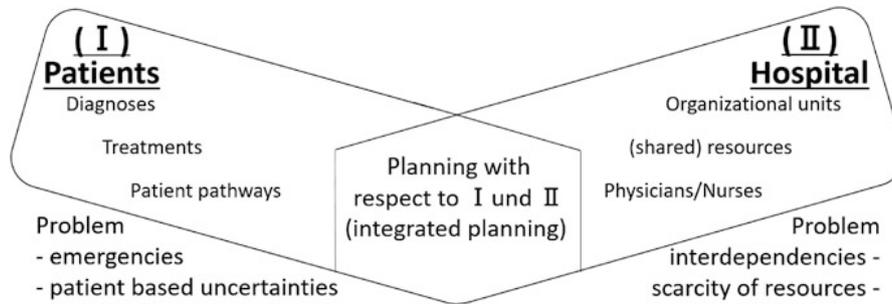


Fig. 1.1 Central planning task in hospitals—I: Demand and II: Supply

In Fig. 1.1 the two main wings of the overall planning perspective of a hospital are shown. In Fig. 1.1 (I) the patient point of view is considered. In general patients are classified via their diagnoses. Based on that, possible treatments are set. Basically a combination of possible treatments is called a patient pathway. The main difficulties arising here are the occurrence of emergencies and patient-based uncertainties like arrival times, different treatment paths and different treatment times. In general wing (I) describes the problem of composing a service, generally represented and identified as a patient pathway, for different patients in order to recreate or to maintain a positive health status. Hereby a first complexity of planning arises by ensuring the combinability of diagnoses, treatments, and other services and the simultaneous consideration of elective and emergency patients.

In Fig. 1.1 (II) the hospital point of view is described. Basically a hospital consists of different organizational units like departments, diagnostic centers, and wards. Furthermore, hospitals have to deal with generally scarce resources, for example, beds and equipment. Additionally, based on the context, shared resources exist, which are used by multiple units at the same time. Moreover, physicians and nurses have to be planned inside wards of a hospital. Besides the scarcity of resources, a main problem within this wing is the existence of interdependencies of different kinds. In this wing a second type of complexity arises by considering the feasibility of a certain patient mix with respect to available resources. In general the main planning task from an operations research perspective for a hospital is located in the intersection between I and II.

Inside this intersection the bed management, as a central connecting decision support task between patient pathways and resources, is located. As stated before, beds are considered as one of the most important resources inside a hospital. Without a proper bed for a patient, no other planning task is possible because every treatment or intervention is linked to a bed for a patient. Basically this means that every resource inside a hospital is subsumed by beds from a planning point of view. Bed and treatment management are strongly interrelated and can be tackled by means of hierarchical optimization [4].

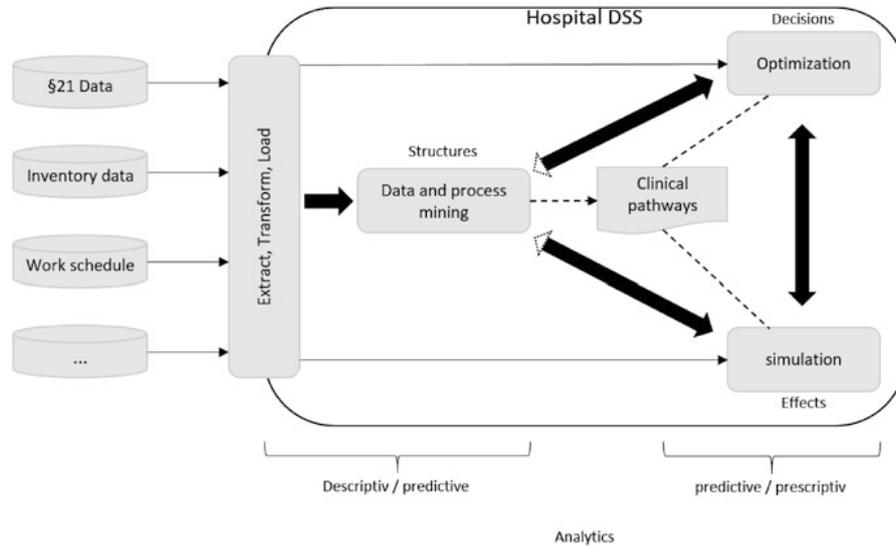


Fig. 1.2 An overall decision support concept for hospitals [8]

Furthermore, all problem areas have a critical demarcation from classical economic decision support. Nearly every decision of a hospital depends on the patient. A patient-centered approach naturally introduces a series of uncertainties into the decision-making process. These uncertainties can be divided into different areas. First, it is difficult to forecast the arrival of patients, especially for emergency patients. In addition, it is difficult to predict the course of treatment of patients [10]. Different diagnoses often result in different treatment paths and, depending on the condition of the patient, different treatment times [11]. These patient-related uncertainties greatly complicate decision-making in a hospital and in healthcare in general. Because of this patient-centered approach, our research team defines a hospital-wide decision support concept based on patient pathways (Fig. 1.2) [8]. Within this concept, optimization is used to perform decisions and simulation studies on the effects of these decisions. Furthermore this concept combines techniques of data/process mining, optimization, and simulation to enable new ways of decision-making.

In addition to the uncertainties, interdependencies between individual organizational units of a hospital have a great influence on the complexity of the decision-making process and provide interesting questions and use cases for researchers and practitioners. Furthermore, we integrate flexibility strategies of resource usage in our experiments. These are evaluated in our case studies presented in Sect. 1.5 and further discussed in Sect. 1.6.

1.2.2 *Types of Interdependencies in Hospital Processes and Decisions*

Interdependencies generally refer to interactions of at least two actors, processes, or issues. In the current research literature on decision support in hospitals, these interdependencies are not examined and classified in detail. There are a few articles that discuss interdependencies in a hospital. Unfortunately they mostly focus on one kind of interdependencies. So a broad overview about interdependencies is lacking. Furthermore, in most cases researchers state that there are interdependencies and they make assumptions in order to cope with them. Because of that, this section provides a more detailed classification and analysis of possible interdependencies in a hospital. In general, it can be assumed that, depending on the level of abstraction of the decision problem, the nature and influence of interdependencies changes. In many cases, this has a major impact on the modeling of the problem. The more interrelationships are considered, the more complex the problem becomes [12]. In order to discuss interdependencies and their implication for decision problems, we present and propose six main types of interdependencies to their classification inside a hospital (Table 1.1).

Capacity-based interdependencies are characterized by the competition for shared and narrow resources. Basically different patients have a certain demand for the same shared resource like beds or medical equipment [13, 14]. By validating results in our case studies [2, 3] (Sect. 1.5.1), we observed two additional aspects of capacity-based interdependencies respecting room capacity. First, bed capacity in a ward may be shortened by diagnosis and gender mix of patients. Some diagnosis of single patients with communicable diseases may necessitate that a multibed room must be assigned to a single patient. Second, because mixed men/women occupancy is prohibited, a certain gender mix of patients may necessitate that

Table 1.1 Kind of interdependencies in a hospital

No.	Interdependency	Properties
1	Capacity-based	Competition for shared resources A decision has a possible impact on further decisions
2	Process-based	Effects of process improvements are investigated Effects of local optimization depend on the position in the system
3	Functional-based	Arising from treatment of various diagnosis With rising numbers of diagnosis uncertainties increase
4	Staff-based	Employee specialization and hierarchy levels are considered Effects on staff planning and pooling
5	Problem-based	Relation between separate decision problems On the same or on different hierarchical levels
6	Patient-based	Relationship between elective and emergency patients Forecasting of emergencies affects the available capacity for elective patients

not all beds of a ward can be occupied. Additionally this decision has a huge impact on potential treatment capacities. Depending on the diagnosis, different treatments may be necessary. Therefore, a second competition arises by competing for timeslots in specialized units. Therefore, decisions that are good at the bedside level, for example, optimizing the occupancy rate of beds, can have a negative impact on further capacity decision problems on treatment level. Therefore, the capacity bottleneck is pushed just one step further [14]. So optimizing resources for all patient groups at the same time is a complex task [13].

The second type of interdependencies involves the *process-based interdependencies*. These interrelations mainly relate to the effects of process improvements. A hospital can be seen as a so-called downstream system [15]. This means that the flow of patients is primarily directed in one direction. This means that patients enter the hospital via a few facilities, such as a central emergency room, and will be distributed to other facilities. A characteristic of downstream systems is the fact that an isolated view of a domain can have a negative impact on the overall performance of a system. The effects of local optimizations on the overall performance depend on the position of the considered area in the overall system. In particular, process improvements in the main admission facilities lead to problems in the following areas[15].

Functional interdependencies denote the interdependencies that arise from the treatment of various diagnoses or diseases. With a rising number of diseases treated, the uncertainty for the planning process and for capacity supply also increases. Functional units that treat only one disease have little functional interdependence. For such units, standard processes can be developed in order to simplify planning, while units that treat a high number of illnesses need integrated planning solutions to incorporate the interrelationships[16].

The fourth kind of interdependencies is composed of *staff interdependencies* that are dealing with employee specialization and hierarchy levels of workers. Also the effects from staff planning and pooling approaches on other problem areas are covered within this kind of interdependencies [14, 17–19].

The next and mostly neglected but crucial kind of interdependencies covers *problem-based interdependencies*. This kind describes the relation between separate decision tasks. In general combinations of previous interdependencies are possible. For example, when a capacity planning of a ward is performed, the possible consequences for the planning of treatment capacities should be respected. This means that for a particular decision problem the related upstream or downstream problems should be respected in order to achieve results usable in practice. But in a hospital environment it is difficult to characterize upstream and downstream problems. In most cases a decision problem has multiple interdependencies with other decision areas, which have multiple relations on their own.

In connection with the last paragraph a sixth kind of interdependency can be discussed. These kind covers *patient-based interdependencies* between elective patients and emergency patients. From a planning point of view, this is a crucial kind of interdependency on the highest level of planning. The available capacity for elective patients depends on the quality of the forecast of emergency patients. As

every planning task in a hospital is correlated to the amounts of patients, therefore it is crucial for hospital decision support to cope with this kind of interdependency.

1.3 Abstraction Levels of Decision Support in Hospitals

This section examines possible abstraction levels of decision support in a hospital, which are necessary to further classify arising problem areas and decision support applications. First of all, the possibilities of abstraction of patient pathways are discussed. Subsequently, resources are presented as a second type of abstraction.

1.3.1 *First Abstraction: Patient Pathway and Scope of Planning*

According to Bartz (2006), there is no standard definition of patient pathways [20]. From different definitions, the nature and characteristics of a patient's pathway can be discussed. In general, a patient pathway can be understood as an instrument that represents a comprehensive diagnosis-oriented interdisciplinary treatment plan for defined patient groups or a virtual average patient [21], which corresponds to the first column of our two-dimensional scheme. A patient path has two main objectives [22, 23]. On the one hand, qualitative medical goals and, on the other hand, economic efficiency-oriented goals are pursued. These two main goals are usually in conflict with each other, so an efficient solution within the resulting trade-off has to be found as foundation for a good cost management [24]. Pathways can still be understood as an operational version of a guideline [22]. In general a reasonable planning of patient pathways enables the hospital management and medical staff to avoid unnecessary waiting times for patients [25].

The presented definition, however, is aimed more at operational considerations. For this chapter, the definition has to be extended by introducing abstraction levels in the context of patient paths. Regardless of the level of detail, we use the previous definition as an abstract patient pathway (Fig. 1.3a). Further abstraction levels are based on considered organizational units and the number of concurrent or parallel patient pathways. On the second level of abstraction (Fig. 1.3b), all or many abstract patient paths within a ward or functional unit are considered. The special feature is that the different paths compete for shared resources. The third level of abstraction (Fig. 1.4a) considers path groups or multiple paths at an aggregated organizational level, for example, on department or cluster level. The fourth and last level of abstraction (Fig. 1.4b) examines hospital-wide (individual) paths. There are two variants, which are summarized at this level. Path groups or patient-specific paths can be considered.

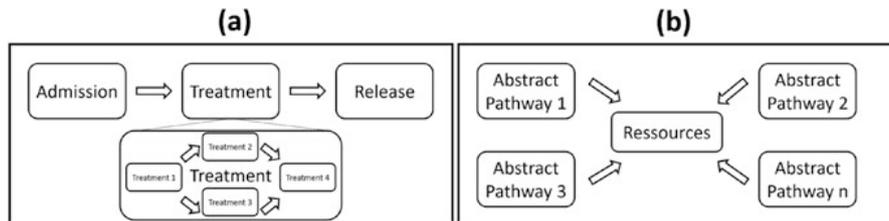


Fig. 1.3 Different abstractions of patient paths at one organizational unit. (a) Abstract path. (b) Many paths

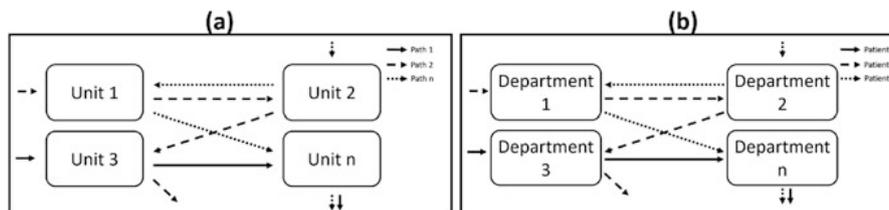


Fig. 1.4 Different abstractions of patient paths at multiple organization units. (a) Department-wide paths. (b) Hospital-wide paths

1.3.2 *Second Abstraction: Resources and Detail Level of Planning*

Another level of abstraction to classify planning problems is the subdivision at resource level. Here, a partition based on the degree of detail of the resource is presented. The most detailed planning level is at treatment level. A treatment is a completed activity that is performed to improve or maintain a patient's state of health. The planning deals with the sequence planning and the chronological planning of individual treatments on a granular level.

The next level of planning is the daily planning of beds or treatment capacities. This is a key requirement for the treatment of patients. Occupancy management is involved in nearly every hospital process [26]. In the literature [27] a bed is considered as one of the most important and expensive resources inside a hospital. Good planning and utilization of existing bed capacity is a prerequisite for fast and smooth treatment of patients. Above all, the daily planning of the beds is considered within this planning level.

Schwarz et al. [4] present bed management and treatment scheduling as a hierarchical interdependent problem. In Fig. 1.5 the integrated planning of the first and the second abstraction levels is shown. So the daily planning of beds is done with respect to a possible planning on treatment level. A more detailed discussion of this interrelated decision task is given in Sect. 1.5.2. For a more strategic planning of bed capacities, the next level of abstraction is used. Here, bed capacities or resource

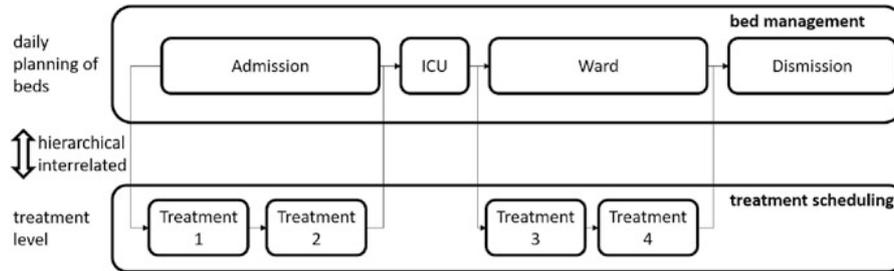


Fig. 1.5 Hierarchical planning of beds and treatments [4]

capacities are planned in an aggregated way over a long period of time. Thus, a strategic planning of capacities can take place here [14].

1.4 Two-Dimensional Categorization Scheme

In order to use the presented abstraction levels to classify problem areas and current research direction, we designed a two-dimensional categorization scheme for simulation- and optimization-based decision support tasks in hospital, which is presented and discussed in Sect. 1.4.1. Within this scheme, a classification of problem areas will be presented in Sect. 1.4.3 and a literature review for certain problem areas shows insights about the current research direction and methods used.

1.4.1 Two-Dimensional Categorization Scheme for Decision Support in Hospitals

As stated in previous sections, decision support via simulation and optimization is a broad research field in various problem areas inside a hospital. A wide range of literature reviews shows that a lot of problem areas inside a hospital exist. In [12] a general overview about using system sciences in health care is given. Based on that, some general problem areas are detected. In [28] different problem definitions regardless of their organizational unit are shown. Additionally two other surveys [29, 30] try to classify problem areas regarding their organizational scope of application. In addition to these general reviews there are several specialized literature reviews that cover different scopes. This scope ranges from operating room scheduling [31] over capacity management [32] to capacity planning [33]. Furthermore, some reviews about different organizational units exist in the current research. There are special problem areas in intensive care [34], emergency departments [35, 36] or in specialized treatment areas like radiation therapy [37]

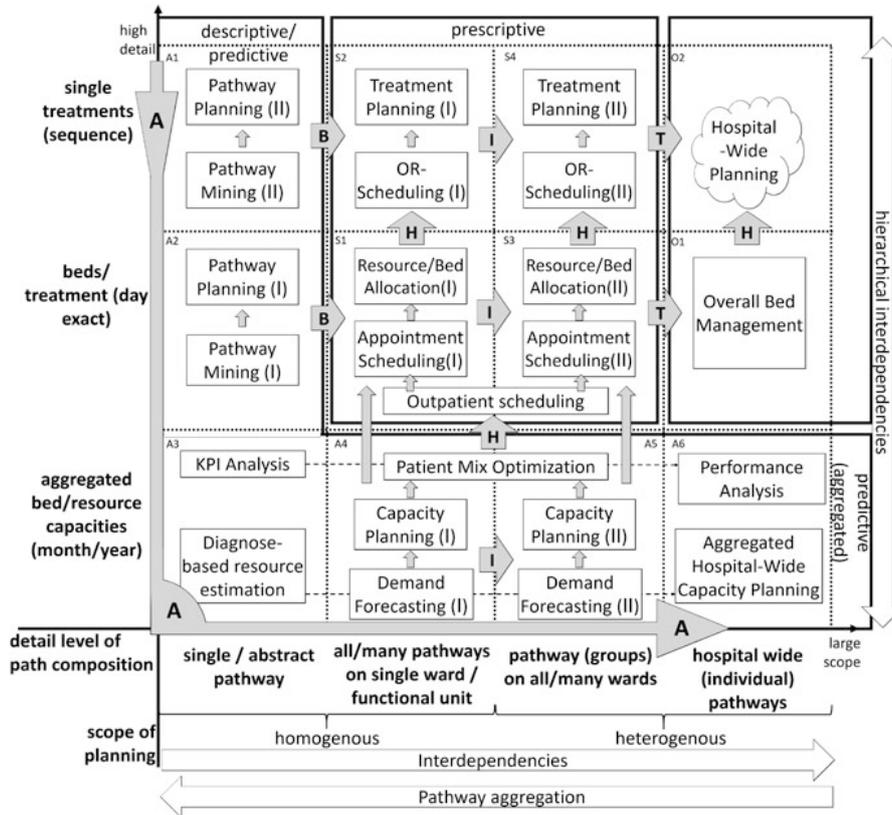


Fig. 1.6 Two-dimensional categorization scheme for decision support in hospitals

or outpatient scheduling in general. It is obvious that there are several review articles. Nevertheless all presented review articles share the same problem. Based on the focus of the review, there is only a categorization based on problem areas or organizational units.

Figure 1.6 shows the developed categorization scheme. Based on the previously presented abstraction levels and problem areas, the categorization scheme is implemented. On the y-axis, the abstraction levels of resources are shown, which represents the supply for any decision problem. The x-axis shows the different aggregation levels of patient pathways as demand side of the decision problem. Thus the scope of planning and basically the type of demand for resource capacity are located on this axis. By investigating the scheme, some general remarks about decision problems and interdependencies in a hospital environment are possible. In general with an increasing path aggregation the influence of interdependencies decreases. Nevertheless these interdependencies do not disappear. They are encoded into the aggregated pathways by making general assumptions. Furthermore an increasing pathway aggregation increases the homogeneity of pathways and patient groups,

which means that the corresponding decision problems do not have to deal with all possible interdependencies. In the opposite direction an increasing heterogeneity can be assumed, which leads to an increasing influence of interdependencies.

The presented scheme makes it possible to combine different types and levels of planning. In principle, planning areas that are oriented toward operational planning can be linked to strategic planning areas. In particular, the possible levels of detail can be described. In Fig. 1.6 it can be seen that quadrants S1, S2, S3, and S4 in the so-called scheduling sector are more oriented toward operational planning, while quadrants A1, A2, A3, A4, A5, and A6 in the analytic sector are more focused on strategic planning. Furthermore quadrants O1 and O2 in the overall planning sector deal with hospital-wide overall planning tasks.

In Fig. 1.6 it is obvious that resources and their considered granularity have a great influence on the specificity of problem areas. With a rising abstraction level of resources, a rising complexity of decision problems is observed. Furthermore a rising complexity results in a more strategical decision problem. While a more abstract view on resources results in more strategical problems, a changing abstraction level of patient paths only has a minor influence on the decision problem itself. However a more detailed view of patient pathways results in a more detailed planning problem inside a problem area.

A possible use of this classification scheme is the identification of subsequent decision tasks and the inclusion of interdependencies and flexibility. This will be shown using the example of the tasks in the area of arrow A in Fig. 1.6. The starting point for a planning consideration of the processes of a hospital is the planning of patient paths on an abstract level. In general, this involves planning the sequence of treatment steps to each diagnosis type. This can be done in two different ways (or in a combination). On the one hand, planning can be carried out by medical experts. Here, expertise and experience are integrated, which can lead to improvements in the treatment process of specific diagnosis types. On the other hand, planning can be based on historical data. Here a more descriptive planning takes place with the help of techniques of data/process mining. However, only the current actual state of the pathways can be mapped. A detailed discussion about pathway mining is done in [5]. By combining these two variants, computer-assisted planning of abstract pathways for different diagnosis can be done.

On the basis of these paths, an initial estimate of the required resources can be made. This is the general basis for capacity planning in a hospital, which can be done along the abstraction levels of the patient pathways in different areas, which are characterized by an increasing scope planning. As a result, planning is increasingly being driven toward hospital-wide planning. In general, it can be stated in advance that a simple summation of individual capacity plans at one level does not necessarily lead to planning at a higher level. Depending on the transition level, different interdependencies and additional constraints have to be considered.

In the transition from “*diagnosis-based bed/resource estimation*” to “*capacity planning (I) (CPI)*” it is not possible to sum up the results of the estimates for the individual diagnoses and to obtain a planning or estimation for the entire ward. In the aggregation, an additional intersection by patient-based interdependencies, i.e.,

the inclusion of gender segregation and the presence of isolation patients, must be reckoned with. Thus, the capacity requirement can be underestimated in a simple aggregation and problems can arise for operational use.

In the transition from “*capacity planning (I)*” to “*capacity planning (II) (CPII)*” further interdependencies have to be considered. In principle, planning in CPI takes place without considering shared resources, which are often planned as fixed resources for a ward. Thus each ward plans the capacity for shared resources separately. This leads to an overestimation of the required capacities. Simplified this can be described by the following formula: $\sum CPI + \alpha > CPII$. A separated planning causes unused resources at wards, which can be used better by integrating flexibility in an interdepartmental planning of (shared) resources. Generally the impact of shared resources is twofold. On the one hand there are passively shared resources like operating rooms or CT-scans. An isolated planning is too optimistic in respect for shared resources. The capacity of passively shared resources can be denoted by α . On the other hand there are actively shared resources like bed pools or staff pools. This kind of resources has to be planned in a flexible way across several wards in order to use their full potential. This flexibility strategies or the so-called flexibility cuts (ϕ) can have a huge impact on capacity planning. To enable a practical transition from CPI to CPII, we introduce the following relation: $\phi \cdot \sum CPI = CPII$ with $\phi < 1$. This makes it possible to expand the focus of planning without overestimating or underestimating the demand. A further advantage of this broader view of planning is the simple expandability to a hospital-wide focus. The transition to hospital-wide planning is not possible from CPI. However, it is much easier to plan hospital-wide from CPII. Since the most important interdependencies are already integrated in CPII, the expansion is done by considering organizational strategies. This results in aggregated predictive planning.

Basically sector A describes a descriptive or predictive approach for strategical hospital planning tasks. These tasks present an input for sector S, which describes a prescriptive view of planning tasks. This input is shown as arrow B in Fig. 1.6. For a hospital this is a crucial connection between strategical and tactical/operational planning areas. A high-quality planning in sector A is a mandatory requirement for the high quality of planning results in sector S. This can be discussed with the example of pathway mining and planning and its implication for sector S. There is a differentiation into three different variants. The first variant is a direct mining approach in A1. So the focus lies on a possible sequence of treatments. A second variant is the aggregation of treatments on a daily level. So not only the sequence is taken into account. Additionally the planned day of treatment inside a patient pathway is important for this mining and planning approach (quadrant A2). A third variant is a new combination of the previous discussed variants proposed by Helbig et al. [5]. This variant aims at the utilization of pathway mining and planning for the more operational scheduling sector. In order to avoid a too narrow set of input parameters for an operational planning, the exact location of each treatment inside a sequence is not important. Furthermore the exact day of treatment is not important either. In order to provide decent input for planning within this variant, only mandatory relations between treatments and a range of possible treatment days

are considered. So this variant provides an appropriate input for other planning tasks without excluding possible solutions by providing too strict input parameters.

Furthermore it is interesting that the proposed scheme is able to link general planning tasks of a hospital with classical business analytics taxonomies. In general sector A engages, depending on the abstraction level, in a descriptive and a predictive analysis. A descriptive analysis deals with the question what happened while a predictive analysis deals with the more strategical question of what will happen. Planning tasks inside sector S can be seen as prescriptive planning of operations with strategic influences and can answer the question what should a hospital do.

1.4.2 Anticipation Issues of Decision Support Problems Within the Two-Dimensional Scheme

In order to emphasize the importance of the categorization scheme, we will present the differences of apparently similar planning problems in varying abstraction levels. First of all the differences between OR-scheduling (I) and OR-scheduling (II) is discussed. I describes the classical operating room scheduling. At this stage only the actual schedule is considered. In general different surgeries are scheduled based on their needed time and their importance. Based on the complexity of the considered problem, several other constraints like physicians' working hours or preparation times are implemented. Unfortunately a consideration of up- and downstream facilities is neglected during this decision task. However, for an operating room schedule suitable for operational use, a consideration of capacities of related units is crucial. By considering related units, a transition between I and II is performed. So the impact of interdependencies between the operating room and the related wards increases. A feasible schedule respects the capacity restrictions on other wards, and the complexity of the planning problem increases significantly but the possibility to transfer the schedule into operational work is increased. Another example is the problem area of appointment scheduling divided into appointment scheduling I and appointment scheduling II. Appointment scheduling (I) describes the task of assigning dates of admission to patients. Here it is important to assign all patients at one ward. Because of the isolated consideration of one ward, an optimal schedule could worsen the performance of other wards and corresponding organizational units. Especially if we assume multiple wards for several patients. Nevertheless this view leads to a demarcated and less complex decision problem regarding interdependencies. In order to decrease the impact of interdependencies between different wards or organizational units, an integrated consideration of multiple units is possible (appointment scheduling II). A scheduling for multiple wards is performed in one step. So a decision at one ward is automatically considered at another unit. So a trade-off between different solutions is found in order to achieve a global optimum. Hence it should be noted that advantages

in an integrated planning lead to problems regarding complexity. So a detailed contemplation of interdependencies should be integrated in order to gain solutions that can be transferred to an operational use.

In general the transition from I to II independently from a problem area leads to a better modelling of interdependencies. So for most of the problem areas the equation $II = I + \text{modelling of Interdependencies}$ holds. Because of its transfer to a larger scope in direction of a global integrated planning (Quadrant O2), it is easier to reach the goal of an integrated planning platform.

Another relationship between planning areas is shown through arrow H in Fig. 1.6. Here a possible hierarchical relationship is described. Furthermore this relationship is described in Fig. 1.5 for the example of appointment scheduling and treatment planning. In a first step a daily planning of beds is performed as an input for a treatment planning. Additionally this treatment planning provides feedback for the bed management. So bed managers are able to adjust their planning based on this relationship. Another interesting hierarchical relationship is located between quadrant A4/A5 and S1/S3. Inside quadrant A4/A5 a connection between demand forecasting, capacity planning, and patient mix optimization is obvious. Based on a good and reliable demand forecast, a good capacity planning can be done. These two planning areas act as an input either for a strategical patient mix optimization or for a operational appointment scheduling and resource allocation. Furthermore patient mix optimization provides a corridor for a possible operational planning. An additional and mostly neglected possibility is the providing of a feedback loop between sector S and quadrants A4/A5. With the help of anticipating techniques for operational planning, a readjustment of strategical decisions based on anticipated operational decisions is possible.

Arrow T in the categorization scheme describes the transition to a hospital-wide planning view. This basically means the enhancement of department-wide planning approaches with organizational characteristics and strategies.

An overall planning view is mainly influenced by overall organizational aspects, for example, organizing pools of resources or managing rearrangements of functional units. Furthermore this includes a possible adjustment of concepts or ideas to changing conditions of a hospital, which can be done in two different ways. First the changes or reorganizations can be done permanently in order to cope with strategical aspects. The second way is the rearrangement in case of emergency situations. For example, if an epidemic outbreak occurs, the hospital management is able to use organizational strategies, which promotes flexibility on the top planning level, which can be an ad hoc rearrangement of nursing staff and physicians or a reallocation of resources.

1.4.3 *Classifying Problem Areas Based on the Categorization Scheme*

For a more detailed categorization, a further literature analysis based on existing reviews and newer additional papers is done to achieve two main goals. First of all we like to achieve a more detailed classification of problem areas. As a second goal an identification of currently unregarded problem areas in operations research is desired.

From [28] it is possible to extract general problem areas for operations research in healthcare (see Fig. 1.7). In general problem areas can be divided into two subsections. First we consider all planning problems. These problems consist of issues about demand forecasting, location planning, capacity planning, and treatment planning. In a second area healthcare management and logistic problems are considered. From an operational point of view, scheduling is an important topic, in detail patient or resource scheduling. Patient scheduling can be divided into inpatient and outpatient scheduling. For resource scheduling a more detailed partition is needed. Hence there is a split into nurse, physician, operating room, and other scheduling problems. For a further classification insights of the review articles and other recent research literature, a two-dimensional division of problem areas based on abstraction levels is needed. The body of literature is scanned based on the described abstraction levels, and their problem areas are included into the two-dimensional categorization scheme. So a relevant map of problem areas is built and described in the next paragraph.

Within these analyses, an evaluation of the current direction of research is possible. Table 1.2 shows a literature review of current scientific contributions mostly published after 2017. For selected problem areas in different quadrants of the categorization scheme, a distinction between optimization- and simulation-based contributions is done. This review is used to point up current research directions in selected problem areas in order to gain general insights. While using

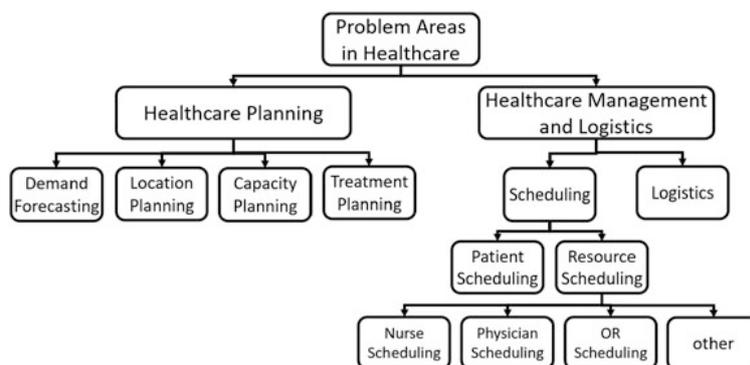


Fig. 1.7 General problem areas in health care

Table 1.2 Assignment from the literature to quadrants and problem areas

Quadrant	Problem area	Optimization	Simulation
S1	Outpatient scheduling	[39–44]	[45, 46]
S1	Appointment scheduling	[13, 49]	[13]
S1	Resource allocation	[50–54]	–
S3	Bed allocation	[55]	
S3	Patient scheduling		[56]
S4	OR-scheduling	[38]	–
A3	Diagnosis-based resource estimation	[47, 48]	–
A3	KPI analysis	–	[59, 62–65]
A4	Capacity planning	[58]	[59–61]
A4 A5	Patient mix optimization	–	[66, 67]
A6	Performance analysis	–	[57, 68–70]
A6	Capacity planning	–	[71]

the presented categorization scheme in combination with Table 1.2, it is obvious that current research is focused on the quadrants located in the left and center of the categorization scheme. Because of that concentration, it is noticeable that in most of the current research interdependencies are left out. Mostly research about single organizational units is done. So a neglect of interdependencies results in a lack of practicality of the investigated decision problems. Furthermore the usage of abstract pathways, which are not fully able to reproduce the behavior of patients, decreases the practicality. So current research activities can be seen as feasibility studies where the last step to a practical implementation is missing because of an insufficient consideration of interdependencies.

Through Table 1.2 another important insight is given. Optimization techniques are mostly used for rather tactical or operational problem areas with more abstract patient paths. For more complex or strategic problem areas, simulation techniques are used. Nevertheless the most important insight from a resource point of view, as stated before, is the concentration on abstract paths and single organizational units. Furthermore most of the scanned literature is focused on single decision problems. Hierarchical interdependencies are mostly left out. In order to discuss a possible usage of interdependencies, two kinds of case studies will be presented in the next section.

1.5 Case Studies in Hospital Decision Support: Flexibility Strategies Coping with Interdependencies

After presenting the categorization scheme and classifying the current research literature, two case studies are presented below, which exploit the positive aspects of interdependencies at different levels of abstraction.

1.5.1 Simulation Case Study

Our research team developed a valid simulation system based on data analysis of one-year data of a university hospital to increase flexibility in bed management [2]. Because of the introduction of the German Diagnosis-Related Group (G-DRG) system, some major changes for hospitals occurred in Germany. Based on these groups, the billing system of hospitals changed significantly and the economic pressure rose dramatically. Furthermore hospitals were forced to collect and transmit standardized case data. This data is used to improve the G-DRG system. This data is fundamental for further analysis of clinical pathways and performance of hospitals. CP forms sequences of ward stays and treatments to be performed during a patient's hospitalization under consideration of all relevant resources like beds, staff, and moveable medical equipment. Through this analysis, it is possible to find rules for patient arrivals, length of stay, and internal transfers of patients and to calculate empirical distributions based on these rules.

Based on these findings, we found that simple, yet sufficiently detailed, pathways are constructed in order to build a hospital-wide simulation model (see Fig 1.8). It is notable that the presented paths are abstract pathways. While using the simulation model, these abstract paths transform into individual patient pathways. For each patient inside the simulation model, individual transfer probabilities are calculated from distributions in order to construct patient paths. Furthermore the simulation model uses the whole hospital infrastructure as an input. The core calculation component of the presented case study performs a daily bed allocation. Here a heuristic is used in order to distribute patients to possible room, respectively, beds. While calculating the allocation, several constraints based on capacity-based interdependencies were taken into account, namely, the consideration of gender separation and the isolation of patients with multiresistant germs.

With the help of simulation techniques, the problem area is expanded. Now it is possible to make strategical capacity decision or to evaluate these decision based on operational decision-making. With the expansion of the focus, more interdependencies were taken into account. Here process- and capacity-based interdependencies between organizational units are considered. This is a concept, which distinguishes the presented model from other simulation-based approaches

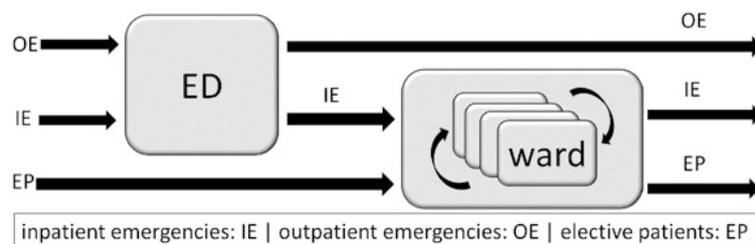


Fig. 1.8 Clinical pathway for simulation

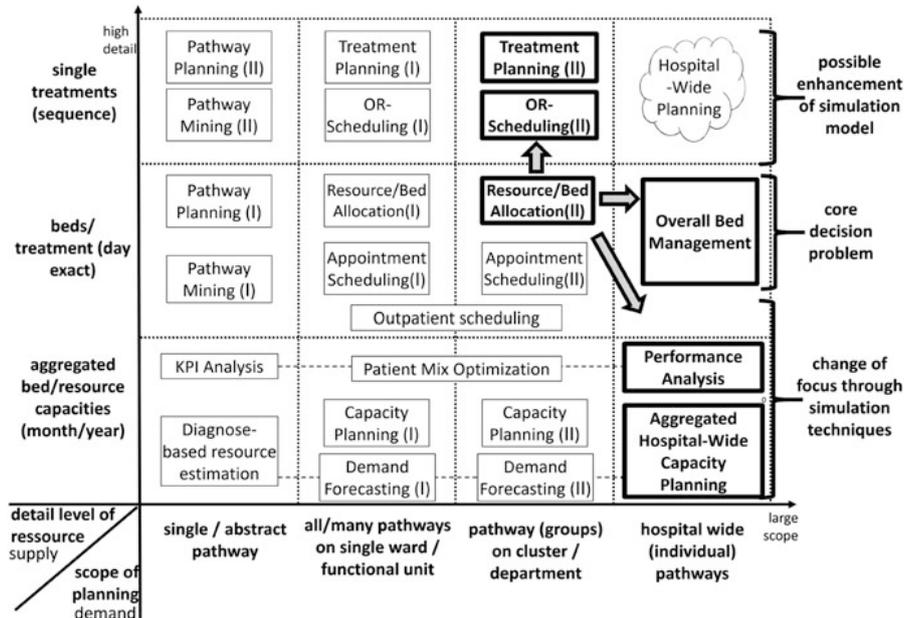


Fig. 1.9 Classification of case studies

in the state of the art. So we are able to tackle different kind of problem areas on different abstraction levels within the same model. Furthermore it is possible to enhance the model by integrating components for different kind of treatment scheduling areas. Logically this is the next step in development because of the hierarchical interdependencies between bed allocation and treatment scheduling. The categorization of the presented case study and its implication is shown in Fig. 1.9.

One important milestone of this case study is the validation of the model for hospital-wide data over one year. We notice that empirical distributions generated from standardized data are accurate enough to model reality in a strategical context. A detailed discussion about validating this model is laid out in [3]. With the help of a validated simulation model, we are able to investigate several ideas in order to promote flexibility in hospital ward and bed management.

A first approach to improve flexibility was the opportunity to lend idle bed capacities between nearby wards (in this primary step without consideration of treatment needs of the patient). A key performance indicator of this scenario is the average waiting time until a patient is transferred to his or her desired ward. With the opportunity to use idle capacities from other wards, the waiting time decreased up to 10 h. However a feared disadvantage for some wards did not occur. Another possible way to improve flexibility was to pool capacities from intensive care and intermediate care wards. The findings are similar to the first scenario. The waiting time for transfers decreased significantly. Furthermore, occupancy rates of some

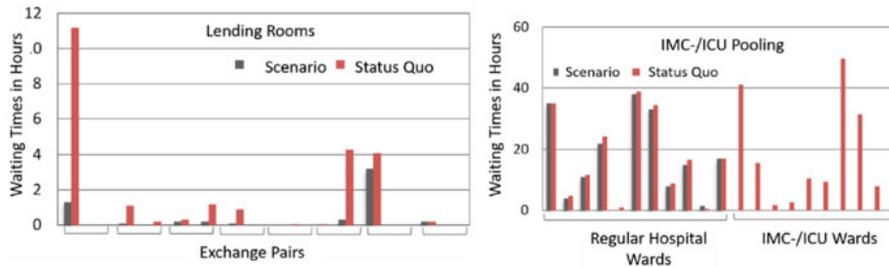


Fig. 1.10 Experimental results of case study 1

hospital wards are rising, while other wards with a high initial occupancy rate notice a decrease in their utilization. Additionally the presented model shows a decrease in occupancy bottlenecks because of a more flexible use of resources. This was a first step toward new thoughts about flexibility in ward and bed management (see Fig. 1.10).

Further discussions with the management of a university hospital led to the concept of ward occupancy cluster in hospitals in order to incorporate medical issues in the flexibility approach. In general, this introduces a new improved version of the opportunity to lend idle capacities with respect to organizational and treatment-based restrictions. In [3], a generic simulation-based decision support application in Simio is developed that enables to evaluate flexible ward clusters in hospital occupancy management. Basically an occupancy cluster is a union of wards that nurses similar patients. Each cluster will contain a number of wards. Within a cluster, all kinds of patients could be nursed by each containing ward. For example, a surgery cluster contains all hospital wards dealing with surgeries (e.g., heart surgery, thoracic surgery, and plastic surgery). At first, every ward tries to use its own beds. If there is no more capacity for another patient, this patient will be admitted to another ward of the cluster that has available capacities. In theory this approach should be able to distribute utilization peaks evenly between wards.

Two major key performance indicators are investigated in simulation studies in order to evaluate this strategy. In general we analyze the utilization rate and the number of waiting or rejected patients. The evaluation of this strategy shows that occupancy clusters are able to distribute occupancy peaks (see Fig. 1.11). The peak utilization of the wards did not rise above 100%. Moreover the number of waiting or rejected patients decreases significantly. The performance of this indicator depends on the evaluated cluster configuration. However, it should be noted that every cluster configuration studied significantly improves the status quo. This is a clear indication that even limited flexibility is better than no flexibility at all. In future research the location of the wards can be included in this approach in order to smoothen the utilization of other resource like staff and moveable medical tools.

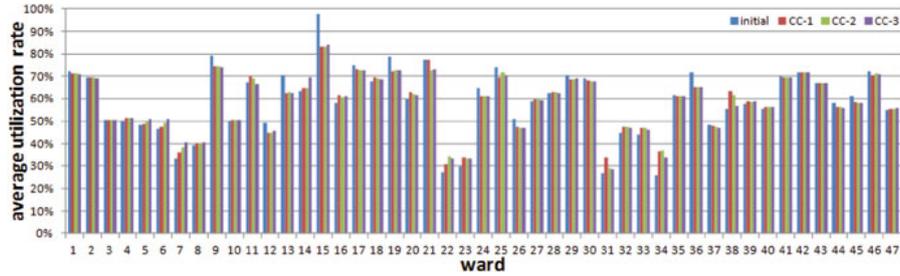


Fig. 1.11 Experimental results of case study 2

1.5.2 Optimization Case Study

Previous case studies aimed at an improvement of operations under flexibility from simulation perspective and a capacity-related point of view. Another way to improve flexibility is to optimize the treatment of a patient based on daily planning of treatments [4]. This study proposes a hierarchical integer linear programming (ILP)-based approach for the tactical day-level scheduling of clinical pathways. The approach uses a multicriteria objective function considering several patient- and hospital-related aspects and allowing to employ our approach in various scenarios. Furthermore, compared to other approaches, it considers several compliance discussed in Sect. 1.1. Basically this case study is located in the third and 7th quadrant of the categorization scheme. Because of its hierarchical architecture, this approach is located in several quadrants. On the top level a daily resource allocation is done, while on the second layer a detailed scheduling of treatments is done. So this case study is considered as a hybrid approach with respect to the presented categorization scheme (see Fig. 1.12).

This approach is evaluated with real-world data from a German university hospital showing that our approach is able to solve instances with a planning horizon of one month exhibiting 1088 treatments and 302 ward stays of 286 patients. These experiments show that our approach is capable of obtaining high-quality solutions within a reasonable amount of time for a tactical planning problem. Furthermore, the detailed evaluation shows that our model is capable of considering different scenarios such as achieving a smooth allocation of resources over the planning horizon and establishing a high resource allocation in the beginning of the horizon.

In the first scenario, the hospital aims at establishing a smooth resource allocation throughout the planning horizon. A smooth resource allocation establishes a similar level of flexibility to react to emergency cases on each day of the planning horizon. In the second scenario, the hospital aims at establishing a high resource utilization at the beginning of the planning horizon. On the one hand, shifting workload into the near future provides more scheduling flexibility for the more distant future to cope with uncertainties, e.g., due to complications and emergencies; on the other hand, this flexibility enables the hospital to seize opportunities for admitting a higher number of elective patients in the future.

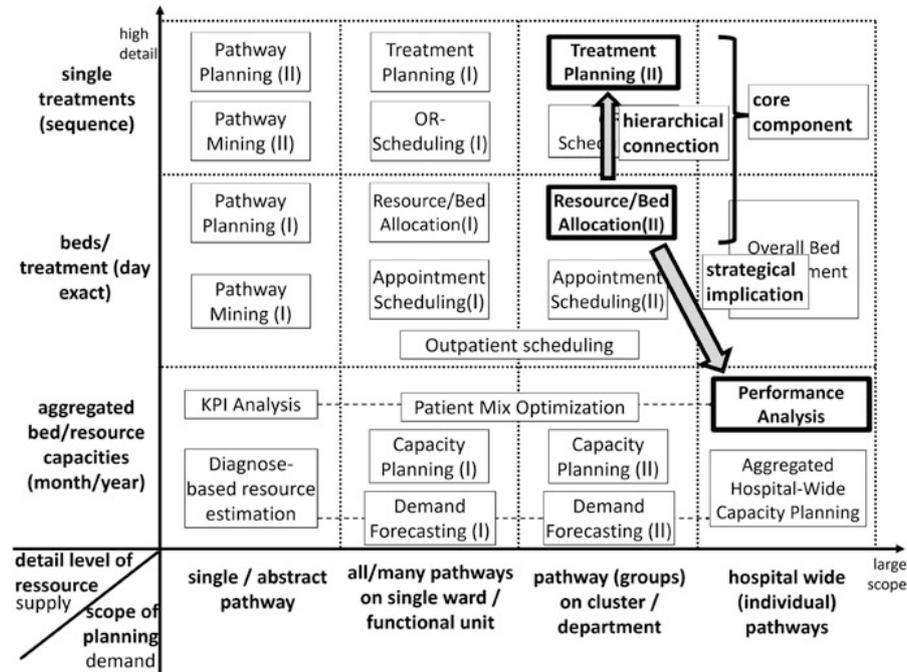


Fig. 1.12 Classification of case studies

1.6 Flexibility Strategies in Hospital-Wide Bed Management

In the previous section two case studies using flexibility strategies for resource usage was described. In order to discuss the strategies in detail, we first derive a definition of flexibility and transfer it to bed management. Afterward some current strategies from the case studies are discussed, and further research possibilities are described.

1.6.1 Definition of Flexibility in the Context of Bed Management

Flexibility has manifold definitions. Depending on the field of research or interest, the definition differs significantly. Because of the similarity between production companies and hospitals, we are able to transfer and enlarge the definition of flexibility from a production point of view to a hospital environment. Flexibility in general describes the ability of a system to change or react with little penalty in time, effort, cost, or performance to a varying environment [72]. This is a rather abstract definition of flexibility. By considering the resource point of view, flexibility can be located on the supply side of operations [73]. In order to support this point of view,

product flexible manufacturing capacities are introduced in [74, 75]. That means different products can be produced on the same machine capacity with little to no extra effort except costs for investments in flexible capacities. One of the key areas of flexibility in a production environment is the possible response to uncertainty. Organizations need to cultivate innovative capacities to promote higher flexibility. Integrating flexible and fixed structures can lead to lower costs and increased performance in operations [76]. By expanding the focus on supply chain flexibility, [76] argues that flexibility is repositioned from an intra- to an interorganizational concept. In general flexibility in manufacturing organizations is a multidimensional process across various functional layers of an organization. But flexibility in and of itself is not a solution. Instead it is a way to achieve a specific goal by delivering a specific response to an environment.

This definition of flexibility can be transferred to flexibility in a hospital environment. Especially attributes of flexible manufacturing capacities and supply chain flexibility can be transferred to hospital bed management. Patients can be seen as products, and in this case beds are considered as product flexible manufacturing capacities. Additionally if a hospital-wide bed management is regarded, principles of supply chain flexibility presented in the literature can be used in order to improve the performance of the bed management. Unfortunately it is not possible to transfer mechanisms of production flexibility directly. Because of the greatly enlarged patient uncertainty, the methods have to be expanded. In the next subsection current flexibility strategies in hospital bed management will be discussed.

1.6.2 Current State of Flexibility

In current decision support practice in hospitals, a low grade of flexibility is observed. In general each problem area, respectively, each organizational unit is treated separately. So possible advantages from interdependencies are neglected. Within this chapter, we will focus on occupancy-based flexibility strategies in order to promote a more efficient way of using existing resources because they are rather similar to the above-presented definition of flexibility. A general overview about different occupancy-based strategies is shown in Fig. 1.13, which shows the classification according to an increasing flexibility research line. By assuming general

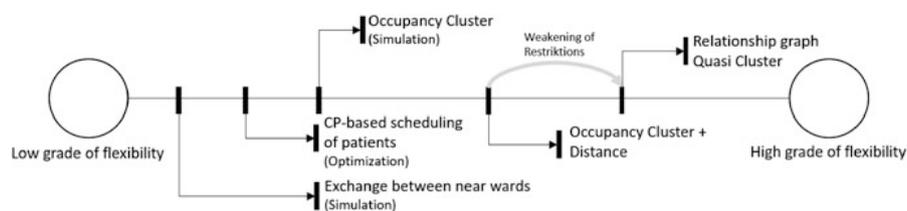


Fig. 1.13 Classification of present and future methods in a flexibility context

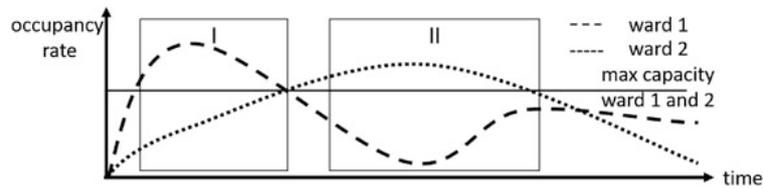


Fig. 1.14 Application areas of occupancy-based flexibility strategies

equality between beds at different wards, it is possible to distribute occupancy peaks from one ward to another. In Fig. 1.14 some occupancy rate developments over time are shown. In I the maximum possible capacity of ward one is exceeded and for ward two capacity is left unused. Practically this leads to rejection of patients or waiting time at ward one and unused following resources like physicians and nurses at ward two. In II it is vice versa.

The first flexibility strategy tries to extract advantages from this occupancy development. At the first stage of flexibility, the simple exchange of empty beds between near wards is used. In I ward one is not able to admit every patient. So this ward uses empty beds of ward two in order to ensure an admission of every patient. So with little to no effort a simple way of increasing the usage of resources is introduced. The downfall of this strategy is the limited amount of flexible resource capacity. Only a few beds of each ward can be used as backup for other wards. Additionally the number of lending partner is limited because of the precondition of a neighborhood of wards. Another flexibility strategy is the pooling of capacities, for example, from intensive care and intermediate care wards. First experimental results of both strategies imply a significant decrease of waiting times and the occurrence of occupancy bottlenecks without the appearance of disadvantages for some wards.

Encouraged by these findings and by further discussion with medical management experts, occupancy clusters are introduced in order to promote flexibility. Hereby the similarity of wards is considered while developing possible cluster configuration. The possibility of using beds from other wards is increased because potentially every bed can be used for other wards. Our study results regarding occupancy-based flexibility suggests a better resource usage of existing resources without investing in new beds. Occupancy clusters are able to distribute occupancy peaks evenly and moreover are able to decrease the number of waiting or rejected patients significantly. Nevertheless the performance of a cluster configuration strongly depends on its compilation. Different occupancy rates at the wards have a great impact on the possibility of using additional beds. If occupancy rates like in Fig. 1.14 are realized, it is simple to use beds from other wards. If the development of occupancy rates are too similar between wards, it is possible that no additional capacity is available when needed because these wards have their occupancy peaks at the same time. A great advantage of the cluster strategy is the possibility of combining multiple wards because the negative impact of too similar occupancy rates can be compensated through a rising number of combined wards. Based on

these promising results and in order to increase flexibility, more advanced strategies in further research will be discussed in the following section.

1.6.3 Further Research

As noted before we could combine the ward occupancy cluster approach with a consideration of locations of the hospital wards. This is the first step in order to improve the performance of our approach. Another possible way to improve performance of such a cluster configuration is to weaken the organizational restrictions. Several given cluster configurations from the hospital management imply that there are no strict medical reasons for a special cluster configuration or for a strict border between occupancy cluster. From a research point of view, it is possible to determine a possible softening of organizational restrictions in several ways. Regarding different cluster configuration, one possibility is the determination of intersection set of occupancy cluster, the so-called core cluster (Clique). By investigating further connections inside a cluster configuration, it is possible to calculate additional connections between core clusters.

A second possibility to weaken strict, but not necessary, organizational restrictions is calculating the similarity or dissimilarity of hospital wards based on their range of diagnosis and treatments. First results show that we are able to quantify the pairwise similarity between wards and to select a threshold of similarity. Based on that a similarity matrix for hospital wards can be calculated.

Both approaches (intersection of clusters and similarity matrix) allow us to break out of our classical cluster structure with strict delimitation. Based on those findings, we are able to implement a relationship graph in order to support the resource allocation process. Additionally this approach supports soft delimitation based on the hospital situation. For example, if there is an epidemic or a huge accident, the cluster delimitation (or the so-called softening degree) can be increased accordingly. Regarding this, a quasi-cluster structure can be updated for hospital-wide emergency situations. Figure 1.15 shows the resulting relationship graph of a cluster configuration with breakout relations. If one cluster is fully occupied, we are then able to use capacities of other clusters by utilizing these breakout relations. Graph-theoretically, we have a dependency graph of cliques with few intercluster connections. With the help of this concept, flexibility regarding hospital ward and bed management can be significantly improved without fully neglecting organizational restrictions and acceptancy of ward medical staff. Besides this, a further flexibility dimension can be added to our concept: If there is a case of an epidemic spread or of a huge accident, the cluster delimitation can be further softened in order to treat higher patient rates. Thus, for hospital-wide emergency situations, the cluster structure can be easily updated using precalculated ward similarities by increasing softening degrees resulting in temporarily more connected core clusters.

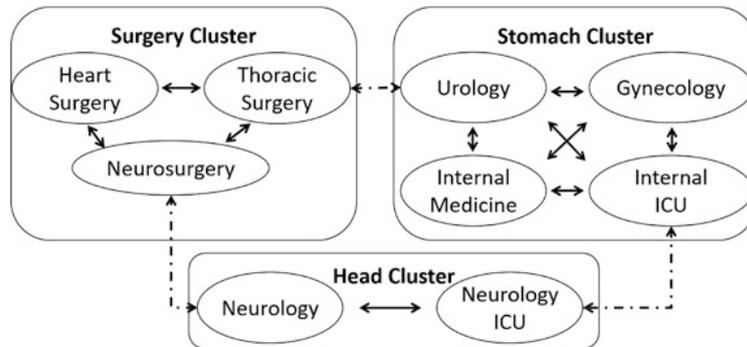


Fig. 1.15 Relationship graph for a hospital with quasi-cluster structure

1.7 Conclusion

Within this chapter, we reached our desired goals. For the first time, a detailed consideration of interdependencies inside a hospital is done. Furthermore these interdependencies are discussed with respect to their problem area and their possible impact on decision problems. With the help of new abstraction levels of patient pathways and resource, a classification of problem areas and current research is done. Here a concentration on certain abstraction levels is obvious. Optimization is mainly used with abstract patient pathways and with single organizational units. Hence optimization is mostly used for tactical or operational problem areas. The analysis of the current research literature shows that more complex paths are mainly tackled by simulation. In some research papers there is a consideration of multiple organizational units. But in general it is notable that most decision problems are discussed based on single organizational units or abstract pathways. That is why it is difficult to transport these studies from research to practice. In order to ensure a practical use, applications for decision support have to respect as much interdependencies as possible.

With the presentation of several case studies, possible ways of using interdependencies to promote flexibility are shown. In the simulation case studies, interdependencies of patient pathways are used to improve flexibility for the resource allocation process. Within the optimization case study, a possible implementation of flexibility inside the treatment planning process is presented. Here process interdependencies are used to improve the treatment planning.

Nevertheless it is vital for the operational use of current research in decision support in hospitals that researcher understand the influence of interdependencies and that more complex decision models are implemented with respect to more organizational units and more complex patient paths. This could lead to a general improvement of practical usage of current approaches in the operations research community.

Another important aspect is that optimization is mostly used for operational problem areas. In contrast, mainly simulation is used for more strategical questions. Unfortunately in nearly every simulation study the operational decision-making is neglected or is done in a greatly simplified way. Because of the rising integration of decision support systems and methods into the operational work of a hospital, this kind of decision-making should be respected in strategical considerations. Hence the operations research and especially the simulation community should move to a simulation of the implemented decision support methods inside a simulation study by using the same components as in operational use. Because of that an intelligent anticipating planning behavior can be simulated. Hence a practical implementation of study results is simplified. Moreover local maxima should not lead to a worsen of the overall performance of a hospital. So an organization-wide simulation with integrated decision support systems can lead to a better understanding of which interdependencies are important for a hospital setting. It is possible to decide which interdependencies should be included into the optimization and which interdependencies could be anticipated. In a next research step we develop a hierarchical anticipating approach for integrated admission scheduling and resource allocation in a hospital.

References

1. Mellouli, T., Stoeck, T.: Synergies between predictive mining and prescriptive planning of complex patient pathways considering process discrepancies for effective hospital wide decision support. In: Masmoudi, M., Jarboui, B., Siarry, P. (eds.) *Artificial intelligence and Data mining in healthcare*, SPRINGER (2020)
2. Helbig [Schwarz], K., Mellouli, T., Stoeck, T., Gragert, M., Jahn, P.: Simulation station-sübergreifender Patientenflüsse zur Evaluation flexibler Bettenbelegungsszenarien aufgrund der Jahresdatenanalyse eines Universitätsklinikums. In: *MKWI 2014 – Multikonferenz der Wirtschaftsinformatik: 26. – 28. Februar 2014 in Paderborn: Tagungsband, 749–762*. University of Paderborn (2014)
3. Helbig [Schwarz], K., Stoeck, T., Mellouli, T.: A Generic Simulation-Based DSS for Evaluating Flexible Ward Clusters in Hospital Occupancy Management. In: *IEEE (eds.) Proceedings of the 48th Annual Hawaii International Conference on System Sciences*, pp. 2923–2932 (2015)
4. Schwarz, K., Römer M., Mellouli T.: A Data-Driven Hierarchical MILP Approach for Scheduling Clinical Pathways: A Real-World Study from a German University Hospital To appear in *BUSINES RESEARCH* (2016)
5. Helbig [Schwarz], K., Römer, M., Mellouli, T.: A Clinical Pathway Mining Approach to Enable Scheduling of Hospital Relocations and Treatment Services. In *Business Process Management*, ed. Hamid Reza Motahari-Nezhad, Jan Recker, and Matthias Weidlich, 9253, pp242–250. Cham: Springer International Publishing (2015)
6. Stoeck, T., Mellouli, T., Schwarz, K.: Case Studies in hospital ward and bed management: decision support by simulation and optimization under flexibility. *AFROS 2018*
7. Gluchowski, P., Gabriel, R., Dittmar, C.: *Management Support Systeme und Business Intelligence*. Springer, Berlin, Heidelberg (2008)
8. Helbig [Schwarz], K.: Ein datengetriebenes System auf Basis klinischer Pfade zur Entscheidungsunterstützung für Ressourcenplanung in Krankenhäusern - Prozess-Mining, Optimierung und Simulation (2016), <http://dx.doi.org/10.25673/1922>

- 1 A Two-Dimensional Categorization Scheme 29
9. Schumann, C., Schieber, A., Hilbert, A.: Moderne Entscheidungsunterstützung im Krankenhaus – Business Intelligence meets Healthcare. *HMD Praxis der Wirtschaftsinformatik* **53/3**, 287–297 (2016)
10. van Merode, G. G., Groothuis, S., Hasman, A.: Enterprise resource planning for hospitals. *International Journal of Medical Informatics* **73/6**, 493–501 (2004)
11. Abraham, G., Byrnes, G. B., Bain, C. A.: Short-Term Forecasting of Emergency Inpatient Flow. *IEEE Transactions on Information Technology in Biomedicine* **13/3**, 380–388 (2009)
12. Atkinson, J., Wells, R., Page, A., Dominello, A., Haines, M., Wilson, A.: Applications of system dynamics modelling to support health policy. *Public Health Research & Practice* **25/3**, (2015)
13. Bakker, M., Tsui, K.: Dynamic resource allocation for efficient patient scheduling: A data-driven approach. *Journal of Systems Science and Systems Engineering* **26/4**, 448–462 (2017)
14. Green, L. V.: Capacity Planning and Management in Hospitals. In: Brandeau, M. L., Sainfort, F., Pierskalla, W. P. (eds.) *Operations Research and Health Care*, pp. 15–41. Kluwer Academic Publishers, Boston (2005)
15. Kolker, A.: Interdependency of Hospital Departments and Hospital – Wide Patient Flows. In: Hall, R. (eds.) *Patient Flow*, pp. 43–63. Springer, Boston (2013)
16. Lamothe, L., Dufour, Y.: Systems of interdependency and core orchestrating themes at health care unit level: A configurational approach. *Public Management Review* **9/1**, 67–85 (2007)
17. Burke, E. K., Curtois, T., Qu, R., Vanden Berghe, G.: A scatter search methodology for the nurse rostering problem. *Journal of the Operational Research Society* **61/11**, 1667–1679 (2010)
18. Burke, E. K., De Causmaecker, P., Berghe, G. V., Van Landeghem, H.: The State of the Art of Nurse Rostering. *Journal of Scheduling* **7/6**, 441–449 (2004)
19. Roche, K. T., Rivera, D. E., Cochran, J. K.: A control engineering framework for managing whole hospital occupancy. *Mathematical and Computer Modelling* **55/3-4**, 1401–1417 (2012)
20. Bartz, M.: *Patientenpfade Ein Instrument zur Prozessoptimierung im Krankenhaus*. VDM Verlag Dr. Müller (2006)
21. Müller, H., Schmid, K., Conen, D.: Qualitätsmanagement: Interne Leitlinien und Patientenpfade. *Medizinische Klinik* **96/11**, 692–697 (2001)
22. Holler, T., Conen, D.: Kostenbasierte Behandlungspfade. In: Albrecht, D. M., Töpfer, A. (eds.) *Erfolgreiches Changemanagement im Krankenhaus*, pp. 167–179. Springer, Berlin Heidelberg (2006)
23. Holler, T., Conen, D.: Prozessorientierung – Analyse und Optimierung von Wertschöpfungsprozessen. In: Albrecht, D. M., Töpfer, A. (eds.) *Handbuch Changemanagement im Krankenhaus*, pp. 217–228, Springer, Berlin Heidelberg (2017)
24. Wicke, C., Teichmann, R., Holler, T., Rehder, F., Becker, H. D.: Entwicklung und Einsatz von Patientenpfaden in der Allgemein Chirurgie. *Der Chirurg* **75/9**, 907–915 (2004)
25. Helbig, K.: Zeitplanung für Patientenpfade unter Berücksichtigung von Betten-, Behandlungskapazitäten und Fairnesskriterien. In: Alt, R., Eisenecker, U., Franczyk, B., Heyden, K. (eds.) *Forschungsberichte des Instituts für Wirtschaftsinformatik der Universität Leipzig*, pp. 34–44. Leipzig (2011)
26. Proudlove, N. C.: Can good bed management solve the overcrowding in accident and emergency departments?. *Emergency Medicine Journal* **20/2**, 149–155 (2003)
27. Black, D.: Average length of stay, delayed discharge, and hospital congestion. *BMJ* **325/7365**, 610–611 (2002)
28. Rais, A., Viana, A.: Operations Research in Healthcare: a survey. *International Transactions in Operational Research* **18/1**, 1–31 (2011)
29. Fone, D., Hollinghurst, S., Temple, M., Round, A., Lester, N., Weightman, A., Roberts, K., Coyle, E., Bevan, G., Palmer, S.: Systematic review of the use and value of computer simulation modelling in population health and health care delivery. *Journal of Public Health* **25/4**, 325–335 (2003)
30. Günal, M. M., Pidd, M.: Discrete event simulation for performance modelling in health care: a review of the literature. *Journal of Simulation* **4/1**, 42–51 (2010)

31. Cardoen, B., Demeulemeester, E., Beliën, J.: Operating room planning and scheduling: A literature review. *European Journal of Operational Research* **201/3**, 921–932 (2010)
32. Jack, E. P., Powers, T. L.: A review and synthesis of demand management, capacity management and performance in health-care services. *International Journal of Management Reviews* **11/2**, 149–174 (2009)
33. Baru, R. A., Cudney, E. A., Guardiola, I. G., Warner, D. L., Phillips, R. E.: Systematic Review of Operations Research and Simulation Methods for Bed Management. *Proceedings of the 2015 Industrial and Systems Engineering Research Conference* (2015)
34. Bai, J., Fügener, A., Schoenfelder, J., Brunner, J. O.: Operations research in intensive care unit management: a literature review. *Health Care Management Science* **21/1**, 1–24 (2018)
35. Saghafian, S., Austin, G., Traub, S. J.: Operations research/management contributions to emergency department patient flow optimization: Review and research prospects. *IIE Transactions on Healthcare Systems Engineering* **5/2**, 101–123 (2015)
36. Gul, M., Guneri, A. F.: A comprehensive review of emergency department simulation applications for normal and disaster conditions. *Computers & Industrial Engineering* **83**, 327–344 (2015)
37. Vieira, B., Hans, E. W., van Vliet-Vroegindeweyj, C., van de Kamer, J., van Harten, W.: Operations research for resource planning and -use in radiotherapy: a literature review. *BMC Medical Informatics and Decision Making* **16/1**, (2016)
38. Bai, M., Storer, R. H., Tonkay, G. L.: A sample gradient-based algorithm for a multiple-OR and PACU surgery scheduling problem. *IIE Transactions* **49/4**, 367–380 (2017)
39. Conforti, D., Guerriero, F., Guido, R.: Optimization models for radiotherapy patient scheduling. *4OR* **6/3**, 263–278 (2008)
40. Diamant, A., Milner, J., Queresby, F.: Dynamic Patient Scheduling for Multi-Appointment Health Care Programs. *Production and Operations Management* **27/1**, 58–79 (2018)
41. El-Sharo, M., Zheng, B., Yoon, S. W., Khasawneh, M. T.: An overbooking scheduling model for outpatient appointments in a multi-provider clinic. *Operations Research for Health Care* **6**, 1–10 (2015)
42. Maschler, J., Hackl, T., Riedler, M., Raidl, G. R.: An Enhanced Iterated Greedy Metaheuristic for the Particle Therapy Patient Scheduling Problem. *MIC/MAEB* (2017)
43. Maschler, J., Raidl, G. R.: Particle therapy patient scheduling with limited starting time variations of daily treatments. *International Transactions in Operational Research* **00**, 1–22 (2018)
44. Papi, M., Pontecorvi, L., Setola, R., Clemente, F.: Stochastic Dynamic Programming in Hospital Resource Optimization. In: Sforza, A., Sterle, C. (eds.) *Optimization and Decision Science: Methodologies and Applications*, pp. 139–147 Springer, (2017)
45. Gocgun, Y.: Simulation-based approximate policy iteration for dynamic patient scheduling for radiation therapy. *Health Care Management Science* **21/3**, 317–325 (2018)
46. Bruballa, E., Wong, A., Rexachs, D., Luque, E., Epelde, F.: Scheduling model for non-critical patients admission into a hospital emergency department. In: *IEEE (eds.) 2017 Winter Simulation Conference (WSC)*, pp. 2917–2928 (2017)
47. Davis, S., Fard, N.: Theoretical bounds and approximation of the probability mass function of future hospital bed demand. *Health Care Manag Sci* (2018). <https://doi.org/10.1007/s10729-018-9461-7>
48. Luo, L., Luo, L., Zhang, X., He, X.: Hospital daily outpatient visits forecasting using a combinatorial model based on ARIMA and SES models. *BMC Health Services Research* **17/1**, – (2017)
49. Patrick, J., Puterman, M. L., Queyranne, M.: Dynamic Multipriority Patient Scheduling for a Diagnostic Resource. *Operations Research* **56/6**, 1507–1525 (2008)
50. Bolaji, A. L., Bamighola, A. F., Shola, P. B.: Late acceptance hill climbing algorithm for solving patient admission scheduling problem. *Knowledge-Based Systems* **145**, 197–206 (2018)
51. Turhan, A. M., Bilgen, B.: Mixed integer programming based heuristics for the Patient Admission Scheduling problem. *Computers & Operations Research* **80**, 38–49 (2017)

52. Bastos, L. S. L., Marchesi, J. F., Hamacher, S., Fleck, J. L.: A mixed integer programming approach to the patient admission scheduling problem. *European Journal of Operational Research* (2018), <https://doi.org/10.1016/j.ejor.2018.09.003>
53. Ogulata, S. N., Koyuncu, M., Karakas, E.: Personnel and Patient Scheduling in the High Demanded Hospital Services: A Case Study in the Physiotherapy Service. *Journal of Medical Systems* **32/3**, 221–228 (2008)
54. Guido, R., Solina, V., Conforti, D.: Offline Patient Admission Scheduling Problems. In: Sforza, A., Sterle, C. (eds.) *Optimization and Decision Science: Methodologies and Applications*, pp. 129–137 Springer, (2017)
55. Aringhieri, R., Landa, P., Mancini, S.: A Hierarchical Multi-objective Optimisation Model for Bed Levelling and Patient Priority Maximisation. In: Sforza, A., Sterle, C. (eds.) *Optimization and Decision Science: Methodologies and Applications*, pp. 113–120 Springer, (2017)
56. Paulussen, T. O., Jennings, N. ., Decker, K. S., Heinzl, A.: Distributed Patient Scheduling in Hospitals. *IJCAI'03 Proceedings of the 18th international joint conference on Artificial intelligence*, 1224–1229 (2003)
57. Busby, C. R., Carter, M. W.: Data-driven generic discrete event simulation model of hospital patient flow considering surge. In: *IEEE (eds.) 2017 Winter Simulation Conference (WSC)*, pp. 3006–3017 (2017)
58. Côté, M. J.: A note on Bed allocation techniques based on census data. *Socio-Economic Planning Sciences* **39/2**, 183–192 (2005)
59. van de Vrugt, N. M., Schneider, A. J., Zonderland, M. E., Stanford, D. A., Boucherie, R. J.: Operations Research for Occupancy Modeling at Hospital Wards and Its Integration into Practice. In: Kahraman, C., Topcu, Y. I. (eds.) *Operations Research Applications in Health Care Management*, pp. 101–137 Springer, (2018)
60. Carmen, R., Defraeye, M., Van Nieuwenhuysse, I.: A Decision Support System for Capacity Planning in Emergency Departments. *International Journal of Simulation Modelling* **14/2**, 299–312 (2015)
61. Cochran, J. K., Roche, K.: A queuing-based decision support methodology to estimate hospital inpatient bed demand. *Journal of the Operational Research Society* **59/11**, 1471–1482 (2008)
62. Kuo, Y.-H., Leung, J. M.Y., Graham, C. A., Tsoi, K. K.F., Meng, H. M.: Using simulation to assess the impacts of the adoption of a fast-track system for hospital emergency services. *Journal of Advanced Mechanical Design, Systems, and Manufacturing* **12/3**, – (2018)
63. Persson, M., Persson, Jan A.: Health economic modeling to support surgery management at a Swedish hospital. *Omega* **37/4**, 853–863 (2009)
64. Cayirli, T., Dursun, P., Gunes, E. D.: An integrated analysis of capacity allocation and patient scheduling in presence of seasonal walk-ins. *Flex Serv Manuf J* (2018). <https://doi.org/10.1007/s10696-017-9304-8>
65. Luo, L., Liu, C., Feng, L., Zhao, S., Gong, R.: A random forest and simulation approach for scheduling operation rooms: Elective surgery cancelation in a Chinese hospital urology department. *The International Journal of Health Planning and Management* **33/4**, 941–966 (2018)
66. Gedik, R., Zhang, S., Rainwater, C.: Strategic level proton therapy patient admission planning: a Markov decision process modeling approach. *Health Care Management Science* **20/2**, 286–302 (2017)
67. Freeman, N., Zhao, M., Melouk, S.: An iterative approach for case mix planning under uncertainty. *Omega* **76**, 160–173 (2018)
68. Landa, P., Sonnessa, M., Tãnfani, E., Testi, A.: Multiobjective bed management considering emergency and elective patient flows. *International Transactions in Operational Research* **25/1**, 91–110 (2018)
69. Schneider, A. J. T., Besselink, P. L., Zonderland, M. E., Boucherie, R. J.: Allocating Emergency Beds Improves the Emergency Admission Flow. *Interfaces* **48/4**, 384–394 (2018)
70. Alvarado, M. M., Cotton, T. G., Ntaimo, L., Pérez, E., Carpentier, W. R.: Modeling and simulation of oncology clinic operations in discrete event system specification. *Simulation* **94/2**, 105–121 (2018)

71. Devapriya, P., Strömblad, C. T. B., Bailey, M. D., Frazier, S., Bulger, J., Kemberling, S. T., Wood, K. E.: StratBAM: A Discrete-Event Simulation Model to Support Strategic Hospital Bed Capacity Decisions. *Journal of Medical Systems* **39/10**, – (2018)
72. Upton, D. M.: The management of manufacturing flexibility. *California Management Review* **36/2**, 72–89 (1994)
73. Chod, J., Rudi, N.: Resource Flexibility with Responsive Pricing. *Operations Research* **53/3**, 532–548 (2005)
74. Fine, C. H., Freund, R. M.: Optimal Investment in Product-Flexible Manufacturing Capacity. *Management Science* **36/4**, 449–466 (1990)
75. Netessine, S., Dobson, G., Shumsky, Robert A.: Flexible Service Capacity: Optimal Investment and the Impact of Demand Correlation. *Operations Research* **50/2**, 375–388 (2002)
76. Fayezi, S., Zutshi, A., O’Loughlin, A.: *International Journal of Management Reviews* **19/4**, 379–407 (2017)

B. AI/OR Synergies of Process Mining with Optimal Planning of Patient Pathways for Effective Hospital-Wide Decision Support

Mellouli, T und Stoeck, T (2021)

In: M. Masmoudi, B. Jarboui, P. Siarry (eds.) Artificial Intelligence and Data Mining in Healthcare, 1 edn. Springer International Publishing (2021)

Chapter 2

AI/OR Synergies of Process Mining with Optimal Planning of Patient Pathways for Effective Hospital-Wide Decision Support



Taïeb Mellouli and Thomas Stoeck

Abstract Within a hospital, most of the relevant decision problems focus on patient pathways. Earlier studies show that OR techniques are capable of planning these heterogeneous pathways in multiple ward bed management. This chapter focuses on the synergies of these OR techniques with AI process mining. The first type of AI/OR synergy is to adapt process mining to learn the structures of patient pathways for different diagnoses and forward them to optimization. A case study with yearly data of a university hospital shows many business benefits and better planning results quality for shared resources. Further, the second type of AI/OR synergy is detected after a profound study of problem classes within our two-dimensional classification scheme considering both complexity dimensions related to patient pathways and hospital resources. Because of the many hard-to-model interdependencies, model-reality gaps occur. For the second type of AI/OR synergy, process mining is interpreted in a dual way where discrepancies of operations against planned pathway structure are detected. For this sake, a discrepancy mining approach is proposed and embedded with optimization into a plan-and-refine framework.

2.1 Motivation and Research Outline

Facing unprecedented challenges and economic pressure, hospitals are forced to make their processes more effective and to use their resources more efficiently. A serious burden of effective decision support in hospitals for all actors and decision makers, like physicians, nurses, and hospital managers, is the simultaneous twofold complexity inherent in their professional planning and organizational decisions. By clarifying the two interrelated dimensions of complexity, their interplay, and the many interdependencies to be considered for achieving better expert decisions, we

T. Mellouli (✉) · T. Stoeck
Department of Business Information Systems and Operations Research, Martin Luther University
Halle-Wittenberg, Halle, Germany
e-mail: mellouli@wiwi.uni-halle.de; thomas.stoeck@wiwi.uni-halle.de

© Springer Nature Switzerland AG 2021
M. Masmoudi et al. (eds.), *Artificial Intelligence and Data Mining in Healthcare*,
https://doi.org/10.1007/978-3-030-45240-7_2

23

show in this paper many facets of synergy between descriptive/predictive mining of complex patient pathways and process discrepancies within hospitals from an AI point of view and prescriptive planning of these complex entities considering complex resource requirements in hospitals from an OR point of view.

2.1.1 AI/OR Synergies meet Hospital Decision Task Complexities

The first type/dimension of complexity is related to the complex composition of clinical pathways, which patients should “follow” through the hospital over different wards depending on the locations of their associated treatments. A clinical pathway associated to a certain pathology/diagnosis contains detailed information about both clinically relevant treatments and organizationally relevant allocation of beds in hospital’s wards. Besides physicians’ knowledge about the treatment package for a patient with certain pathology, AI methods for descriptive/predictive process mining of historical hospital data may help them to decide about details of the clinical pathways to be adopted in operations. As prescriptive planning of groups of patients in one or several ward(s) cannot be realistic without accurate knowledge of the patient pathways, a first type of synergy between pathway mining and prescriptive planning arises: By extracting relevant pathway structure and pathway constraints from a process mining procedure, we are able to utilize them as input data and for the formulation of constraints within the mathematical models for scheduling patient pathways in wards. Thus, the first type of synergy is to utilize process mining results of pathways in prescriptive planning methods. We illustrate the benefits of this first type of synergy by considering case studies based on yearly hospital data and previous works published in an AI-oriented and an OR-oriented paper of our research group.

The second type/dimension of complexity is related to the complex environment of resources and their organizational management demarcated by the existence of several wards within hospitals with shared resources and with several other types of hidden interdependencies. First, we distinguish and discuss in some details six types of these interdependencies that have to be taken into account for accurate decision-making and decision support in hospitals. Second, we combine two dimensions of grads of consideration (or modeling granularities) of the first and second type of complexity into a two-dimensional problem scheme in order to demarcate different (aggregation levels of) decision-making and decision support tasks of hospital expert and management actors. Based on this two-dimensional scheme for decision support in hospitals, we are able to clearly differentiate various AI-/mining-oriented tasks and prescriptive planning OR-oriented tasks within hospital decisions, to detect AI/AI process/data mining synergies, and AI/OR synergies similar to the abovementioned first type. Moreover, we illustrate the substantial gaps between modeling and reality when considering ways for effective hospital-wide

decision support. These model–reality gaps are generally existent, because not all types of interdependency could be considered in prescriptive planning models and methods. Some types of interdependencies remain outside modeling consideration in spite of integrating heterogeneous pathway flows in different wards with shared capacities within (hierarchical) mathematical optimization and simulation models in our research.

In order to minimize these model–reality gaps, we introduce a second kind of synergy of predictive mining and prescriptive planning of complex pathways for effective hospital-wide decision support in hospitals. To operationalize this second type of AI/OR synergy, we propose a new kind of mining procedures of process discrepancies in hospitals caused by the model–reality gaps, in order to learn strain situations in hospitals leading to disagreement between result plans of prescriptive methods and operational reality. Ideally, the results of this mining approach would resemble expert rules describing bottleneck situations in terms of general modeling entities, so that these learned rules could be integrated into prescriptive models. As this method is not likely to exhaustively handle all types of interdependencies, individual instantiated bottleneck and local strain situations recognized within plans of optimization results can be utilized to iteratively add restrictions to the prescriptive model (cuts) in order to avoid these situations in next optimization rounds.

This subsection summarizes the argumentation path and the main contents of the chapter. The last three paragraphs roughly correspond to synopses of the three main sections of this chapter. Note that most of the new contributions are presented in Sects. 2.3 and 2.4 after discussing case studies in Sect. 2.2 in a business-oriented manner showing economic benefits in practice.

2.1.2 Pathway Centered Decision Support Toward AI/OR Synergy

After introducing DRG (diagnosis-related groups) payment systems for clinical services in many countries, notably the German DRG (G-DRG) in 2003 in Germany, hospitals are no longer payed on the basis of patient length of stay and actual treatment services offered, but rather on a diagnosis basis with associated standard treatment packages and standard fixed values of patient length of stay independent of hospital choice. Under these circumstances, economic pressure on hospitals is rising and they are facing unprecedented challenges in management, accounting, control, and decision-making. Hospitals are, therefore, forced to make their processes more effective and to use their resources more efficiently.

In enterprises with complex structures both in terms of their products and services as well as their organizational resources, decision-making and decision support tasks are interrelated and hide many difficulties in terms of modeling and solution approaches. Complex structures arise in hospitals for the services to be

offered to patients in form of clinical pathways. According to [6], the at most leverage effect in hospital performance is promised by the establishment of patient-centered clinical pathways. Referring to [7], a patient (or clinical) pathway is a multidisciplinary plan determining which treatment stations/wards a patient pass through from admission until discharge. In fact, clinical pathways contain detailed information about both clinically relevant treatments and organizationally relevant allocation of beds in hospital's wards where treatments and other services are offered.

Patient pathways help hospitals to comply with DRG regulations, to effectively read just their processes, and to efficiently seize their resource usage. The level of details offered by patient pathways enables hospitals to manage their processes effectively and control their costs accurately. Relevant information about treatments within these clinical pathways are stored on a regular basis in order to ensure compliance to government directives with respect to DRG and treatment standards. Information on pathways also helps insurances to compare treatment practice of hospitals depending on patient diagnosis and therefore obtain accounting transparency. On this basis, a fair comparison of clinics and hospitals in terms of performance for special diagnoses is possible.

In light of the many management and controlling facets of the information about clinical pathways, a new nationwide standard of these data is introduced in Germany (known as standard §21 data) and is continuously being refined together with adjusting treatment standards and treatment costs for diagnosis groups as directives for hospitals (see [8, 9]). Our research group at the department of business information systems and operations research at the Martin Luther University Halle-Wittenberg (headed by the first author) recognized the potentials of these standard management and accounting data (§21 data) in order to deliver effective decision support for hospitals, ideally in generic way for German hospitals. Five years ago [2], a simulation model for hospital-wide clinical pathway flows (modeling paths of patient groups across wards) is realized in order to evaluate flexible bed allocation scenarios on the basis of yearly data of a university hospital. The simulation model, initially realized in ARENA, is reimplemented in a generic way [3] using the object-oriented simulation environment SIMIO in order to evaluate flexible ward clusters in hospital occupancy management.

In order to deliver accurate information on pathways for detailed prescriptive planning and scenario simulation, a clinical pathway mining approach is presented [4] in order to enable scheduling of hospital relocations and treatment services. It is argued that, for an effective use of mining results in predictive planning methods, information on pathway structure as well as pathway restrictions should be mined in order to be integrated in scenario simulations of pathway flows through the hospital [3] and in optimization methods for scheduling pathways [5]. In [5], it is shown that the information on pathway structure and pathway restrictions and rules gained by process mining can be effectively used in prescriptive planning of clinical pathways using mathematical optimization giving rise to a data-driven hierarchical mixed-integer programming approach. A real-world case of German university hospital department shows the benefits on the solution quality of prescriptive planning.

2.1.3 *Research on AI/OR Synergy and Chapter Outline*

In this chapter, we first review in the next section these research works and case studies in order to introduce and practically introduce a first type of AI/OR synergy within a framework for hospital decision support. With this type of AI/OR synergy, utilizing the pathway structures gained by process mining increases the accuracy of prescriptive planning of bed-and-ward allocation for patients.

The second part of the chapter includes two sections: the third section is devoted to detection types and instances of AI/OR synergies within hospital decision support and the last fourth section to clarify the new detected second type of AI/OR synergy and to propose ways to operationalize this synergy, which is demarcated by mining of process discrepancies and its interplay with prescriptive planning toward effective hospital-wide decision support. The third and fourth sections are based on recent works and presentations of the authors. The first fundamental work [1] proposes and discusses a two-dimensional categorization scheme for simulation-/optimization-based decision support in hospitals applied to overall bed management in interdependent wards under flexibility. The first research ideas exposed in this chapter were presented at the “Digital Agenda Workshop” on Artificial Intelligence organized by the ministry of economics, sciences, and digitalization of the Land Saxony-Anhalt in cooperation with “Leopoldina” - Germany’s National Academy of Sciences.¹ In this workshop, our department participates with 5 presentations (out of a total of 14), distributed into three sessions: three contributions within the “intelligent city” session, and one to each of the sessions “intelligent industry” and “intelligent society.” Two of the three contributions within the “intelligent city” session are given by the authors and concerned “synergy between predictive AI and prescriptive planning methods for effective decision support in hospitals” and “AI-based mining of clinical pathways and process discrepancies for an anticipating self-learning planning in hospitals.”

The second part of the paper opens new directions of research on AI/OR synergy by discussing new ideas of these two AI Workshop presentations with reference to fundamental work on the two-dimensional scheme in [1]. As sketched in the Abstract/Summary, it begins in Sect. 2.3 with a detailed discussion of interdependencies in hospitals affecting decision-making and decision support tasks. Then two orthogonal dimensions of complexity are differentiated, one of them related to the composition of pathways and the other to the complex environment with respect to interdependent wards and shared resources and organizations in hospitals. Based on this, a two-dimensional scheme is proposed to categorize various decision-making and decision support tasks in hospitals. Two types of AI/OR synergy are then detected within the two-dimensional scheme: The first straightforward AI/OR synergy is the connection between a single pathway consideration of process

¹Digitale Agenda Workshop künstliche Intelligenz. Kooperationsveranstaltung des Ministeriums für Wirtschaft, Wissenschaft und Digitalisierung mit der Leopoldina—Nationale Akademie der Wissenschaften, Halle, August 29, 2019.

mining and a multiple pathway flow needed for resource and bed allocation for patient groups in one or several wards (homogenous or heterogenous pathways) in prescriptive planning methods. The second new type of AI/OR synergy is presented and discussed in more detail in Sect. 2.4. The idea is to propose a second kind of AI/mining procedure devoted to process discrepancies and to show its interplay with prescriptive planning toward effective hospital-wide decision support. Referring to the aggregation level of pathway composition in the two-dimensional scheme, both types of AI/OR synergy could be viewed at different level of details: aggregated resource and bed allocation level as well as treatment package and/or treatment sequence level.

2.2 First Type of AI/OR Synergy: Process Mining of Pathways for Accurate Prescriptive Planning of Ward-and-Bed Allocation

In this section, we illustrate by decision-making and decision support scenarios in hospitals, how descriptive/predictive analytics methods both for simple and complex structures have benefits toward a more accurate prescriptive planning of patient pathways and ward-and-bed allocations in hospitals. Realistic case studies discussed in previous works of our department [4, 5] show the impact of the resulting AI/OR synergy (of first type). This business-oriented exposition of this section helps the reader to follow the more fundamental two-dimensional categorization in the next section and the more abstract and generic discussion of types of AI/OR synergies.

2.2.1 Synergy between Predictive and Prescriptive Analytics: Cases of Simple vs. Complex Structures

While descriptive and predictive analytics help the manager and decision maker to be informed on what is happened and to analyze what will happen from an outside observer point of view, prescriptive methods support decision maker to shape the future by optimizing plans for operations from an inside decision maker point of view. Major prescriptive planning tasks in hospitals considered in our research are linked to ward-and-bed allocation for inpatients (patients with planned hospital stays) and to the evaluation of scenarios of flexible resource usage for inpatients from both flows of elective (planned-stay) patients and of emergency patients (forwarded to hospital wards). Prescriptive OR methods support decisions in both cases, in the first kind of tasks, by mathematical optimization approaches (e.g., [5]) and for the second kind of tasks, by simulation models helping to evaluate different organizational scenarios (see, e.g., [4]). For both prescriptive analytics approaches, we need accurate input data, parameter, distributions, KPI,

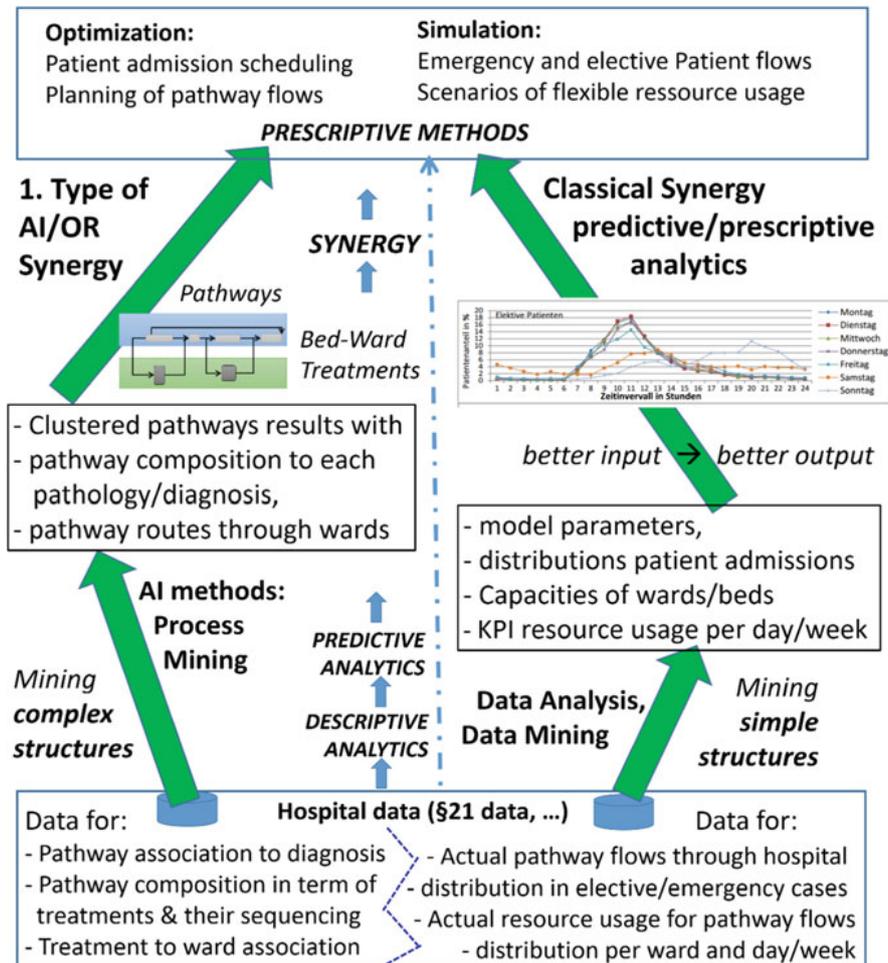


Fig. 2.1 Synergies between descriptive/predictive and prescriptive analytics for hospital decision support: classical synergy and 1. Type of AI/OR synergy

etc., in order to get accurate planning and scenario evaluation results. The better the input quality, the better the output quality. This is depicted in Fig. 2.1 (right side arrows) and denominated as the classical synergy between descriptive/predictive and prescriptive analytics.

For this classical synergy, simple structures in the form of model parameter, distributions of patient admissions, capacities of ward bed, and KPI for resource usage per day/week are needed as input for optimization and simulation models of prescriptive methods. Data analysis and simple data mining tools help gathering these simple structures first in a descriptive analytics framework. Taking into account trends and factors influencing the future environment (also depending on scenarios to be evaluated), predictive results for these simple structures are gained.

In prescriptive methods, where complex structures of objects/entities/tasks like clinical pathways are planned, the composition of these structures and other parameters concerning these structures should be known in advance as input. It is rarely the case that experts know all needed details about these complex structures. A way to gather the complex structures is to apply predictive AI methods such as pattern recognition, machine learning, association rule mining, or process mining. Thus, another form of synergy between descriptive/predictive and prescriptive analytics is needed, which is depicted in Fig. 2.1 (left side arrows) and denominated as “1. Type of AI/OR synergy.” For the hospital case study, a special process mining approach for clinical pathways that harmonizes with the needs of the prescriptive optimization models to plan pathway flows in wards is proposed. This special approach for process mining is illustrated in the next subsection, and the benefits of the AI/OR synergy are shown by considering case studies with data of a university hospital.

2.2.2 First Type of AI/OR Synergy and Its Benefits for Effective Hospital Decision Support: Case Study of a University Hospital

A special clinical pathway mining approach is presented in [4]. In order to enable accurate prescriptive scheduling of hospital relocations and treatment services, it is argued that information on pathway structure and pathway restrictions are needed in order to be integrated into the prescriptive optimization model (see Fig. 2.2). To each clustered pathology-dependent pathway class, the pathway structure indicates two detailed levels (the left side of Fig. 2.2). The first level indicates the succession of wards that can be taken by a patient following the corresponding clustered and generalized pathway, where possible alternative wards can be chosen. Anchored with the ward-day indications of the first level, the second level specifies which treatments are to be offered depending on the treatment package associated with the pathway. Also here, it is possible to choose between alternative treatments within the pathway—a good opportunity for optimization depending on availability of resources. As the pathways gained by process mining are considered in clusters, the variability of the length of stay at the ward-day level and treatment occurrence on the treatments level are indicated by the variables min, max, average, and median. The pathway constraints on the right side of Fig. 2.2 include the corresponding tables/information to these variabilities together with order constraints between ward-day relocations and between treatments as well as anchored constraints between the two kinds of these time-lasting “activities.” For these order constraints, the transition probability is indicated together with lag-bandwidth (min lag, max lag) for the allowed start of successor activity/step with respect to the start of considered step.

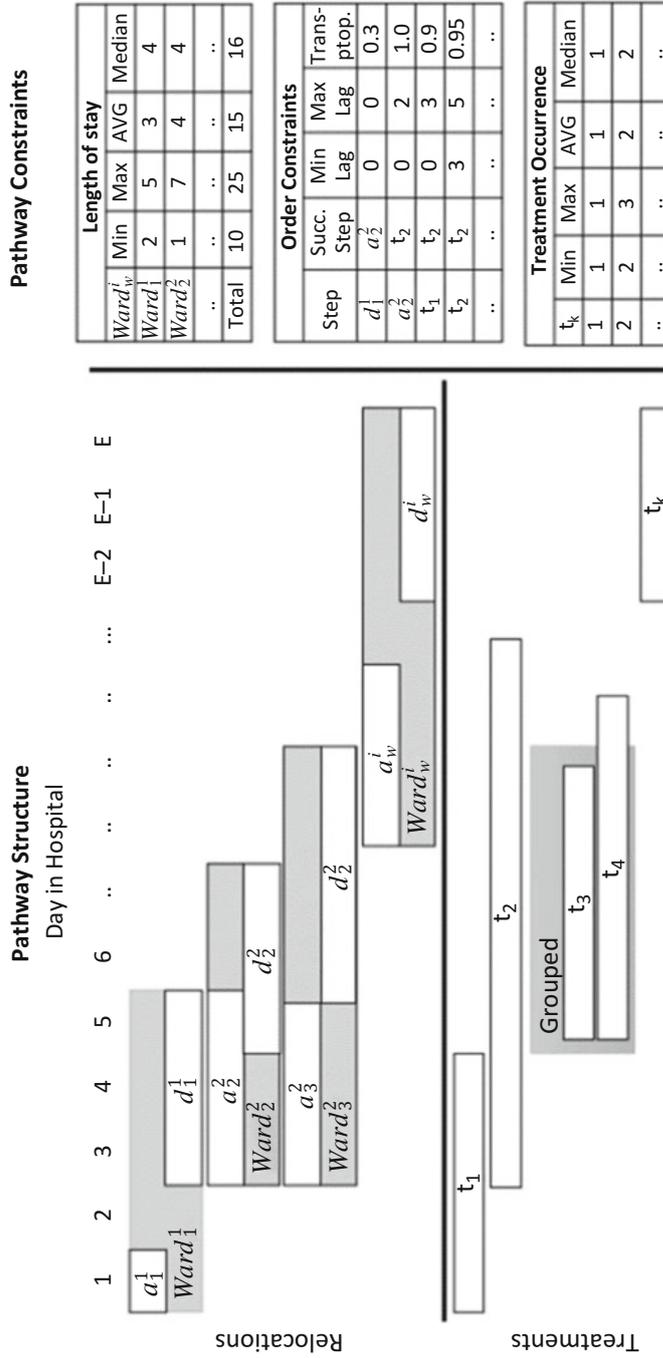


Fig. 2.2 Structure of mined pathway structure and constraints [4]

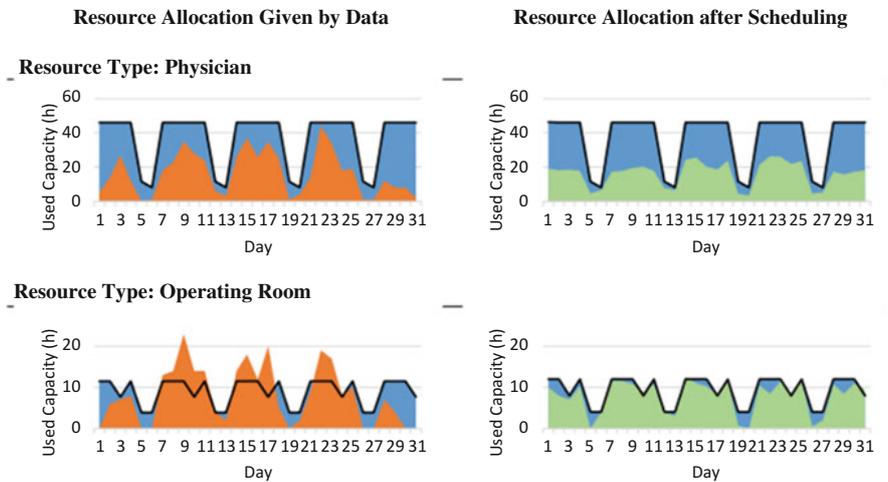


Fig. 2.3 Improved quality of planning results gained by prescriptive methods [5] using AI/OR synergy

In [5], it is shown that the information on pathway structure and pathway restrictions and rules gained by process mining as indicated in Fig. 2.2 can be effectively used in prescriptive planning of clinical pathways using mathematical optimization giving rise to a data-driven hierarchical mixed-integer programming approach. A real-world case of German university hospital department shows the benefits on the solution quality of prescriptive planning. The details can be inspected in [5]. Here, only some remarks about the quality of results gained by the AI/OR synergy are indicated.

Figure 2.3 depicts the resource usage given by (historic) data compared with the resource usage implied by the results of prescriptive optimization for the same period (as it were to be planned). For the resource type “physician,” a smoother resource usage is indicated by the optimization results without exceeding the given physician capacities. With the optimized plans, physicians may regularly integrate other tasks within their working days, giving rise to more productivity and planning stability. For the critical resource “operating room,” a twofold quality benefit emerges: not only that the optimized plan indicates smoother resource usage but also that the many capacity violations indicated by the data could be resolved. For this critical scarce resource, the solution of predictive methods attains higher resource utilization without violating capacities.

As our purpose in this paper is to discuss AI/OR synergies in a generic and abstract way, we consciously do not go here into details of how the pathway structure and constraints are integrated as variables and constraints of the mathematical model and we also do not dwell on the innovative hierarchical mathematical programming approach in [5]. At the top level of the hierarchical model, the planning of admissions for elective patients together with the scheduling of critical

and complex treatments is formulated. In the top-level model, an anticipation of the base level is integrated. The base-level model includes the scheduling of other treatments together with ward and bed assignments. Recall that within hierarchical planning, top- and base-level models interact in terms of instruction and reaction [10]. One of the complex treatments considered in the higher hierarchical level are the operations in operating rooms. This further explains the good quality solutions indicated by a smooth and feasible solution with respect to the scarce resource “operating room” (the bottom part of Fig. 2.3).

This section had the purpose of introducing the types of synergies between descriptive/predictive and prescriptive analytics. Figure 2.1 showed two types of such synergies, where one of them is denominated by the 1. Type of AI/OR synergy. In this AI/OR synergy, complex structures are mined, as indicated in Fig. 2.2 for pathway structure and constraints, and then integrated into optimization models of prescriptive approaches. The quality of results should increase (as exemplarily shown in Fig. 2.3) because of the use of more accurate structures mined by AI methods. The next two sections will detect and discuss types of AI/OR synergies in a more generic and abstract way (Sect. 2.3). A new second type of AI/OR synergy will be detected and discussed in detail (Sect. 2.4).

2.3 Detecting AI/OR Synergies Within Hospital Decision Support: Interdependencies, Dimensions of Complexity, Two-Dimensional Scheme, and Types of AI/OR Synergy

As indicated earlier, effective decision support in hospitals depends on understanding the different decision-making tasks and their interrelations. Besides dealing with complex patient-centered multidisciplinary pathways, there are many hidden interdependencies, whose understanding heavily affects the effectiveness of decision support. We first discuss the different types of interdependencies apparent in complex decision-making environments like hospitals. Based on this discussion, two main dimensions of complexity are recognized: complex structures and complex environments. We then combine these two dimensions of complexity into a new kind of two-dimensional scheme. This scheme categorizes a magnitude of decision-making and decision support tasks in hospitals at a varying level of detail and consideration. By identifying AI and OR tasks within this scheme, many types of AI/OR synergies will be detected and discussed.

2.3.1 Types of Interdependencies: First Group

Interdependencies generally refer to interactions of at least two actors, processes or issues. In the current research literature on decision support in hospitals, these

interdependencies are not examined and classified in detail. There are a few articles that discuss interdependencies in a hospital. Unfortunately they mostly focus on one kind of interdependencies. So a broad overview about interdependencies and its integration in planning models is lacking. Furthermore, in most cases researchers state that there are interdependencies and they make assumptions in order to cope with them. Because of that, this subsection provides a more detailed classification and analysis of possible interdependencies in a hospital. In general, it can be assumed that, depending on the level of abstraction of the decision problem, the nature and influence of interdependencies change. In many cases, this has a major impact on the modeling of the problem. The more the interrelationships are considered, the more complex the problem becomes [11]. In order to tackle their importance for decision-making, they are separated into two groups. The first group (Table 2.1) refers to the first synergy, which means that it is generally possible to integrate them into planning models. The second group (Table 2.2) is harder or even impossible to model and will be discussed in combination with a second type of synergy in Sect. 2.4.1.

The first type of interdependencies covers *capacity-based interdependencies*, which are characterized by competition for shared resources. For example, competition for CT scans. Basically different patients from different wards have a certain demand for scan resources. So these different patient pathways should be synchronized in order to achieve an evenly utilization rate without long waiting times. Depending on the level of abstraction, different subareas can be considered. On the one hand, there is competition between patients for beds and resources within

Table 2.1 First group of interdependencies in a hospital

No.	Interdependency	Properties
1	Capacity-based	Competition for shared resources A decision has a possible impact on further decisions
1	Staff-based	Employee specialization and hierarchy levels are considered Effects on staff planning and pooling
3	Problem-based	Relation between separate decision problems On the same or on different hierarchical levels

Table 2.2 Second group of interdependencies in a hospital

No.	Interdependency	Properties
1	Process-based	Effects of process improvements are investigated Effects of local optimization depend on the position in the system
2	Functional-based	Arising from treatment of various diagnoses With rising numbers of diagnoses uncertainties increase
3	Patient-based	Relationship between elective and emergency patients Forecasting of emergencies affects the available capacity for elective patients

a ward [12]. Since a bed can only be used by one patient at a certain time, it must be decided which patient is admitted to which bed. Moreover, there are different types of beds that are only suitable for different patient groups [13]. Additionally, capacity decisions on bed level have a huge impact on potential treatment capacities. Depending on the diagnosis, different treatments may be necessary. Therefore, a second competition arises. Certain diagnoses require treatment in specialized organizational units. The patients admitted compete for surgery timeslots or appointments in imaging departments. Decisions that are good at the bedside level, for example, optimizing the occupancy rate of beds, can have a negative impact on further capacity decision problems on treatment level. Therefore, the capacity bottleneck is pushed just one step further [13]. So optimizing resources for all patient groups at the same time is a complex task [12].

The next kind of interdependencies is composed of *staff interdependencies*. In a hospital, employees are highly specialized medical professionals. For example, nurses can have different specializations and hierarchy levels. In contrast, there is a possibility that medical professionals are cross-trained in different professions [13]. In addition to nurses, there may be head nurses with more responsibility and authority. Furthermore not all nurses are preassigned to a particular ward. For example, the concept of resource pooling is transferred to nurses in order to gain flexibility in nurse assignment in case of unforeseen events because they are distributed to different wards as needed. The interdependencies are particularly evident here as a result of personnel planning [16, 17]. If nurses with a special field of study are only employed at individual wards, this can lead to treatment or care bottlenecks at other wards [13]. Bottlenecks in treatment processes can appear if a nurse or a physician is forced to wait for the completion of another task. If there is no suitable employee ready for this task, delays appear inside the treatment process [13]. Therefore, a better consideration of staff-related interdependencies could lead to a better planning of staff-related questions of the treatment process [18]. One possibility of coping with these interdependencies is pooling of nurses. As required, these pooled nurses can be assigned to different wards according their qualification.

The last and mostly neglected but crucial kind of interdependencies within this group covers *problem-based interdependencies*. This kind describes the relation between separate decision tasks. In general, combinations of previous interdependencies are possible. For example, when a capacity planning of a ward is performed, the possible consequences for the planning of treatment capacities should be respected. This means that for a particular decision problem the related upstream or downstream problems should be respected in order to achieve results usable in practice. But in a hospital environment it is difficult to characterize upstream and downstream problems. In most cases a decision problem has multiple interdependencies with other decision areas that have multiple relations on their own.

In Fig. 2.4 two examples of multiple interdependencies are shown. On a strategic level, a connection between bed, treatment, and staff capacity is obvious. For example, with rising bed capacities in a ward, treatment and staff capacities should be adjusted as well in order to prevent additionally capacity bottlenecks.

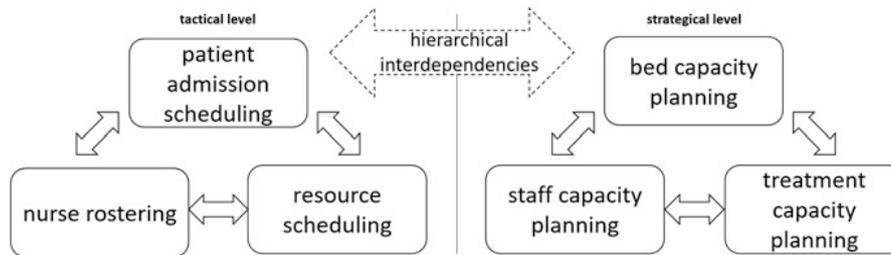


Fig. 2.4 Problem-based and hierarchical interdependencies

The same logic can be applied to the tactical level. Decisions made during the patient admission scheduling have a direct impact on decisions in other problem areas like nurse rostering or resource scheduling. Another form of problem-based interdependencies incorporates hierarchical interdependencies. That means that connections between decision problems at different decision levels are an important source of interdependencies. In Fig. 2.4 a hierarchical connection between bed capacity planning and patient admission scheduling is illustrated. If the bed capacity is high, the corresponding patient admission-scheduling problem is less complex. With a tighter planned bed capacity, the admission scheduling becomes more complex.

Despite of the inherent complexity of these interdependencies, it is possible to integrate them in planning models. In order to clarify their impact, two dimensions of complexity are introduced in the next subsection. Moreover, a two-dimensional scheme of decision tasks and the presented interdependencies are discussed as an approach to generate a first synergy between different decisions tasks.

2.3.2 Dimensions of Complexity and Overview About OR and AI Tasks and Synergies

Clinical pathways as complex structures represent a foundation of a lot of patient-centered planning problems, and their proper consideration is a general precondition for an effective hospital-wide decision support. But for an effective decision support, this is only one precondition. A complex environment has a huge impact on the complexity of planning problems. In general, patient pathways can consider one-to-many wards and different kind of resources. Also the environment creates another form of complexity within the decision support. Within the environment, there is a consideration of shared resources between multiple wards, general compliances that are present in a hospital, and other complex organizational conditions within a ward or the whole hospital. These different kinds of complexities, as shown in Fig. 2.5, are generating a lot of problems in the context of planning and decision

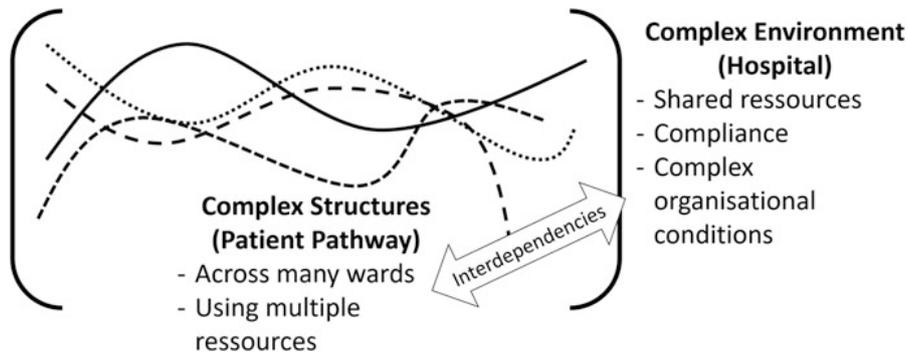


Fig. 2.5 Schema of confrontation of complex structures and complex environment in hospitals

support. While considering the combination of several dimensions of complexity, the discussion and investigation of different interdependencies in the last subsection is very important.

Because of the confrontation of two different kinds of complexities, a two-dimensional consideration of the problem is suitable in order to gain a deep understanding of the underlying quadratic complexity. In a consideration of complexity, the different dimensions can be investigated in different detail level, which have a great impact on the kind of decision support provided. The grade of complexity can be viewed from different starting points. First the complexity based on a consideration of patient pathways is shown. In the direction of the y -axis, the composition of a pathway is shown in different detail levels ranging from bed sequence to treatment sequences. On the x -axis, the multiplicity of pathways is considered. Here, an extension from abstract pathways to homogenous and further heterogenous pathways is illustrated. The most complex consideration is the observation of all possible pathways including irregularities during the pathway execution. The second possible point of view is the consideration of the resources of a patient pathway. Across the y -axis, the detailed level of resources needed by a pathway is shown, while the x -axis shows the extension of the scope of resources from one-to-many wards to a hospital-wide view. These considerations are illustrated in Fig. 2.6.

Within Fig. 2.6, the transition between strategical, tactical, and operational planning can be seen. Here, several grades of detail can be considered. It is important to notice that the complexity rises in two dimensions. From a consideration of single pathway and aggregated resources, a route to a considering all pathways and detailed resources has to be found. Moreover, with the help of this figure it is possible to link long-term, middle-term, and short-term decision support on an abstract level. This link is shown through the synergies of AI/OR methods on the left, bottom, and right side of the figure, which are discussed in detailed in the following (sub)sections.

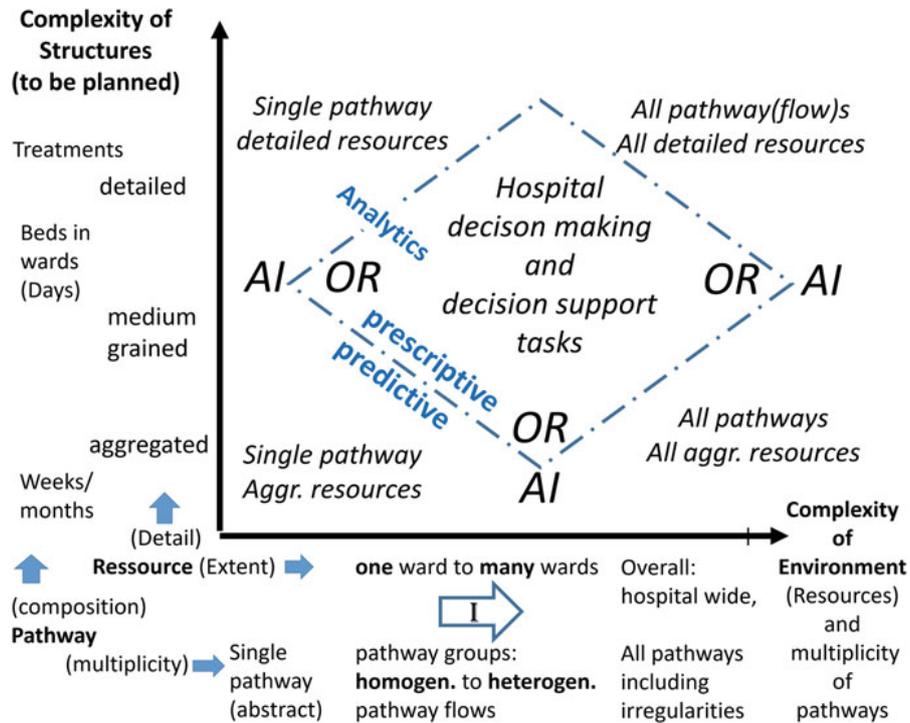


Fig. 2.6 Operationalization of the combination of complexities in hospital decision support

2.3.3 A New Two-Dimensional Scheme for Simulation-/Optimization-Based Decision Support in Hospitals Applied to Overall Bed Management in Interdependent Wards

A wide range of literature reviews show that a lot of problem areas inside a hospital exist. In [11], a general overview about using system sciences in health care is given. Based on that, some general problem areas are detected. In [19], different problem definitions regardless of their organizational unit are shown. Additionally two other surveys [20, 21] try to classify problem areas regarding their organizational scope of application. In addition to these general reviews, there are several specialized literature reviews that cover different scopes. This scope ranges from operating room scheduling [22] over capacity management [23] to capacity planning [24]. Furthermore, some reviews about different organizational units exist in the current research. There are special problem areas in intensive care [25], emergency departments[26, 28], or in specialized treatment areas like radiation therapy [27] or outpatient scheduling in general. It is obvious that there are several review articles. Nevertheless all presented review articles share the same problem.

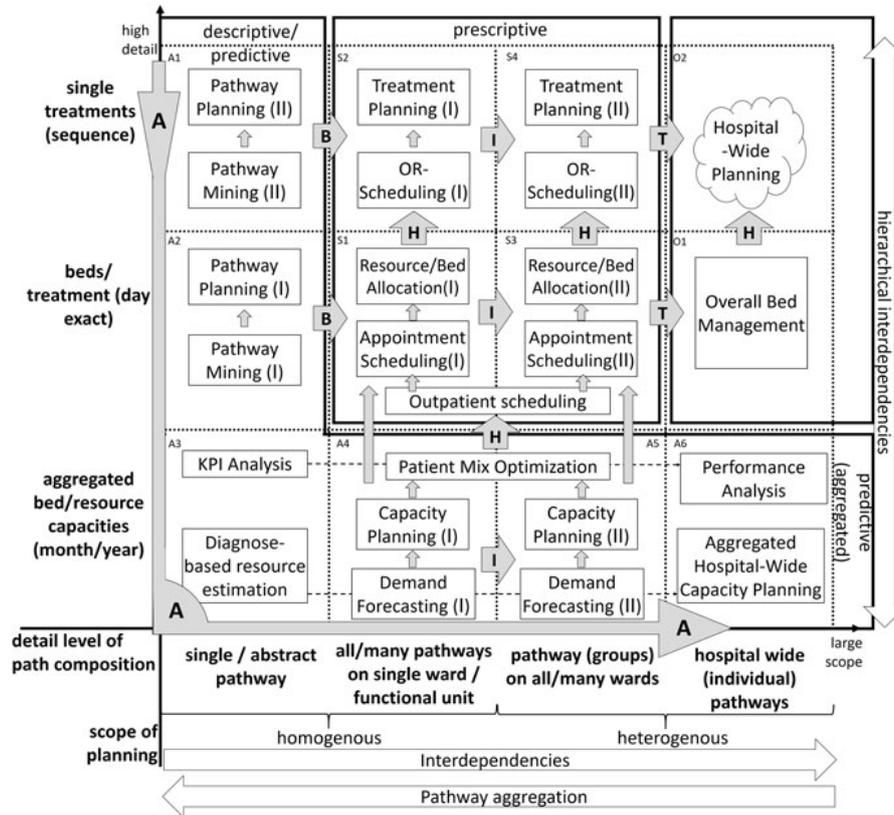


Fig. 2.7 Two-dimensional categorization scheme for decision support in hospitals

Based on the focus of the review, the existing categorizations are mostly based on problem areas or organizational units.

We propose a two-dimensional scheme depicted in Fig. 2.7 combining the complexity dimensions: complex structures (y -axis) and complex environments (x -axis), considered at different abstraction/aggregation levels. On the y -axis, the abstraction levels of resources are shown, which basically represents the inner composition of a patient pathway based on the granularity of resources needed. The x -axis shows different aggregation levels of patient pathways and pathway flows in the context of complex environments in a hospital. To clarify the discussion, only the amount of different pathways and their interaction with several departments inside a hospital are considered. By investigating the scheme, some general remarks about decision problems and interdependencies in a hospital environment are possible. In general, with an increasing path aggregation, the influence of interdependencies decreases. Nevertheless these interdependencies do not disappear. They are encoded into the aggregated pathways by making assumptions. Furthermore, an increasing pathway aggregation increases the homogeneity of pathways and patient groups.

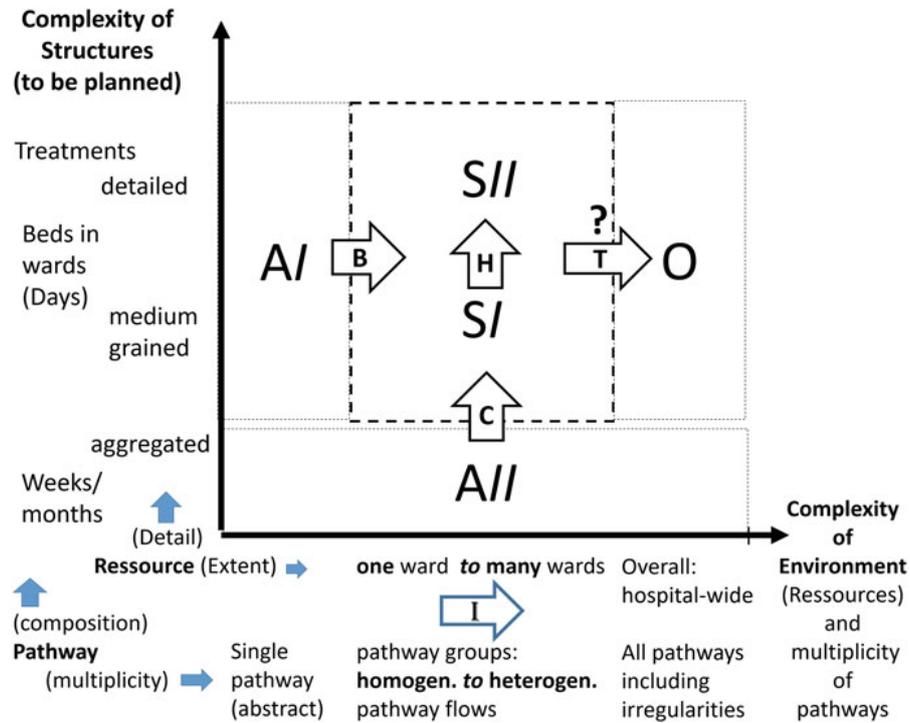


Fig. 2.8 Sectors of decision support in hospitals

This means that the corresponding decision problems do not have to deal with all possible interdependencies. In opposite direction, an increasing heterogeneity can be assumed, which leads to an increasing influence of interdependencies.

For the sake of clear derivation of types of AI/OR synergies, we will simplify the two-dimensional scheme of Fig.7 into that of Fig. 2.8 where only general problem sectors and their possible interactions are clearly highlighted. In discussing these different interactions between the sectors, the first type of AI/OR synergy discussed in Sect. 2.2 is shown and, furthermore, a hidden second type of AI/OR synergy is detected.

Considering the scheme, it is possible to derive several sectors, each one encompasses similar type of planning problems requiring the same special type of solving methods. These sectors are depicted in Fig. 2.8. Within sector AI, the task of pathway composition plays an important role. Within this sector, expert knowledge or process mining methods can be used in order to design patient pathways. Sector A II describes the problem area of strategical planning and performance analysis. Here, several tasks based on KPI and performance analysis can be done. In order to solve these tasks, a combination of data analysis methods, data mining approaches, and the aggregation of previously gathered AI results can be used. The scheduling-oriented sector S (divided into sector SI and SII) includes prescriptive planning

tasks of groups of pathways (pathway flows). These groups of pathways can be homogenous if a single ward is covered and heterogenous if several wards are considered. Finally, the most complex sector of decision tasks in a hospital is illustrated by sector O (for overall and hospital-wide view). Within this sector, decision tasks are very complex because of the occurrence of many different pathways including irregular pathways that are not known in advance. So several new interdependencies arising inside this sector and this complex problematic will be resolved in Sect. 2.4 by the proposed AI/OR synergy of the second type.

The transitions B, C, H, and T indicate opportunities for different kinds of synergy. These synergy types will be discussed in the next subsections. For the transition T that completes the planning to hospital-wide or overall extent is linked to second type of AI/OR synergy and will be discussed in detail in Sect. 2.4. The question mark over the T-transition symbolizes that the operationalization of the associated AI/OR synergy of second type is neither straightforward nor similar to the other types of synergies including first type AI/OR synergy.

2.3.4 AI Tasks and AI/AI Synergy: Stepwise Aggregation from Process Mining to More Accurate Hospital Data Mining

One interesting synergy arises along arrow A in Fig. 2.7, which is detailed in Fig. 2.9. Here, a possible synergy between different AI methods is shown. Inside one dimension, there is an aggregation of resources to a single pathway for each diagnosis. In this part, one main method used is patient pathway mining. Basically, this kind of aggregation starts with medical needs on treatment level, where sequences of treatments are mined depending on diagnoses. With a rising level of aggregation, the focus of the mining changes. At the second level, the day-exact sequence of bed allocations is investigated and on the more strategical level general rules for capacity allocation are learned during the mining run in order to make a key performance indicator analysis or a diagnosed resource estimation. This also generates a starting point for an aggregation to groups of patient pathways. Within the first aggregation, several patient pathways at one ward are considered. It is possible to use standard data mining methods to make a demand forecast, which is enhanced during the usage of more aggregate environmental structures of the hospital. Generally, if the pathway is followed, it is possible to use sufficiently detailed input data and knowledge for each mining step. Furthermore the results of these approaches can be improved by using this new discovered synergy. If every step is done sequential, it can be assumed that a hospital-wide predictive planning uses detailed insights from a mining approach at treatment level. With a more detailed view on the input data, a more detailed result at a more aggregated level can be achieved.

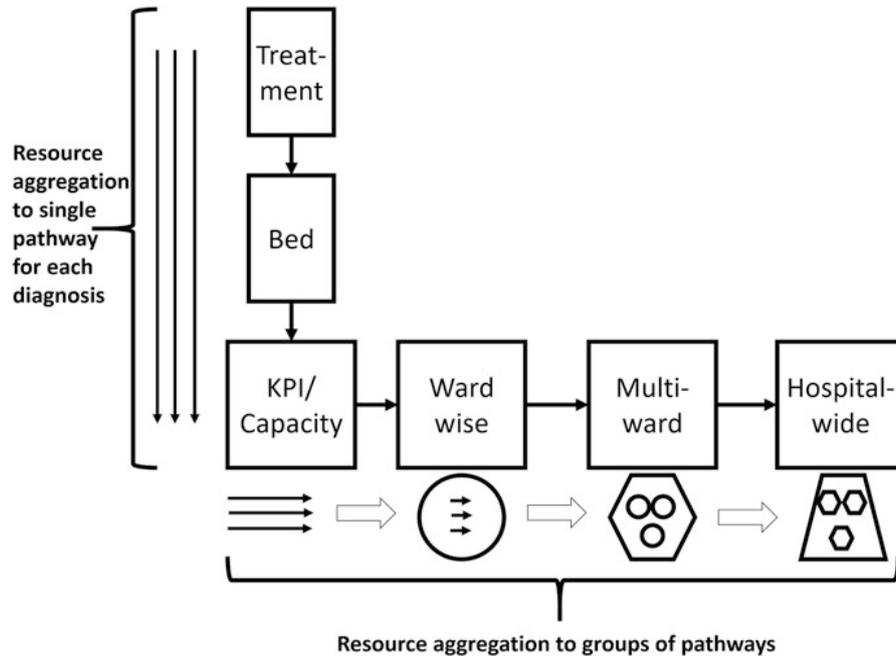


Fig. 2.9 Stepwise aggregation of process mining results

2.3.5 OR Tasks and OR/OR Synergies

Within Fig. 2.10, two different types of OR synergies are shown. Arrow H between the shown sectors describes a hierarchical synergy. The classical way of planning these different abstraction levels is the distinction between top and base levels (see [10]). In a standard consideration, the top-level problem deals with the planning of aggregated bed capacities and the base level describes the planning of single treatment sequences. Within the top level, an anticipation of the base level is done, which is clarified in another planning at base level. While considering basic resources, this type of hierarchical synergy is able to increase the quality of the results. But if the planning problem considers critical shared or scarce resource, this synergy could be regarded in different configuration as shown in Sect. 2.2.2 or in [5]. Within this configuration, the top level consists of planning scarce resources like operating rooms or main treatment resources for a certain patient pathway and an anticipation of a possible bed allocation is done. Afterward the exact planning of bed allocations and secondary treatments is done as a base-level problem. Another interesting interdependency arises along arrow I. Here, the transition from rather homogenous patient pathways for one ward to heterogenous patient pathways flows for a multiward setting is described. Basically, multicommodity (pathway) flow

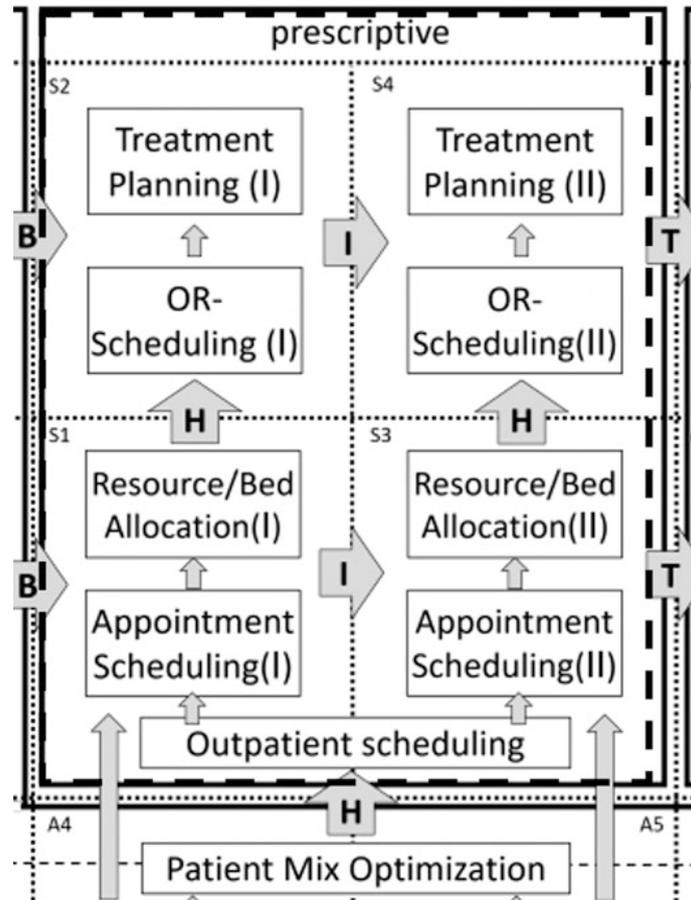


Fig. 2.10 S-Sector with OR tasks and OR/OR synergies

models are considered for modeling in order to increase the practicability of a planning and the efficiency of modeling.

2.3.6 First Type of AI/OR Synergy and Detecting a Second Type

The first type of synergy basically refers to Fig. 2.1 and the discussion in Sect. 2.2.2. Based on this rather economical discussion, a generalization considering the presented two-dimensional scheme is proposed. Referring to the aggregation level of pathway composition in the two-dimensional scheme, this type of AI/OR synergy could be viewed at different levels of detail.

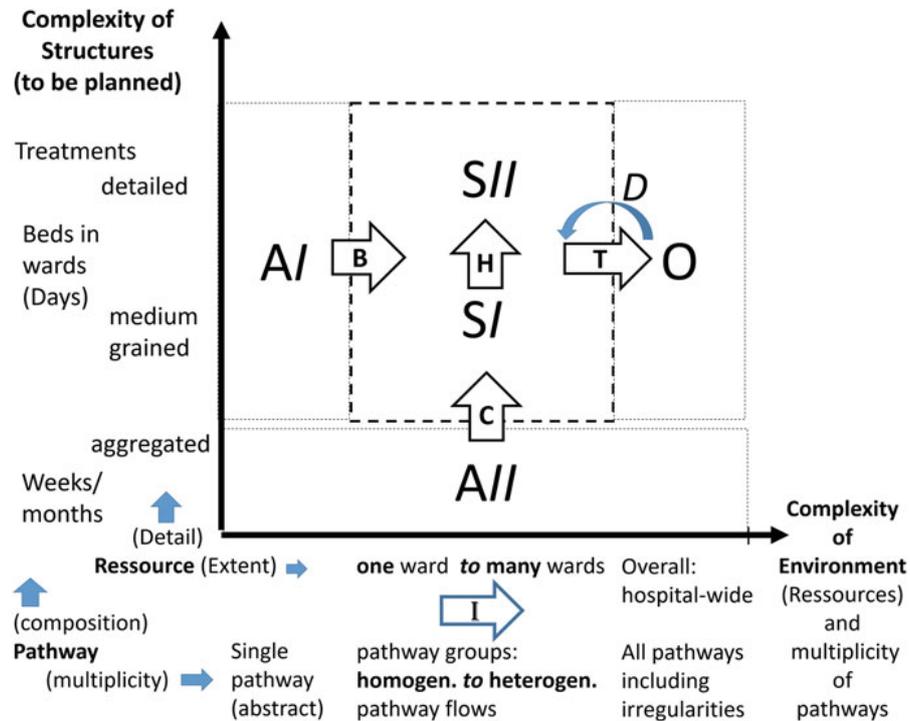


Fig. 2.11 Two-dimensional discussion of the combination of complex structures and environment

Generally, the first type of synergy describes the interplay between the descriptive/predictive sector A and the prescriptive sector S in Fig. 2.11. Generally, this synergy describes the usage of process mining or data mining methods as an input, for example as parameter or constraints, for prescriptive planning approaches. This kind of synergy can be divided into two subtypes. The first subtype deals with the possibility to learn details about the patient pathway composition via process mining as an input for an optimization (arrow B in Fig. 2.11). The second subtype is the usage of data mining methods in order to get good prognostic values about the path flow and its resource requirement.

Basically sector A describes a descriptive or predictive approach for strategical hospital planning tasks. These tasks present an input for sector S, which describe a prescriptive view of planning tasks. This input is shown as arrow B in Fig. 2.11. For a hospital, this is a crucial connection between strategical and tactical/operational planning areas. A high quality result of mining and aggregation procedures in sector A (AI or AII) is a mandatory requirement for a high quality planning result in sector S. This can be discussed with the example of pathway mining and planning and its implication for sector S. There is a differentiation into three different variants. The

first variant is direct mining approach for patient pathways in the upper quadrant of sector AI. So the focus lies on details on treatments and their sequencing. A second variant is the aggregation of treatments on a daily level. The planned day of treatment inside a patient pathway is important (lower quadrant in sector AI). A third variant is a new combination of the previously discussed variants proposed in [4] and discussed earlier in Sect. 2.2. This variant aims at the utilization of pathway mining and planning for the more operational scheduling sector. In order to avoid a too narrow set of input parameters for operational planning, the exact location of each treatment inside a sequence is not important. Furthermore, the exact day of treatment is not important either. In order to provide decent input for planning within this variant, only mandatory relations between treatments and a range of possible treatment days are considered. So this variant provides an appropriate input for other planning tasks without excluding possible solutions by providing too strict input parameters.

This is one potential aspect of the usage of synergies between descriptive/predictive mining methods and prescriptive planning tools. A mining approach can be used in order to extract more general decision rules, which can be used as additional input parameter during the optimization. So the insights from a mining point of view are included. Nevertheless this possible combination cannot be extended for a hospital-wide view on decision support. Generally, this synergy can be described by mining relevant structures and constraints from patient pathways or patient data. These structures and constraints contain exigent knowledge that serves as an input for an optimization.

Within Fig. 2.11, several other kinds of synergies are evident. The consideration of a classical hierarchical synergy shown by arrow H between Sector SI and Sector SII is able to improve the practicability of the results. Furthermore, arrow C shows a generalization of classical synergies between predictive and prescriptive methods. So, for example, data mining of KPI structures and simple planning methods could be used in order to enhance the quality of prescriptive planning methods. Considering arrow T and its reverse arrow D, a new kind of synergy arises. While increasing the multiplicity of patient pathways and extending the scope of resource consideration, the complexity of the planning problems is huge. Clearly this synergy deals with the inclusion of irregularities inside the planning process. Within a complex organization like a hospital, not all patient pathways are known in advance and it is not possible to include all compliance and interdependencies arising for the whole hospital. In order to enhance the scope of planning, the nature and the occurrence of these irregularities are crucial for introducing a new area of decision support in hospitals. In fact, to integrate the transition T for a hospital-wide decision support, methods have to be implemented in order to integrate mined discrepancies in sector O within prescriptive planning methods in sector S (arrow D).

2.4 Second Type of AI/OR Synergy: Mining of Process Discrepancies and Its Interplay with Prescriptive Planning Toward Effective Hospital-Wide Decision Support

As indicated in Fig. 2.11, the second type of AI/OR synergy should help for the transition T from a multiward, multipathway flow optimization in sector SII toward a hospital-wide overall decision support (sector O). We first discuss a second group of interdependencies (Sect. 2.4.1), which may explain the model–reality gaps between solutions produced by prescriptive planning methods for the SII-sector and reality, that is when checking complex interrelationships not being modeled within prescriptive models. In order to operationalize the second type of AI/OR synergy (and the T-transition to the O-sector), we propose to introduce a mining procedure for process discrepancies that can be organized by type of interdependencies (Sect. 2.4.2). The backward D-arrow in Fig. 2.11 indicates the interplay between process discrepancy mining with prescriptive planning. This mechanism together with the operationalization of the second type of AI/OR synergy by a discrepancy-driven approach is discussed (Sect. 2.4.3).

2.4.1 Types of Interdependencies: Second Group and Model–Reality Gap

As stated before, we differentiate between two different groups of interdependencies. The second group consists of interdependencies that are very complex and hard to model in classical planning methods. In order to achieve a hospital-wide decision support, it is crucial to understand their behavior and try to incorporate them in planning approaches. Generally they refer to organizational structures. Thus they are enlarging the planning scope within the environment of the hospital. An overview about these interdependencies is given in Table 2.2.

The first type of interdependencies within this group involves the *process-based interdependencies*. These interrelations mainly relate to the effects of process improvements. A hospital can be seen as a so-called downstream system [14]. This means that the flow of patients is primarily directed in one direction. This means that patients enter the hospital via a few facilities, such as a central emergency room, and will be distributed to other facilities. A characteristic of downstream systems is the fact that an isolated view of a domain can have a negative impact on the overall performance of a system. The effects of local optimizations on the overall performance depend on the position of the considered area in the overall system. In particular, process improvements in the main admission facilities lead to problems in the following areas. This can be demonstrated by a simple example.

We consider a simple system consisting of a central emergency room and a downstream operating room with an attached intensive care unit. If the flow of an emergency department (ED) is significantly increased, it means that patients will need surgery capacities sooner. Thus, the capacity bottleneck no longer arises at the ED but in the operating room area. As a result, the emergency room and regular ward patients are given a longer waiting time for their surgery and the doctor's workload may be stretched beyond their limit. Thus, considering process improvements, the implications for neighboring or downstream facilities should always be included in the considerations [14].

Another type of interrelations consists of the so-called *functional interdependencies*. At this type, the orientation of the functional unit determines the influence of interdependencies. In principle, functional interdependencies denote the interdependencies that arise from the treatment of various diagnoses or diseases. With a rising number of diseases treated, the uncertainty for the planning process and for capacity supply also increases. Functional units that treat only one disease have little functional interdependence. For such units, standard processes can be developed in order to simplify planning, while units that treat a high number of illnesses need integrated planning solutions to incorporate the interrelationships. Thus, interdependencies within the functional unit have a much higher impact. For an overview about functional interdependencies, see Fig. 2.12 [15].

In connection with the last paragraph, a sixth kind of interdependency can be discussed. This kind covers *patient-based interdependencies* between elective patients and emergency patients. From a planning point of view, this is a crucial kind of interdependencies on the highest level of planning. The available capacity for elective patients depends on the quality of the forecast of emergency patients. As every planning task in a hospital is correlated to the amounts of patients, therefore it is crucial for hospital decision support to cope with this kind of interdependency.

In Fig. 2.13, a graphical interpretation of this central trade-off between elective and emergency patients is given. In general, there are two different strategies dealing with this relation. Basically a hospital has a fixed capacity, for example, the amount

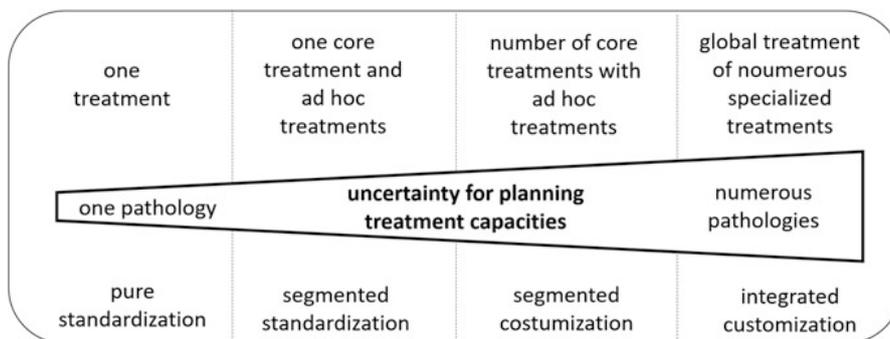


Fig. 2.12 Uncertainty through rising numbers of pathologies [15]

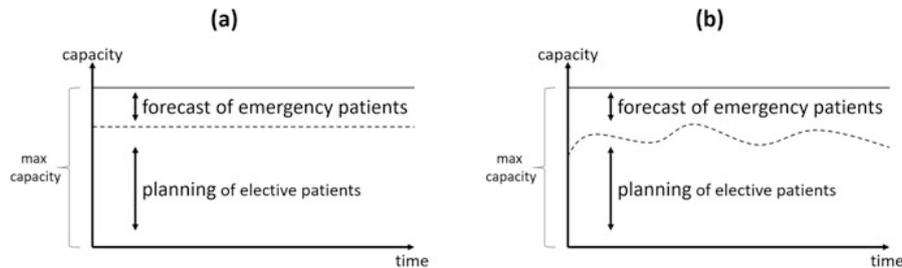


Fig. 2.13 Implications of patient-based interdependencies. (a) Fixed forecast strategy. (b) Flexible forecast strategy

of beds at a ward, for patient admission. The difficulty lies in the decision of how much capacity should be reserved for unplanned emergency patients. In Fig. 2.13a, a fixed strategy is presented. Based on a forecast, a fixed amount of beds over a longer period is reserved for emergency patients. The remaining amount can be used for planning elective patients. The performance of this strategy depends on the quality of the forecast of emergencies. If the forecasted amount is higher than the actual realized demand, the hospital has unused idle capacities. If the forecasted amount is lower than the realized demand, the hospital is overcrowded and patients have to be rejected. It is not allowed to reject emergency patients and therefore appointments of elective patients have to be canceled and in a worst-case scenario, all planning tasks located after an admission planning have to be redone. In order to cope with this problem, most hospitals reserve roughly 15% of its capacity for emergencies.

In Fig. 2.13b, a more flexible strategy is described. Here the amount of emergencies is forecasted for a shorter period of time or with different amounts. In general, a hospital is now able to react to a changing demand in emergency cases. In order to implement this strategy, a hospital is forced to adjust the planning of elective patients. So the planning of patients has to be done for shorter time periods in order to remain flexible in scheduling. So planning methods of a hospital have to be adjusted. Especially organizational changes in admission planning have to be ensured like short-term replanning of appointments of patients. In general, it could be possible that a hospital is able to use its capacity more efficiently with this strategy.

This group of interdependencies is complex in terms of modeling and integration into prescriptive planning models. Moreover not all aspects of the first group of interdependencies discussed in Sect. 2.3.1 can be modeled directly. Therefore model–reality gaps arise and harden the transfer of optimization results into practice. Because of this gap, a lot of results of planning problems cannot be transferred into practice. Within this gap, there are important organizational interdependencies that have an impact on the operational quality of planning results. For using an effective hospital-wide decision support, it is crucial to recognize these gaps and to make them as small as possible. Because of their complexity, new considerations regarding their integration into planning models have to be taken. One way to

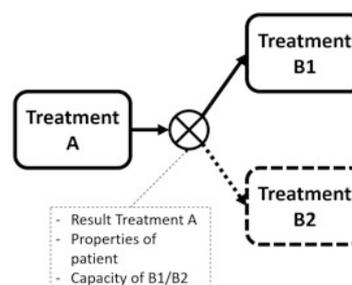
decrease the model–reality gaps is to use mining techniques in order to detect discrepancies during the patient pathways and gain knowledge from them for the future use within the planning process.

2.4.2 Mining Process Discrepancies by Type of Interdependency

In previous sections, the nature of patient pathways as complex structures, complex hospital environments, and the interdependencies between these two are discussed. In order to use these findings for an efficient decision support, a closer look at decision points inside a patient pathway is necessary. It is noticeable that these decision points harden the decision process even if only one patient pathway is considered. When considering multiple pathways across many wards, the complexity explodes. Fig. 2.14 shows a simple patient pathway with one decision point. After performing treatment A, a decision is made whether treatment B1 or B2 is performed. In fact the outcome of the decision depends on multiple factors like the result of the previous treatment, the properties of the patient or the capacity restrictions of the following treatments. Note that there are a lot more influencing factors for medical decisions during a patient pathway. Moreover, the previously discussed interdependencies have a huge impact on the decisions. That is the reason why these interdependencies have to be considered as detailed as possible within the decision process.

From a planning point of view, it is nearly impossible to optimize all decisions during a patient pathway or across multiple pathways. So a new planning approach has to be introduced. Normally a patient pathway has a standard pathway (given by the solid arcs in Fig. 2.14). In fact, the standard pathway is used for an initial planning for the patients. During the execution of the pathway, that means during the treatment process of a patient, the results of the treatment are stored. If a discrepancy against the standard pathway occurs, the medical expert has to make a decision on what alternative pathway should be taken by the patient. Here there are several possibilities. The expert could change to a well-known route through the pathway or decide to use another treatment that is not included within the patient pathway. For this online replanning, procedures can be implemented in order to decide which

Fig. 2.14 Example of process discrepancies



alternative treatment or alternative department is suitable for the patient. In looking at discrepancies in a more general way over all pathways (mining methods for discrepancies), we may generalize the way of using alternative pathways in order to avoid these discrepancies and thus reduce the model–reality gaps.

Another way to look at process discrepancies is the change in process execution that has never happened before. On the first look, there is no possibility to react to such occurrences. For example, in the decision point shown in Fig. 2.14 there is no possibility to use treatment B1 or B2. So the medical expert has to come up with a unique solution. Another more practical example for the use of AI methods in this context would be at department level. If we assume that a patient can either be admitted to department 1 or 2 and none of them has any free capacity left. Then the case manager or medical expert has to find another department that is suitable for this patient in a short amount of time. In [3] the so-called ward cluster is used to find a suitable department or ward. This is a rather static approach to tackle this problem. In future research we propose the use of mining methods in order to achieve rules for dealing with such extreme situation. One solution could be the mining for similarities of wards. This could include the similarity in case of doing the same treatments or having similar qualified staff. If this is done on diagnosis level, this could lead to a set of breakout rules for strain situation in hospitals.

Generally from the clear differences between several kinds of interdependencies, there is a need for special mining techniques for each class of interdependencies. Ideally, the results of a mining process following these lines would resemble expert rules describing bottleneck situations in terms of general modeling entities, so that these learned rules could be integrated into prescriptive models.

2.4.3 Interplay Between Mining Process Discrepancies with Prescriptive Planning and Operationalization of the Second Type of AI/OR Synergy by a Discrepancy-Driven Approach

To illustrate the possible use of process discrepancies, three different approaches for manually detecting and using interdependencies and discrepancies for a more efficient decision support are shown. All of these are based on capacity evaluation at different abstraction levels.

For the first example, ward capacities are considered. In general simulation approaches, the ward capacity is considered as number of beds inside a ward. One result of our research [3] is a more detailed view on ward capacity. It was detected that interdependencies between male and female patients have a huge impact on available capacities. So a gender separation is an improvement of the modeling and leads to a more practical relevance of the results. A Second example in the same study is the handling of shortages of capacities at different wards. These strain situations are caused by interdependencies between several patient pathways

on the same wards. So if a ward has no available capacity left, strategies for reallocation of patients have to be found. In [3] ward cluster is used to deal with this bottleneck in order to find a suitable ward, but this is a rather static approach. For an even more flexible strategy, the usage of similarity mining of wards could be encouraged in order to find suitable wards for patients. As a third example, the results of [5] are used. Here interdependencies between different treatments inside a patient pathway and across several pathways are considered. So for a scheduling of patients and treatments, these interdependencies are included inside the planning model. For this purpose, possible treatments are inserted into two groups. First complex treatments are scheduled, and afterward secondary treatments are planned. These three examples show the manual way to include extracted discrepancies into prescriptive planning models. The area of future research could be extended by searching ways to (partially) automate the inclusion of new interdependencies.

The inclusion of all possible rules inside an optimization model for planning purposes is nearly impossible. Some rules cannot be expressed and some others may result into optimization models which are prohibitively inefficient and thus not suitable for practical usage. That is why a new approach based on branch and cut is introduced, see, e.g., [29].

In general, branch and cut is an approach that enhances the well-known branch and bound algorithm by generating cuts as mathematical formulas inside the branch and bound tree. Within the presented approach in this chapter, interdependencies are seen as additional restrictions for a planning model. Because of the presented model–reality gap, it is not possible to exhaustively model all interdependencies within one planning model.

In Fig. 2.15, a new plan-and-refine framework for integrating new interdependencies into planning as a research agenda is proposed. This framework includes an

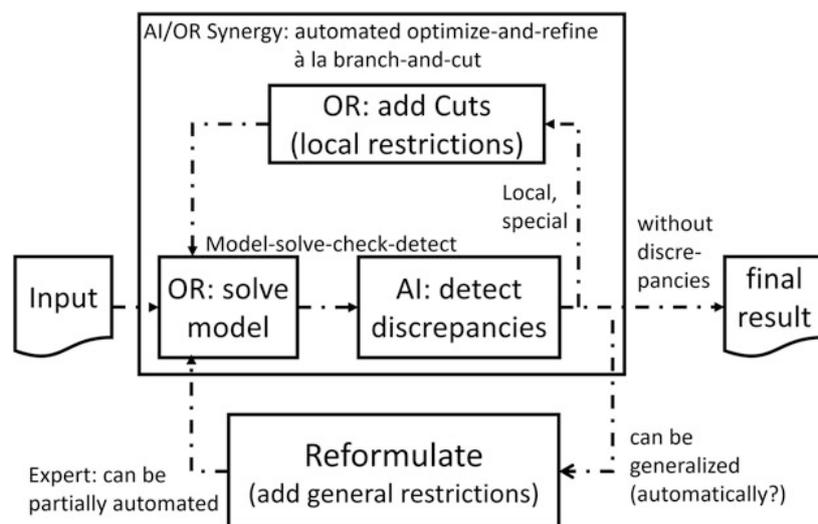


Fig. 2.15 Plan-and-refine framework including optimize-and-refine procedure

automated optimize-and-refine component operationalizing the AI/OR synergy of second type in the following form. First, the OR-based prescriptive model is solved, and then AI-mining procedure detects discrepancies (disagreement situations to reality). This is performed by a check routine incorporating compatibilities and compliance rules of hospitals. If discrepancies are found, some corresponding cuts (local restrictions avoiding the discrepancies) are added iteratively to the OR-based prescriptive model. In case a group of discrepancies of same type is recognized by the expert, he/she can reformulate the model by adding general restrictions. This model reformulation procedure is not done manually by the expert, but rather in a semiautomated way because the branch-and-cut kernel supports the expert by a listing of iteratively added constraints. This semi-automated procedure form together with the automated optimize-and-refine component the whole plan-and-refine framework.

2.5 Conclusion

In this chapter, we detected opportunities of synergy between artificial intelligence and operations research in the context of effective hospital-wide decision support. We showed that AI/OR synergy exhibits many facets and can take different forms. Observing that effective decision support in hospitals relies on considering complex entities to be planned in the form of patient-centered clinical pathway, a first type of synergy is discussed and its benefits considering real-world case studies are shown. Mining the structure and constraints related to the complex pathways helps integrating details on these objects within prescriptive mathematical optimization models.

By a more fundamental discussion around types of interdependencies, dimensions of complexity related not only to entities to be planned but also to resource environment, as well as of a two-dimensional characterization scheme for decision-making and decision support tasks in hospital, another hidden second type of AI/OR synergy is detected and its possible operationalization is discussed. We observed that although some types of interdependencies could be integrated in sophisticated optimization models for prescriptive planning, some other types of interdependencies in hospital decision-making could not be modeled. Thus, model–reality gaps emerge when trying to build prescriptive model for effective overall hospital-wide decision support. For the second type of AI/OR synergy, not the complex entities, but the complex hidden relationships when planning complex entities in complex environments are of interest. To gain these relationships, we proposed to mine process discrepancies (model–reality disagreements) in order to detect the relationships not being modeled within the prescriptive model. If these detected relationships exhibit a general form, an OR expert can integrate them into the model. Otherwise, the located discrepancies can be automatically used in order to generate cuts into the model, that is, restrictions prohibiting the same process

discrepancies to occur in next optimization round. This is much like a branch-and-cut approach integrating an AI-oriented discrepancy mining procedure.

The second type of AI/OR Synergy will be the subject of future research where several questions should be answered. The first question is how to mine process discrepancies in an efficient and effective way. Here, detected types of interdependencies in this paper may guide us in formulating a shape-oriented inspection of model–reality gaps. The second question is how to automate or semiautomate a model-and-refine framework. Beginning with a branch-and-cut approach, it is necessary also to automate the generation of local restrictions (cuts) out of mined discrepancies. Last but not least, it is desirable then to automate the generalization of global restrictions out of many located restrictions (cuts) of the same type. This could be another form of AI/OR synergy: AI mining is here out of local restrictions (restriction mining) in order to gain general restrictions dealing with the same type of interdependency. The idea of learning association rules could be of help in order to learn not only general but also situation-conditioned restrictions.

References

1. Stoeck, T., Mellouli, T.: A two-dimensional categorization scheme for simulation/optimization based decision support in hospitals applied to overall bed management in interdependent wards under flexibility. In: Masmoudi, M., Jarboui, B., Siarry, P. (eds.) *Operations research and simulation in healthcare*, Springer (2020)
2. Helbig, K., Mellouli, T., Stoeck, T., Gragert, M., Jahn, P.: Simulation stationsübergreifender Patientenflüsse zur Evaluation flexibler Bettenbelegungsszenarien aufgrund der Jahresdatenanalyse eines Universitätsklinikums. In: *MKWI 2014 – Multikonferenz der Wirtschaftsinformatik*: 26. – 28. February 2014 in Paderborn: Tagungsband, 749–762. University of Paderborn (2014)
3. Helbig, K., Stoeck, T., Mellouli, T.: A Generic Simulation-Based DSS for Evaluating Flexible Ward Clusters in Hospital Occupancy Management. In: *IEEE (eds.) Proceedings of the 48th Annual Hawaii International Conference on System Sciences*, pp. 2923–2932 (2015)
4. Helbig [Schwarz], K., Römer, M., Mellouli, T.: A Clinical Pathway Mining Approach to Enable Scheduling of Hospital Relocations and Treatment Services. In *Business Process Management*, ed. Hamid Reza Motahari-Nezhad, Jan Recker, and Matthias Weidlich, 9253, pp242–250. Cham: Springer International Publishing (2015)
5. Schwarz, K., Römer M., Mellouli T.: A Data-Driven Hierarchical MILP Approach for Scheduling Clinical Pathways: A Real-World Study from a German University Hospital To appear in *BUSINES RESEARCH* (2016)
6. Salfeld, R., Hehner, S. P., Wichels, R.: *Modernes Krankenhausmanagement: Konzepte und Lösungen*. Springer (2008)
7. Roeder, N., Küttner, T.: Behandlungspfade im Licht von Kosteneffekten im Rahmen des DRG-Systems. *Der Internist* **47/7**, (2006)
8. Frese, E., Heberer, M., Hurlebaus, T., Lehmann, P.: Diagnosis Related Groups (DRG) und kosteneffiziente Steuerungssysteme im Krankenhaus. *Schmalenbachs Zeitschrift für betriebswirtschaftliche Forschung* **56/8**, 737–759 (2004)
9. Reinhold, T., Thierfelder, K., Müller-Riemenschneider, F., Willich, S.: Gesundheitsökonomische Auswirkungen der DRG-Einführung in Deutschland - eine systematische Übersicht. *Das Gesundheitswesen* **71/5**, 306–312, (2009)

10. Schneeweiß, C., *Distributed Decision Making*. Springer, Berlin (2003)
11. Atkinson, J., Wells, R., Page, A., Dominello, A., Haines, M., Wilson, A.: Applications of system dynamics modelling to support health policy. *Public Health Research & Practice* **25/3**, (2015)
12. Bakker, M., Tsui, K.: Dynamic resource allocation for efficient patient scheduling: A data-driven approach. *Journal of Systems Science and Systems Engineering* **26/4**, 448–462 (2017)
13. Green, L. V.: Capacity Planning and Management in Hospitals. In: Brandeau, M. L., Sainfort, F., Pierskalla, W. P. (eds.) *Operations Research and Health Care*, pp. 15–41. Kluwer Academic Publishers, Boston (2005)
14. Kolker, A.: Interdependency of Hospital Departments and Hospital – Wide Patient Flows. In: Hall, R. (eds.) *Patient Flow*, pp. 43–63. Springer, Boston (2013)
15. Lamothe, L., Dufour, Y.: Systems of interdependency and core orchestrating themes at health care unit level: A configurational approach. *Public Management Review* **9/1**, 67–85 (2007)
16. Burke, E. K., Curtois, T., Qu, R., Vanden Berghe, G.: A scatter search methodology for the nurse rostering problem. *Journal of the Operational Research Society* **61/11**, 1667–1679 (2010)
17. Burke, E. K., De Causmaecker, P., Berghe, G. V., Van Landeghem, H.: The State of the Art of Nurse Rostering. *Journal of Scheduling* **7/6**, 441–449 (2004)
18. Roche, K. T., Rivera, D. E., Cochran, J. K.: A control engineering framework for managing whole hospital occupancy. *Mathematical and Computer Modelling* **55/3–4**, 1401–1417 (2012)
19. Rais, A., Viana, A.: Operations Research in Healthcare: a survey. *International Transactions in Operational Research* **18/1**, 1–31 (2011)
20. Fone, D., Hollinghurst, S., Temple, M., Round, A., Lester, N., Weightman, A., Roberts, K., Coyle, E., Bevan, G., Palmer, S.: Systematic review of the use and value of computer simulation modelling in population health and health care delivery. *Journal of Public Health* **25/4**, 325–335 (2003)
21. Günal, M. M., Pidd, M.: Discrete event simulation for performance modelling in health care: a review of the literature. *Journal of Simulation* **4/1**, 42–51 (2010)
22. Cardoen, B., Demeulemeester, E., Beliën, J.: Operating room planning and scheduling: A literature review. *European Journal of Operational Research* **201/3**, 921–932 (2010)
23. Jack, E. P., Powers, T. L.: A review and synthesis of demand management, capacity management and performance in health-care services. *International Journal of Management Reviews* **11/2**, 149–174 (2009)
24. Baru, R. A., Cudney, E. A., Guardiola, I. G., Warner, D. L., Phillips, R. E.: Systematic Review of Operations Research and Simulation Methods for Bed Management. *Proceedings of the 2015 Industrial and Systems Engineering Research Conference* (2015)
25. Bai, J., Fügener, A., Schoenfelder, J., Brunner, J. O.: Operations research in intensive care unit management: a literature review. *Health Care Management Science* **21/1**, 1–24 (2018)
26. Saghafian, S., Austin, G., Traub, S. J.: Operations research/management contributions to emergency department patient flow optimization: Review and research prospects. *IIE Transactions on Healthcare Systems Engineering* **5/2**, 101–123 (2015)
27. Vieira, B., Hans, E. W., van Vliet-Vroegindeweyj, C., van de Kamer, J., van Harten, W.: Operations research for resource planning and -use in radiotherapy: a literature review. *BMC Medical Informatics and Decision Making* **16/1**, (2016)
28. Gul, M., Guneri, A. F.: A comprehensive review of emergency department simulation applications for normal and disaster conditions. *Computers & Industrial Engineering* **83**, 327–344 (2015)
29. Nemhauser, G., Wolsey, L.: *Integer and Combinatorial Optimization*. John Wiley & Sons, Inc. (1988)

**C. Simulation stationsübergreifender
Patientenflüsse zur Evaluation flexibler
Bettenbelegungsszenarien aufgrund der
Jahresdatenanalyse eines Universitätsklinikums**

Helbig, K, Mellouli, T, Stoeck, T, Gragert, M und Jahn, P (2014)

In: Tagungsband der Multikonferenz Wirtschaftsinformatik 2014, pp. 749–762.
Paderborn (2014)

Simulation stationsübergreifender Patientenflüsse zur Evaluation flexibler Bettenbelegungsszenarien aufgrund der Jahresdatenanalyse eines Universitätsklinikums

Karsten Helbig, Taïeb Mellouli, Thomas Stoeck, Markus Gragert

Martin-Luther-Universität Halle-Wittenberg, Lehrstuhl für Wirtschaftsinformatik und Operations Research, 06108 Halle (Saale), E-Mail: karsten.helbig@wiwi.uni-halle.de, mellouli@wiwi.uni-halle.de, thomas.stoeck@student.uni-halle.de, markus.gragert@student.uni-halle.de

Patrick Jahn

Universitätsklinikum Halle (Saale), Stabsstelle 7 des Klinikumsvorstands des UKH „Pflegeforschung und Entwicklung“, 06120 Halle (Saale), E-Mail: patrick.jahn@uk-halle.de

Abstract

Im Zuge der Gesundheitsreform 2003 sind Krankenhäuser gezwungen, ihre Prozesse zu rationalisieren. Zur Evaluation von Verbesserungsmaßnahmen der komplexen Krankenhausprozesse ist die ereignisdiskrete Simulation ein effektives Werkzeug zur Unterstützung von Managemententscheidungen. Gemäß der Anforderungen an moderne Simulationsstudien im Krankenhauskontext (u.a. Praxisrelevanz und ganzheitliche Betrachtung) werden in diesem Aufsatz die Patientenflüsse im Universitätsklinikum Halle (Saale) stationsübergreifend modelliert. Zur stationären Aufnahme wird eine genaue Belegungsstrategie hinsichtlich Geschlecht und Isolationsstatus in die auf Jahresdaten basierende Simulation eingebettet. Flexible Bettenbelegungsszenarien wie Zimmerverleih an räumlich angrenzende Stationen sowie die Zusammenführung aller ITS- und IMC-Stationen zu zentralen Pools führten zu einer deutlichen Reduzierung der Wartezeit auf Verlegungen innerhalb des Klinikums.

1 Einleitung

Krankenhäuser sind der wichtigste Leistungsbringer im deutschen Gesundheitssystem. Im Jahr 2011 verursachten diese ca. 76,8 Milliarden Euro an Kosten. Dies entspricht ca. 25% der Gesamtausgaben von 293,8 Milliarden Euro für Gesundheit im Jahre 2011 [13]. Aufgrund der Einführung des DRG-basierten Abrechnungssystems sind Krankenhäuser seit 2003 einem wettbewerbsbedingten Reformdruck ausgesetzt. Krankenhäuser, die es nicht schaffen, ihre Prozess- und Kostenstrukturen den Gegebenheiten anzupassen, sind in ihrer Existenz bedroht. Prozessverbesserungen sowie deren Auswirkungen sind aufgrund der hohen Komplexität und starken Interdependenzen der Krankenhausprozesse schwierig umzusetzen. Dies gilt insbesondere für große Krankenhäuser mit mehr als tausend Betten und einer Vielzahl fachspezifischer Stationen. Das Universitätsklinikum Halle (Saale) (UKH) gehört mit seinen ca. 1100 Betten zu dieser Gruppe. Im UKH werden jährlich ca. 40.000 voll- und teilstationäre Patienten behandelt. Davon sind ca. 10.000 stationäre Notfallpatienten, die das Klinikum durch die zentrale Notaufnahme (ZNA) betreten. Deren stationäre Aufnahme kann erst erfolgen, sobald ein Bett auf der entsprechenden Station zur Verfügung steht. Zur Überbrückung dieser Zeit stehen der ZNA zehn Betten zur Verfügung. Diese sind primär für Patienten, die zur medizinischen Überwachung in der ZNA verweilen, ausgelegt. Nur im Falle von Ressourcenengpässen werden sie als Puffer verwendet. Sollte die Überwachungseinheit der ZNA ebenfalls voll ausgelastet sein, wird die gesamte ZNA handlungsunfähig und kann keine weiteren Patienten aufnehmen, bis wieder freie Kapazitäten zur Verfügung stehen.

In diesem Aufsatz wird gezeigt, wie Entscheidungsunterstützung zur Gestaltung des Bettenbelegungsmanagements des UKH mit Hilfe eines ereignisdiskreten Simulationsmodells des gesamten Patientenflusses erfolgen kann. Ziel ist es zu evaluieren, welchen Einfluss Verbesserungsmaßnahmen auf Wartezeiten in der Überwachungsstation der ZNA sowie bei klinikinternen Verlegungen haben. Dazu werden im folgenden Kapitel bisherige Arbeiten zum Einsatz von ereignisdiskreter Simulation im Krankenhaus vorgestellt und Anforderungen an moderne Simulationsstudien in diesem Kontext abgeleitet. Anschließend werden im dritten Kapitel die abgebildeten Patiententypen, das Simulationsmodell sowie die in der Simulation eingebettete Heuristik zur Bettenbelegung vorgestellt. Im vierten Kapitel wird die Analyse der für die Simulation verwendeten Patientenfalldaten beschrieben. Im fünften Kapitel werden die in einer Zusammenarbeit mit dem UKH erarbeiteten Lösungsszenarien vorgestellt. Das sechste Kapitel beinhaltet die Modellvalidierung sowie die Evaluation der Szenarien. Abschließend werden die Ergebnisse der Studie zusammengefasst und auf weiterführende Forschungsfragen eingegangen.

2 Einsatz ereignisdiskreter Simulation in Krankenhäusern

„Discrete-event simulation offers perhaps the most powerful and intuitive tool for the analysis and improvement of complex health care systems.“[8] Zu diesem Schluss kommen *Jacobson et.al.* nach der Sichtung einer Vielzahl von Studien zum Einsatz von ereignisdiskreter Simulation im Krankenhauskontext der letzten 40 Jahre [8]. Untermuert wird diese These durch die große Anzahl von Surveys, die die lange Tradition des Einsatzes von Simulationstechniken im Kontext des Gesundheitswesens sowie deren Anerkennung als geeignetes Mittel zur Entscheidungsunterstützung unterstreichen [3, 5, 7–11].

Ereignisdiskrete Simulation wird vorwiegend zur Unterstützung operativer Entscheidungen wie z.B. Personaleinsatz, Patientenplanung, Ressourcenausstattung, Bettenzuweisungen oder Layout von Gebäuden verwendet [5, 7, 10]. Auffallend ist der Fokus auf isolierte Krankenhausteilbereiche wie

einzelne Stationen, die Notaufnahme oder Operationssäle und die versuchte Problemlösung innerhalb dieser, wie es der Großteil der Studien vor 2010 dokumentieren [5, 7, 8]. Da Krankenhausprozesse komplex miteinander verflochten sind, kann eine isolierte Betrachtung die Realitätsnähe der Modelle erheblich negativ beeinflussen [8]. Zusätzlich können dadurch keine verallgemeinerbaren Erkenntnissen für ähnliche Problemstellungen abgeleitet werden [7].

Eldabi et. al. sowie *Gunal et. al.* hinterfragen die Sinnhaftigkeit von Publikationen, die wenig praktischen Nutzen und überdies wenig theoretischen Mehrwert für andere Forscher bieten. Solange ähnliche Probleme mit ähnlichen Modellen gelöst werden, wird sich die Forschung zur Simulation im Krankenhauskontext nicht weiterentwickeln, so die Autoren [6, 7].

Anforderungen an zukünftige Studien sind demnach die Entwicklung integrierter Modelle, die die Komplexität der Krankenhausrealität möglichst umfassend darstellen können [5, 7], die Herleitung allgemeingültiger Aussagen sowie die transparente Darstellung des praktischen Nutzens [7].

Eine aktuelle Studie zur Effizienzsteigerung in der Notaufnahme eines Klinikums in Wales nimmt die genannte Kritik teilweise auf und ermittelt Schwachstellen im Patientenfluss der Notaufnahme. Verglichen werden Simulationsergebnisse einer perfekten Welt ohne Ressourcenbeschränkungen mit Ergebnissen der simulierten Ist-Situation. Die Differenz der beiden Modelle zeigt die Schwachstellen bei gleichem Patientenaufkommen. Es konnten ein effizienter Personal- und Ressourceneinsatz, sowie die nötigen Investitionen ermittelt werden, um die gegebenen Qualitätsziele zu erreichen [2].

Coughlan et. al. ist es gelungen, die dynamischen Re-Priorisierungsstrategien zur Reduzierung von wartenden Patienten in der Notaufnahme eines Londoner Krankenhauses valide nachzubilden. Ziel dieser Strategien ist es, Patienten spätestens nach vier Stunden Wartezeit in der Notaufnahme zu entlassen, oder aufgenommen zu haben. Aufgrund der Vielzahl von verschiedenen Diagnose- und Therapiemethoden wurden diese jeweils in einem Prozessschritt zusammengefasst. Differenziert werden die einzelnen Methoden durch ermittelte Verteilungen für Nutzungswahrscheinlichkeit und Dauer. Die Ergebnisse zeigen anhand der starken Korrelation ($r = 0,98$) zwischen tatsächlicher und simulierter Wartezeit die Validität des Modells [4].

Eine Hilfestellung bei der Erstellung von Simulationsmodellen liefert die Arbeit von *Gunal*. Basierend auf Literaturrecherchen und eigenen Erfahrungen werden die konzeptionelle, sowie die technische Sichtweise einer Simulationsstudie im Krankenhauskontext erläutert. Die Modellierung der komplexen Beziehungen zwischen Dienstleistungen und Aktivitäten am Patient stellt nach Meinung des Autors eine der größten Herausforderungen in der Krankenhausmodellierung dar. Dabei stellt die ereignisdiskrete Simulation u.a. aus Gründen der Modellflexibilität, Verfolgbarkeit einzelner Individuen, sowie der Möglichkeiten zur Abbildung stochastischer Komponenten eine häufig eingesetzte Methode zur Evaluierung von Verbesserungsmaßnahmen dar [6].

Die vorliegende Studie orientiert sich an den genannten Anforderungen und Hilfestellungen und bildet zur Evaluierung von Verbesserungsmaßnahmen des Belegungsmanagements den gesamten stationsübergreifenden Patientenfluss in einem ereignisdiskreten Simulationsmodell ab. Wie in [2, 4, 6] beschrieben, entsprechen die Entitäten den Patienten, die sich charakteristisch für beobachtete Patiententypen durch ein Prozessnetzwerk bewegen und Ressourcen für Behandlungen und stationäre Aufnahmen benötigen. Grundlegende Einflussfaktoren wie bspw. Ankunftsdaten, Prozessdauern und Übergangswahrscheinlichkeiten werden wie in [2, 4, 6] beschrieben verwendet. Dabei erhebt das entwickelte Modell den Anspruch, für ähnliche Strukturen in anderen Krankenhäusern angewendet werden zu können. Die Simulation berücksichtigt reale Belegungskapazitäten in der zentralen

Notfallaufnahme und den einzelnen Stationen. Praxisrelevanz ist durch die Entscheidungsunterstützung aktueller Diskussionen zu Verbesserungsmaßnahmen im UKH gegeben.

3 Simulationsmodell für Patientenflüsse im Krankenhaus

3.1 Patiententypen zur Differenzierung der Patientenflüsse

Im Universitätsklinikum konnten drei verschiedene Patiententypen im Hinblick auf deren Bewegung durch die Bereiche des UKH identifiziert werden:

Ambulante Notfallpatienten werden in der Zentralen Notfallaufnahme (ZNA) behandelt und im Anschluss wieder entlassen. In einzelnen Fällen (z.B. zum Ausschluss eines Myokardinfarktes) werden diese Patienten auf der Überwachungseinheit aufgenommen. In Jahr 2011 wurden von insgesamt 26.366 behandelten ambulanten Patienten ca. 1,35% auf der Überwachungseinheit untergebracht.

Stationäre Notfallpatienten müssen nach der Behandlung auf der ZNA von einer Station des Krankenhauses stationär aufgenommen und versorgt werden. Der Aufenthalt in der ZNA kann sich aufgrund einer medizinisch notwendigen Überwachungsphase in der Überwachungseinheit verzögern. Die darauf folgende Verlegung kann jedoch nicht in allen Fällen direkt im Anschluss durchgeführt werden: Zum einen erfolgen Verlegungen nur tagsüber, zum anderen muss die jeweils vorgesehene Nachfolgestation die benötigten Ressourcen zur Verfügung stellen können. Ist auch nur eine dieser Bedingungen nicht erfüllt, muss der Patient zur Überbrückung weiterhin auf der Überwachungseinheit untergebracht werden. In diesem Fall entsteht Wartezeit auf der ZNA. Von den insgesamt 9.718 stationären Notfallpatienten mussten 10,3% kurzzeitig auf der Überwachungsstation betreut werden.

Elektive Patienten mit anstehenden Behandlungen, deren Zeitpunkte verhältnismäßig frei wählbar sind, werden bei Ihrer Ankunft direkt auf der jeweiligen Station aufgenommen. Im Anschluss durchlaufen sie gegebenenfalls noch weitere Folgestationen bevor sie entlassen werden. Eine klinikinterne Verlegung kann nur erfolgen, wenn auf der Folgestation ein freies Bett zur Verfügung steht, andernfalls entsteht Wartezeit. Insgesamt wurden im Jahr 2011 23.936 elektive Patienten im Krankenhaus behandelt.

3.2 Simulationsmodell

Die vorgestellten Patiententypen dürfen aufgrund der Nutzung gleicher Ressourcen nicht losgelöst voneinander betrachtet werden. Daher wurde ein ereignisdiskretes Simulationsmodell in ARENA 10.0 (Rockwell Software) entwickelt, in dem die Entitäten den Patienten entsprechen. Die Bewegungen der Entitäten im Modell repräsentieren die für die beschriebenen Patiententypen charakteristischen Patientenflüsse. Da das Modell zu umfangreich und zu komplex für eine Abbildung ist, wird die umgesetzte Logik in einem vereinfachten Schema in Abbildung 1 veranschaulicht. Die Pfeile repräsentieren mögliche Bewegungen der Patienten zwischen verschiedenen Einheiten des Krankenhauses. Diese Einheiten stellen Ressourcen in Form von freien Betten zur Verfügung.

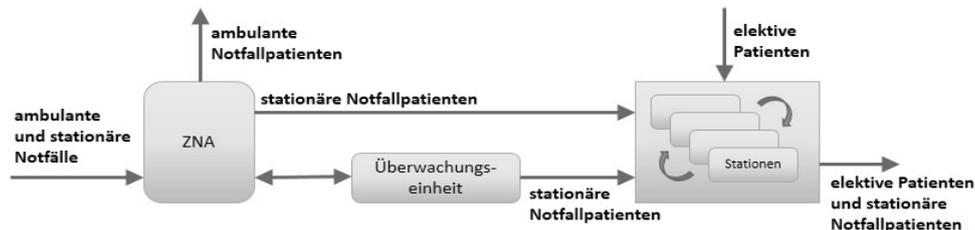


Abbildung 1: Schematische Darstellung der Simulationslogik

Die Bewegung einzelner Patienten im Modell wird durch empirische Verteilungsfunktionen, die sich aus den Ankunfts-, Aufenthalts- und Verlegungsdaten ergeben, bestimmt. Ausgewählte Charakteristika dieser Daten werden im vierten Kapitel beschrieben. Die Patientenflüsse werden ausschließlich mit Ankunfts- und Übergangsverteilungen und losgelöst von Diagnosen und Behandlungen abgebildet. Mit Hilfe dieser Übergangsverteilungen werden die zu durchlaufenden Stationen bei Ankunft der Patienten in einem individuellen Stationsplan hinterlegt. Dieser Plan wird im Modell sukzessive durchlaufen. Da bei Erstellung ausschließlich Ausgangs- und Folgestationen betrachtet werden, könnten Stationspläne entstehen, die im verwendeten Datensatz nicht dokumentiert sind. Aus Sicht der Gesamtkapazitäten der Klinik wird das Ergebnis davon kaum beeinflusst werden, da mit sehr niedriger und abnehmender Wahrscheinlichkeit Patienten in eine zweite oder dritte Station verlegt werden.

Neben den patientenspezifischen Falldaten wurden für das Simulationsmodell Daten zu Anzahl und Verteilung vorhandener Krankenhausbetten, aufgeschlüsselt nach Stationen und verfügbaren Zimmer erhoben.

Mögliche Bettenengpässe können entstehen, wenn eine Vielzahl stationärer Patienten aus der ZNA zu einer bestimmten Station verlegt werden müssen. In diesem Fall verbringen die Patienten ihre Wartezeit auf der Überwachungseinheit. Diese wird im Modell als Kennzahl „Wartezeit von ZNA auf Folgestation“ gemessen. Wartezeiten bei innerklinischen Verlegungen entstehen ebenfalls durch Bettenengpässe auf der Folgestation. Diese Wartezeit wird durch einen verlängerten Aufenthalt auf der gegenwärtigen Station überbrückt und als „Wartezeit von Station auf Folgestation“ erfasst. Um stationäre Aufnahmen sowie innerklinische Verlegungen auf Stationen realistisch abbilden zu können, müssen wichtige Nebenbedingungen bei der Bettenbelegung in den Einzel- und Mehrbettzimmern berücksichtigt werden. Dies wird mit einer im Modell eingebetteten Heuristik erreicht.

3.3 Heuristik für die Bettenbelegung an den Stationen

Voraussetzung einer erfolgreichen Patientenverlegung ist es sicherzustellen, inwieweit die Nachfolgestation in der Lage ist, den Patienten in einem geeigneten Zimmer unterzubringen. Inwieweit ein freies Bett vergeben werden kann, wird vom Krankenhauspersonal koordiniert. Hierbei gilt, dass jedes Zimmer nur mit Patienten des gleichen Geschlechts belegt werden darf. Nur vereinzelt gibt es Stationen, darunter die Intensivstationen, bei denen diese Regelung nicht gilt. Weiterhin müssen Patienten, bei denen ein multiresistenter Keim diagnostiziert wurde, isoliert untergebracht werden. Isolation bedeutet in diesem Kontext die Unterbringung in einem Einzelzimmer oder die alleinige Unterbringung in einem Mehrbettzimmer.

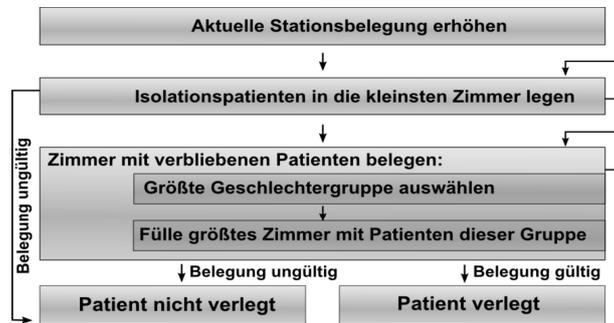


Abbildung 2: Heuristik zur Bettenbelegung

Da im Krankenhausalltag die Bettenbelegung durch Mitarbeiter der jeweiligen Stationen koordiniert wird, wurde eine Heuristik (siehe Abbildung 2) entwickelt, die diesen Entscheidungsprozess realistisch nachbildet. Die hierfür formulierte Heuristik prüft bei jeder Belegungsänderung einer Station, ob es für die jeweilige Stationsbelegung und die zur Verfügung stehenden Zimmer eine Belegungsvariante gibt, bei der alle Nebenbedingungen erfüllt sind. Hierzu werden die verfügbaren Zimmer einer Station, die gewünschte Stationsbelegung, das Geschlecht sowie der Isolationsstatus des Patienten benötigt. Die Heuristik lässt sich in drei Teilschritte gliedern:

- (1) Alle an einem multiresistenten Keim erkrankten Patienten werden einzeln auf die kleinsten verfügbaren Zimmer verteilt.
- (2) Alle verbliebenen Patienten werden nun auf die übrigen Zimmer, beginnend bei dem größten verteilt. Dabei ist folgendes zu beachten: Sollte es unter den verbliebenen Patienten mehr Männer geben, so wird das größte verfügbare Zimmer mit Männern belegt. Wenn es hingegen mehr Frauen sind, so wird dieses Zimmer mit Frauen belegt.
- (3) Die Heuristik endet, sobald alle Patienten erfolgreich auf entsprechende Zimmer verteilt wurden (gültige Belegung) oder keine freien Zimmer mehr für verbliebene Patienten verfügbar sind (ungültige Belegung). Im Falle einer ungültigen Belegung werden verbliebene Patienten in der Simulation nicht verlegt und es entstehen Wartezeiten.

4 Analyse der Patientenfalldaten für die Simulation

Die Informationen bezüglich der Patientenankunft, Aufenthaltsdauer, sowie der Verlegungsprozesse wurden aus einem anonymisierten Falldatensatz des UKH gewonnen. Dieser Datensatz umfasst insgesamt 60.020 Falldaten aus dem Zeitraum vom 01.01.2011 bis zum 31.12.2011. Jede Patientenaufnahme sowie jeder Stationswechsel ist dokumentiert. Im Folgenden werden ausgewählte Charakteristika der Patientenankünfte, der Aufenthaltsdauern und der Verlegungsprozesse vorgestellt.

4.1 Patientenankunftsdaten je nach Patiententyp

Um die Anzahl der Patienten pro Tag und Station zu bestimmen, muss sowohl der Wochentag als auch das Geschlecht des Patienten berücksichtigt werden. Abbildung 3 zeigt die Verteilung der Patientenankünfte für elektive Patienten sowie ambulante und stationäre Notfallpatienten im Wochenverlauf. Erkennbar ist, dass elektive Patienten vor allem zu Beginn der Woche bestellt werden. Ambulante Notfallpatienten hingegen werden seltener an Werktagen, sondern meist am

Freitagnachmittag sowie am Wochenende behandelt. Bei stationären Notfallpatienten ist eine konstante Ankunftsrate zu erkennen.

Neben dem Wochenverlauf ist eine getrennte Betrachtung der Verteilung männlicher und weiblicher Patienten durchzuführen. Während diese Verteilung für eine Entbindungsstation naturgemäß bekannt ist, sind nicht offensichtlich unterschiedliche Verteilungen in anderen Stationen aufgrund einer realistischen Abbildung der jeweiligen Ankunftsrate nötig.

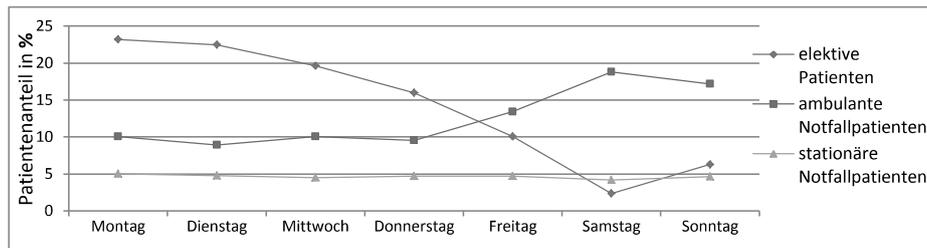


Abbildung 3: Wochenverlauf Patientenankünfte ja Patiententyp [eigene Darstellung]

Neben den Ankunftsschwankungen innerhalb einer Woche kommt es auch zu Unregelmäßigkeiten innerhalb eines Tages. Abbildung 4 zeigt, dass elektive Patienten vermehrt vormittags bestellt werden. Beispielsweise erreichen 18% aller am Dienstag ankommenden Patienten das Krankenhaus zwischen 10.00 Uhr und 11.00 Uhr. Im Gegensatz dazu zeigt sich bei Notfallpatienten eine andere Tagesverteilung. Sowohl bei ambulanten als auch bei stationären Notfallpatienten kommt es, im Gegensatz zu elektiven Patienten, zu deutlich weniger Schwankungen im Tagesverlauf der Ankünfte. Vergleich man ambulante und stationäre Ankünfte, so fällt auf, dass ambulante Patienten vorwiegend am späten Nachmittag das Krankenhaus erreichen. Lediglich an den Wochenendtagen kommt es vermehrt zu Ankünften am Vormittag. Bei den stationären Patientenankünften lässt sich kein Unterschied zwischen den einzelnen Tagesverläufen feststellen. Die Ankünfte sind vom Vormittag bis zum Abend gleichbleibend.

Die Analyse der Jahresdaten im Wochen- und Tagesverlauf ermöglicht eine realistische stundengenaue Abbildung der Patientenströme in der Simulation. Dieser Detaillierungsgrad erlaubt es, krankenhausweite Verzögerungen im Stunden- bis Minutenbereich zu erfassen.

4.2 Aufenthaltsdauer und Patientenentlassung im Wochenverlauf

Neben den Ankunftsdaten wurde die Aufenthaltsdauer der Patienten auf den Stationen analysiert. Vergleicht man die durchschnittliche Verweildauer verschiedener Stationen, so können hier starke Unterschiede beobachtet werden. Dies kann mit der medizinischen Ausrichtung einer Station und dem hiermit verbundenen Schweregrad der behandelten Krankheiten begründet werden. Konkret wurden Verweildauern von durchschnittlich 1,32 bis zu 10,4 Tagen festgestellt.

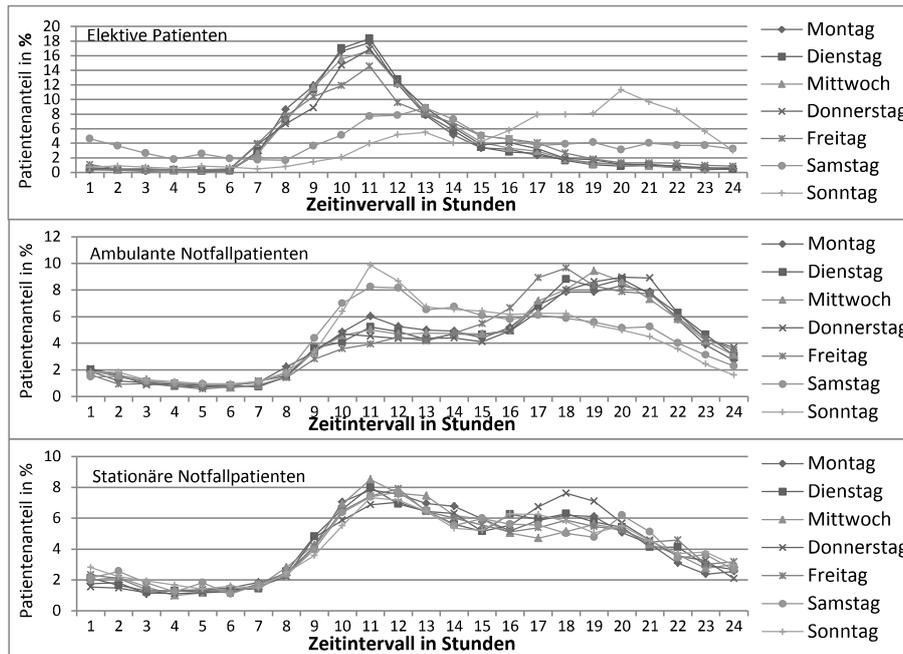


Abbildung 4: Tagesverlauf Patientenankünfte je Patiententyp [eigene Darstellung]

Das Ende eines Stationsaufenthaltes, bestimmt den Entlassungs- bzw. den Verlegungszeitpunkt eines Patienten. Hier ist zu beachten, dass, falls der Patient im Anschluss seines Stationsaufenthaltes entlassen werden soll, der Stationsaufenthalt tendenziell an einem Werktag und seltener an einem Wochenende endet. Dies wird in Abbildung 5 anhand von fünf gewählten Beispielstationen deutlich. Es ist zu erkennen, dass der Anteil der Entlassungen zum Freitag leicht steigt und anschließend deutlich abfällt, wodurch am Sonntag nur ca. 5% aller Entlassungen stattfinden.

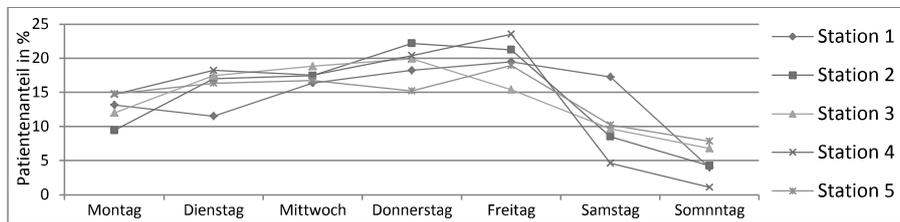


Abbildung 5: Patientenentlassungen im Wochenverlauf [eigene Darstellung]

Die Verweildauer, wie sie im Krankenhausinformationssystem erfasst wird, setzt sich aus dem eigentlichen Stationsaufenthalt und einer eventuell entstandenen Wartezeit zusammen. Im Simulationsmodell soll die Wartezeit jedoch nicht als Eingabegröße einfließen, sondern später als Ergebnisgröße gemessen und zum Szenarienvergleich herangezogen werden. Bei der Berechnung einer Patientenverweildauer musste daher sowohl der Entlassungstermin, als auch die in der Verweildauer eingeschlossenen Wartezeit berücksichtigt werden.

4.3 Verlegungsprozesse

Um die Verlegungsprozesse eines Patienten korrekt abbilden zu können, wird für jeden Patienten ein individueller Stationsplan erzeugt. Dazu wurde ausgehend von der ersten Station eines Patientenfalls die Verteilung der insgesamt zu durchlaufenden Stationen bestimmt. Um die Art sowie die Reihenfolge der zu durchlaufenden Stationen zu bestimmen, wurden Übergangswahrscheinlichkeiten für alle Stationspaaren bestimmt. Dabei ergab die Datenanalyse, dass die Zielstation durch die aktuelle Station sowie durch das Geschlecht des Patienten beeinflusst wird. Beispielsweise werden ca. 41,7% aller männlichen Patienten von Station 2, sollte eine Verlegung stattfinden, im Anschluss auf Station 3 weiterbehandelt.

5 Szenarien flexibler Bettenbelegung zur Verringerung der Wartezeiten

Im Rahmen der Studie haben die Autoren zusammen mit Mitarbeitern der ZNA sowie der zentralen Pflegeforschung des UKH drei, teils bereits im Klinikum diskutierte und teils von den Autoren gestaltete Szenarien entwickelt. Zusätzlich zu der Forderung des UKH, eine ganzheitliche Betrachtung der Klinikumsprozesse zugrunde zu legen, wurden bei der Entwicklung der Szenarien neben der Reduktion von Wartezeiten folgende Ziele verfolgt:

- Freie Kapazitäten an den Stationen sollen besser genutzt werden können und somit eine bessere Auslastung unter Beachtung aller Patientenflüsse ermöglichen.
- Es sollen nur Strategien und Verbesserungsmaßnahmen in Erwägung gezogen werden, die geringe Anpassungen von Prozessen und Strukturen voraussetzen.
- Szenarien sollen nach Möglichkeit investitionsarm und mit wenig Aufwand umsetzbar sein.

Mit Blick auf die genannten Anforderungen konnte in Diskussionen mit dem UKH-Personal die Idee einer Flexibilisierung der Belegung entwickelt werden. Dabei wurden drei mögliche Formen flexibler Belegungen identifiziert, welche zu folgenden drei umsetzbaren Szenarien geführt haben:

[S1] Flexible Belegung durch Zimmerverleih an räumlich angrenzende Stationen,

[S2] Flexible Belegung durch Zusammenführung der ITS- und IMC-Stationen und

[S3] Flexible Belegung durch Einführen einer Früh-Reha als Endphase stationärer Behandlung

Unter Betrachtung der allgemeinen Struktur der Patientenflüsse, zielt Szenario [S3] auf die Schaffung freier Kapazitäten durch eine Entlassung bestimmter Patientengruppen in die Früh-Reha am Ende des Patientenflusses ab. Dadurch könnte die Verweildauer auf den entlassenden Stationen verkürzt werden. Dies ist aus Ressourcensicht des UKH sinnvoll, da die gewonnen Kapazitäten für weitere elektive und stationär übernommene Notfallpatienten verwendet werden können. Allerdings ist das Einführen einer solchen Station medizinisch aufgrund der Vielfalt von zu behandelnden Krankheitsbildern und den daraus resultierenden hohen Anforderungen an das eingesetzte Personal umstritten. Effektiv umsetzbar ist dies nur durch eine eigens dafür eingesetzte Station [12].

In Szenario [S1] können Engpässe durch den Verleih nicht genutzter Zimmer von räumlich angrenzenden Stationen vermieden werden. Insgesamt wurden vom Krankenhaus acht potentielle Tauschpartner identifiziert. Dies hat im Gegensatz zu [S3] Vorteile in allen Phasen des Patientenflusses, insbesondere zur Überwindung stochastisch verteilter zeitlich beschränkter Engpässe. Weiterhin wird dieser Pooling-Ansatz bereits in einigen Stationen des UKH umgesetzt. Aufgrund der Befürchtung, dass durch den Zimmerverleih für einen der Tauschpartner Ressourcenengpässe entstehen könnten, lehnen manche Stationen diesen Ansatz bisher jedoch ab.

Ziel des Szenarios [S2] ist das Pooling aller ITS- sowie aller IMC-Stationen (Intensivtherapie- und Intermediate-Care-Stationen). Dadurch werden bei Zimmern mit hohen Personal- und Ressourcenkosten Kapazitätsengpässe innerhalb wichtiger Phasen der Patientenflüsse, z.B. in postoperativen Phasen, abgebaut. Die Einführung zentraler ITS- und IMC-Stationenpools [S2] wird aktuell im UKH diskutiert und ist gängige Praxis in kleineren Kliniken [1]. Dies hätte den Vorteil, dass die verfügbaren Bettenkapazitäten gebündelt werden und dass bei Verlegungen aus der ZNA auf ein ITS- oder IMC-Bett direkt in den Pool verlegt werden kann. Als nachteilig werden die nötige interdisziplinäre Versorgung und die damit einhergehenden Anforderungen an Personal und Ausstattung angesehen.

6 Simulationsergebnisse und weiterer Forschungsbedarf

Die folgenden Simulationsergebnisse stammen aus Simulationsläufen mit der Dauer eines Jahres. Die Modellvalidierung erfolgte durch den Vergleich der Messwerte des simulierten Ist-Zustandes mit den Vergleichswerten aus dem Falldatensatz des Jahres 2011. Zur Auswertung der Szenarien [S1], [S2] und [S3] wurden die zuvor ermittelten Messwerte des Ist-Modells mit den durch die Simulation ermittelten Messwerten der Szenariokonfigurationen verglichen.

6.1 Validierung des Simulationsmodells mit Jahresdaten des UKH

Am Beispiel der Patientenzahl, der Verweildauern und der Ankunftsverteilung stationärer Notfallpatienten wird ersichtlich, dass das Modell die Realität mit hinreichender Genauigkeit widerspiegelt. Tabelle 1 zeigt, dass die Anzahl ambulanter und stationärer Patienten im Simulationsmodell nur geringe Abweichungen gegenüber den Vergleichswerten aufweisen. Lediglich elektive Patienten sind mit einer Abweichung von -15,6% deutlich unterrepräsentiert. Da elektive Patienten im Simulationsmodell stochastisch erzeugt werden, im Realsystem jedoch geplant und vorhersehbar sind, wurde die Anzahl elektiver Patienten bewusst verringert um diesem Effekt entgegenzuwirken.

	Vergleichswerte Falldatensatz 2011	Messwerte Ist-Modell
Elektive Patienten	23.936	20.185,63
Ambulante Notfallpatienten	26.366	25.682,03
Stationäre Notfallpatienten	9.718	9.781,2

Tabelle 1: Validierung der Patientenzahlen je nach Patiententyp [eigene Darstellung]

Neben den Ankunftsdaten zeigt sich auch bei den Verweildauern eine Übereinstimmung mit den Messwerten des Ist-Modells. Da sich die Verweildauer, wie sie in Kapitel 4 beschrieben wurde, aus dem Stationsaufenthalt und einer eventuell entstandenen Wartezeit zusammensetzt, musste die Verweildauer im Simulationsmodell auf die selbe Art erhoben werden. Das linke Diagramm in Abbildung 6 zeigt, dass die gemessenen Verweildauern mit den gegebenen Werten im Mittel übereinstimmen.

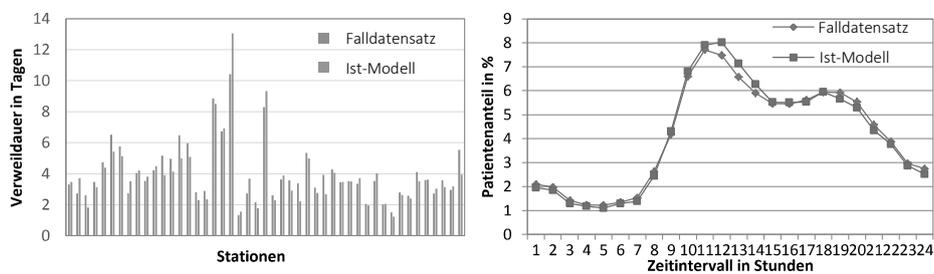


Abbildung 6: Validierung der Stationsverweildauer [eigene Darstellung]

Am Beispiel der stationären Notfallpatienten soll im letzten Schritt gezeigt werden, dass die Ankunftsverteilungen, wie sie in Kapitel 4 beschrieben wurden, korrekt umgesetzt werden konnten. Das rechte Diagramm in Abbildung 6 zeigt den durchschnittlichen Tagesverlauf stationärer Patientenaufnahmen in der ZNA. Es ist zu erkennen, dass die gemessenen Werte des Simulationsmodells den tatsächlichen Verlauf der Ankünfte sehr gut abbilden.

6.2 Simulation und Evaluation von Veränderungsszenarien für die UKH

Das validierte Simulationsmodell konnte anschließend für eine zuverlässige Evaluation der drei Szenarien angewendet werden. Dabei hatten [S1] und [S2] einen größeren Einfluss auf die Verringerung der Wartezeiten als [S3]. Bei den für die Früh-Reha in Frage kommenden Patientengruppen ergaben die Analysen, dass diese Gruppen selten in Engpassstationen auftraten, sodass die Wartezeiten auf der Bettenstation der ZNA sowie auf den Stationen vor klinikinternen Verlegungen nur geringfügig reduziert wurden.

Zimmerverleih-Szenario [S1]

In Abbildung 7 sind die Tauschpaare räumlich angrenzender Stationen, die mittleren Wartezeiten eines Patienten bei Verlegung von einer Station auf eine andere sowie die Wartezeit bei stationärer Aufnahme von der ZNA dargestellt. Aus dem Vergleich dieser Wartezeiten zwischen Ist-Modell und [S1] wird ersichtlich, dass die Wartezeit bei stationären Verlegungen um bis zu 10 Stunden verringert werden konnte. Die Wartezeit auf stationäre Übernahme von der ZNA konnten ebenfalls um bis zu 50% verringert werden. Die befürchtete Benachteiligung einzelner Tauschpartner trat nicht ein.

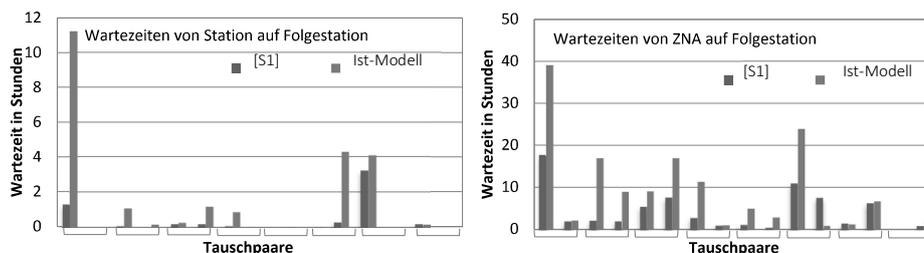
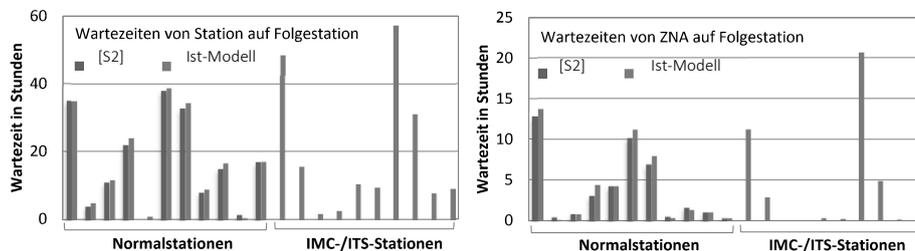


Abbildung 7: Wartezeiten im Szenario S1 [eigene Darstellung]

Zusammenführung zentraler ITS- und IMC-Stationen [S2]

In Abbildung 8 sind die mittleren Wartezeiten eines Patienten bei einer Verlegung zwischen Stationen. Ohne Zusammenlegung der ITS- und IMC-Stationen bildeten sich Bettenengpässe, die dazu führten, dass in einem Jahr ca. 1.170 Patienten auf eine Nachfolgestation warten mussten. Die Wartezeit betrug hier bis zu 20,7 Stunden. Werden ITS- und IMC-Stationenpools gebildet, entstehen keine Wartezeiten mehr an den entsprechenden Stationen. Ein negativer Einfluss auf andere Stationen konnte nicht festgestellt werden. Für die Überwachungseinheit, die Notfallpatienten bei Engpässen nachfolgender Stationen aufnimmt, bedeutet dies ebenfalls eine Entlastung. Auch hier können, wie in Abbildung 8 dargestellt, die Wartezeiten vollständig abgebaut werden.



6.3 Fazit und weiterer Forschungsbedarf

Das in diesem Aufsatz entwickelte Simulationsmodell für stationsübergreifende Patientenflüsse wurde anhand der verfügbaren Jahresdaten des UKH erfolgreich validiert. Die Evaluation der in Zusammenarbeit mit dem UKH entwickelten Szenarien flexibler Bettenbelegung zeigte eine deutliche Verringerung der Wartezeiten und Verweildauern. Die Ergebnisse bei Einführung eines zentralen ITS- und eines IMC-Pools zeigen, dass das Pooling von ITS und IMC auch für größere Kliniken deutliches Potential besitzt. Die Vorurteile einseitiger Vorteilsnahme und möglicher entstehender Engpässe im Zimmerverleih-Szenario [S1] konnten ausgeräumt werden. Die Einführung einer zentralen Früh-Reha ist unter den analysierten Umständen in Hinblick auf den zu erwartenden hohen Einführungsaufwand und die geringen Auswirkungen auf die Wartezeit nicht zielführend.

Die gewählte Modellierung der Patientenflüsse auf Basis von Übergangsverteilungen ist ausreichend, um Verbesserungsmaßnahmen, die den krankenhausweiten Patientenfluss betreffen, zu evaluieren. Nicht im Datensatz dokumentierte Stationspläne beeinflussten die Validität des Modells nicht. Da bei der Modellierung ausschließlich routinemäßig erfasste Falldaten verwendet wurden sowie auf die Modellierungen krankenhausspezifischer Logik verzichtet wurde, kann das Modell mit wenigen Anpassungen für Kliniken mit ähnlicher Struktur und ähnlichen Fragestellungen angewendet werden.

Die genannten Ergebnisse wurden dem Klinikvorstand präsentiert, der einen Mehrwert für die Entscheidungsfindung im Klinikum durch unsere Simulationsanalysen anerkannte und anregte, die Simulation mit vorliegenden aktuellen Daten und der Berücksichtigung der fachlichen Kompatibilität bei den Szenarien flexibler Belegung durchzuführen. Vor einer Umsetzung in die Praxis sind genauere pflegerisch-therapeutischen Analysen durchzuführen, um potentielle kompatible ITS- und IMC-Stationen zu identifizieren. Des Weiteren soll das Szenario flexibler Belegung durch Zimmerverleih in aktuelle Gedanken zur Bildung fachlicher Cluster im UKH integriert werden. Wir haben angeregt, dass alle Paare fachlich kompatibler Partner vom UKH bestimmt werden. Die optimalen Cluster können dann durch unsere um Wiederverwendbarkeit und Objektorientierung verbesserten Simulationsmodelle verknüpft mit einer Optimierungskomponente (vgl. Kapitel 9.5 in [14]) bestimmt werden. Ob die Einführung einiger auf bestimmte Krankheitsbilder spezialisierter Früh-Reha-Stationen sinnvoll ist und welche Krankheitsbilder sich für diese Stationen am besten eignen, bleibt ebenfalls Gegenstand weiterer Forschung.

7 Literatur

- [1] Aken, H.K. van (2007): *Intensivmedizin*. G. Thieme.
- [2] Baboolal, K., Griffiths, J.D., Knight, V.A., Nelson, A.V., Voake, C. and Williams, J.E. (2012): How efficient can an emergency unit be? A perfect world model. *Emergency Medicine Journal*
- [3] Brailsford, S.C., Harper, P.R., Patel, B. and Pitt, M. (2009): An analysis of the academic literature on simulation and modelling in health care. *Journal of Simulation*. 3(3): 130–140.
- [4] Coughlan, J., Eatock, J. and Patel, N. (2011): Simulating the use of re-prioritisation as a wait-reduction strategy in an emergency department. *Emergency Medicine Journal*. 28(12): 1013–1018.
- [5] Eldabi, T., Paul, R.J. and Young, T. (2006): Simulation modelling in healthcare: reviewing legacies and investigating futures. *Journal of the Operational Research Society*.

-
- [6] Günal, M.M. (2012): A guide for building hospital simulation models. *Health Systems*. 1(1): 17–25.
- [7] Günal, M.M. and Pidd, M. (2010): Discrete event simulation for performance modelling in health care: a review of the literature. *Journal of Simulation*. 4(1): 42–51.
- [8] Jacobson, S.H., Hall, S.N. and Swisher, J.R. (2006): Discrete-event simulation of health care systems. *Patient flow: reducing delay in healthcare delivery*. Springer. 211–252.
- [9] Jun, J.B., Jacobson, S.H. and Swisher, J.R. (1999). Application of Discrete-Event Simulation in Health Care Clinics: A Survey. *The Journal of the Operational Research Society*. 50(2): 109–123.
- [10] Klein, R.W. and Dittus, M. (1993): Simulation Modeling and Health-care.
- [11] Mustafee, N., Katsaliaki, K. and Taylor, S.J.E. (2010): Profiling Literature in Healthcare Simulation. *SIMULATION*. 86(8-9): 543–558.
- [12] Reißhauer, A., Liebl, M. and Pögel, S. (2011): Fachübergreifende Frührehabilitation – Warum im Akutkrankenhaus? *Physikalische Medizin, Rehabilitationsmedizin, Kurortmedizin*. 21(06): 280–283.
- [13] Statistisches Bundesamt 2013. Pressemitteilung vom 4. April 2013 – 128/13 Gesundheitsausgaben im Jahr 2011 bei rund 294 Milliarden Euro.
- [14] Suhl, L. and Mellouli, T. (2013): *Optimierungssysteme: Modelle, Verfahren, Software, Anwendungen*. Springer.

D. A Generic Simulation-based DSS for Evaluating Flexible Ward Clusters in Hospital Occupancy Management

Helbig, K, Stoeck, T und Mellouli, T, (2015)

In: Proceedings of the 48th Annual Hawaii International Conference on System Sciences, pp. 2923–2932. IEEE (2015). DOI 10.1109/HICSS.2015.354. URL <http://ieeexplore.ieee.org/document/7070169/>

2015 48th Hawaii International Conference on System Sciences

A Generic Simulation-based DSS for Evaluating Flexible Ward Clusters in Hospital Occupancy Management

Karsten Helbig¹
karsten.helbig@wiwi.uni-halle.de

Thomas Stoeck¹
thomas.stoeck@wiwi.uni-halle.de

Prof. Dr. Taïeb Mellouli¹
mellouli@wiwi.uni-halle.de

¹Department of Management Information Systems and Operations Research, Martin-Luther-University Halle-Wittenberg

Abstract

Hospitals facing competitive pressure, a fortiori unprofitable ones, should improve their efficiency. We propose low-investment opportunities uprating patient treatment by tactically implementing hospital-wide occupancy clusters raising bed resource allocation flexibility. We develop a generic simulation-based DSS to evaluate cluster configurations for a 1000+ bed university hospital. Besides current state of bed resources and patient flow, prospective scenarios with less beds—raising their utilization rate—and with 50% more elective patients are evaluated.

Our data-driven DSS generates entire simulation models automatically from standard hospital data. Practical constraints like gender room separation and isolated infections treatment prevent underestimating bed requirements. Results show that clustering softens patient arrival peaks and induces dramatic reduction of bed bottleneck for all cluster configurations; yet more than 96% when including an internal medicine cluster. Doubling this cluster's size and introducing an interdisciplinary eleven wards surgery cluster induce the best-performing cluster configuration for bottleneck less-resource and more-patient scenarios.

1. Introduction

Health is the most valuable asset for humans. Keeping people healthy, however can become a difficult and expensive task, especially when focussing on hospital costs. These costs have been rising in Germany since 1990. According to rating reports of 2013, at least one third of all hospitals make a loss [1,4]. In order to break this trend, the German government decided to change the way hospitals earn their money. Since 2003 the diagnostics related groups payment system (DRG) is established. Since then,

each German hospital earns an amount of money for each patient case which is computed by the treatment costs of benchmark hospitals. If the costs of treating patients are higher than in the benchmark hospitals, the hospital has to improve their efficiency or may become insolvent after some time [19].

One way to improve efficiency is managing the occupancy of *the most expensive resource*—inpatient beds [3], since most of medical and administrative resources is dependent on treatment (bed) capacity. Only with this, an effective patient flow management is possible [18]. Without this, hospitals have to face higher lengths of stay (LOS), idle expensive resources and bottlenecks within patient care [26].

In our previous simulation study on reducing waiting time of admission from the emergency department (ED) to an inner ward, we figured out that one very promising way of improving efficiency of occupancy management is to increase bed resource flexibility. For the University Hospital Halle (Saale) we achieved more flexibility by allowing patients to be admitted to a cluster containing all intensive care units (ICU) on the one hand and on the other hand allowing wards to borrow rooms from other wards nearby [11]. Encouraged by our findings, the hospital management decided to implement ward clusters to improve the flexibility of bed allocation and avoid bottlenecks in ICU and ED.

A cluster is defined as an amount of wards (hospital units or departments) which are able to nurse all kinds of patients of each single other ward of the cluster. Because of that, if the actual ward has no idle bed capacity, it is possible to admit a patient to another ward on the cluster. E.g. if a patient has an eye disease and the actual ward has no idle bed, each other ward of the corresponding head cluster is able to admit him. Without the cluster, the patient would have to wait or be rejected in the worst case.

Because of the complexity and the high amount of dependencies within hospital processes, changes are full of risk and uncertainty. That is why DSS (decision support systems) are needed to evaluate possible consequences of different occupancy policies [20].

With respect to existing literature on using simulation in the hospital context in general and supporting occupancy decisions in particular, this article pursues three main goals: **First** we will develop a simulation model which is able to simulate the whole patient flow of a hospital in order to evaluate three given cluster configurations. **Second** we will show, that practical constraints like gender separation in rooms and isolated nursing of patient with infectious illnesses have to be added to models for hospital occupancy decision support. **Third** we will show how our model can be integrated in a data driven decision support system for easy reuse within other hospitals.

In order to describe our current results, this paper is structured as follows: In the second section, we discuss the current state of the art of using discrete event simulation (DES) in hospitals generally, in occupancy management context in particular and derive the research gaps. Based on this, we show in the third section our concept of a simulation-based data driven decision support system. In the fourth section, we describe the three cluster scenarios which have to be evaluated. In fifth section, we show our results and discuss the consequences for the hospital. At the end we give a short summary and an outlook on further research opportunities.

2. Related Work

The use of discrete event simulation (DES) has a long tradition in the hospital context. Based on studies of scientific articles of the past 40 years *Jacobson et al.* conclude: “Discrete-event simulation offers perhaps the most powerful and intuitive tool for the analysis and improvement of complex health care systems” [12]. This statement is underlined with a big number of surveys [5,8,9,12,13,16,21,24] showing, that nearly every hospital related aspect has been investigated successfully. DES is mostly used for operational decision support like deployment, resource utilization or occupancy management [7,8,16].

Regarding to the large amount of literature, the low practical and theoretical benefits [7,8] question the sense of simulation studies in hospital context in general. “[...] there is no general sense of the literature moving forwards, because many papers tend to be reports of rather similar work on rather similar problems” [8]. Most of the studies are focusing isolated hospital departments, but this could be misleading

with regard to the strongly complex and interdependent processes in hospitals [7,8,12].

To end this stagnancy in simulation science in hospitals, future studies should contain models that encompass the hospital and the relevant processes at whole, should lead to universal findings and practical benefit and could be reused or easily adapted to similar problems [7,8,9].

Particularly occupancy management is involved in nearly every hospital process [22]. Furthermore, *Black and Pearson* call inpatient beds “the most expensive resource” [3]. Based on this it is not surprising that there are a lot of articles focusing on the inpatient bed resource.

Because of the strong interdependencies between the wards of a hospital, only an approach which models more than one department, or the hospital as a whole could lead to valid results on bed capacity [23]. For this purpose we focus on related work that fulfill that condition.

Kim et al. used a simulation model to analyze the admission and discharge process of an intensive care unit (ICU). The authors successfully developed a simulation model that supports hospital’s administration to evaluate different policies for improving the ICU performance, show that the current capacity of 14 beds is sufficient at the current patient arrival rates and found some initial inferences how ICU performance could be improved generally by pointing to the managerial aspects and showing that the ICU’s capacity is not as important as the management of the other wards and its admission procedures [15].

In 2002 *Harper und Shahani* have shown that employing simple deterministic spreadsheet calculations to plan and manage bed capacities leads to underestimate true bed requirements. A realistic approach has to consider various types of patient flows at individual patient level and resulting bed needs over time. They underline that capturing the inherent variability of different length of stay distributions are important to develop planning tools for hospital capacities [10]. This confirms that misleading planning models are based on average length of stay, homogenous movement of patients through the system and ignoring the inherent heterogeneity of patients [25].

Costa et al. use simulation to estimate the number of required beds. The developed model is able to consider different admission criteria, priorities and expected lengths of stay based on the hospital’s own data. The authors underline this as the main strength of their approach [6].

Kolker developed a simulation model to figure out how many elective surgeries should be scheduled per day in order to reduce diversion in the ICUs. He shows that for his specific 450+ bed teaching hospital a

tradeoff between five surgeries per day with no length of stay less than 24 h would be best. In order to solve these kind of problems in general, *Kolker* describes three basic components that should be accounted for: the number of patients entering the system, the number of patients leaving the system and the capacity which limits the flow of patients through the system [17].

Khare et al. used a simulation model to show that altering the interval of admitted patient departure from the ED has more effect on length of stay than increasing the capacity of the ED [14].

Barado et al. analyzed patient data of 9 years and build a mathematical simulation model that is able to show the bed occupancy dynamics of the ICU at the Hospital of Navarra. The authors successfully developed a tool which is able to predict the bed occupancy rate and evaluate changes in patient admission factors like number of admissions of other hospital wards. They used their model to predict the number of beds needed in the ICU considering up to 50% more patient arrivals [2].

As mentioned in Section 1, we have developed a simulation model of a whole hospital to evaluate the effects on waiting time for patient admission from ED to inpatient wards of a university hospital with approx. 1000 beds in 2014. We analyzed hospital own data to model gender specific patient flows. In our results we found out that increasing flexibility by implementing occupancy clusters of ICU or the possibility to borrow rooms from other wards strongly reduces waiting time. Like [2,14] we could show that one key of increasing hospital performance is a more flexible occupancy management [11].

Encouraged by our findings in [11], the hospital management decided to implement occupancy clusters in the whole hospital and asks advice and assistance of our institute concerning simulation and evaluation.

Regarding to the related work on using simulation for decision support in occupancy management in particular and the critique on simulation based approaches in general, we address the following gaps: pursue a holistic view of the process through the hospital influencing occupancy management. For this we model the whole hospital and all necessary processes to evaluate different occupancy policies and we add practical room occupancy constraints in order to not underestimate bed capacity requirements. No other study takes these kind of constraints into account and we believe that our study will prevent producing misleading results as using average length of stay or homogenous patient flows [10,25].

Finally, we show a decision support system which is able to generate the model including structure and required distributions automatically by using hospital own data. Because of this data driven approach we

reach a new level of generality which is beyond simple change of model parameters. We believe this kind of architecture is necessary to ensure easy reusability and adaptability of the simulation model to other hospitals.

3. Data Driven Decision Support System

3.1. Architecture

In order to build a reusable and extendable information system we choose a modular approach. Basically the system consists of three modules which are independently interchangeable. The basic structure is shown in Figure 1. In this proposal we use a data processing component, a simulation component and a central database.

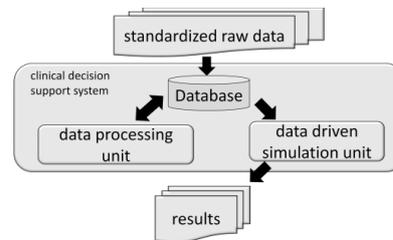


Figure 1. Structure of the information system

The central database stores the raw data provided by the hospital and the generated data needed by the simulation component. We implemented a MySQL database to ensure that the other components are able to access the stored data. For a more detailed view of the data needed, see Section 3.2.

Once the data is provided in a predefined format the data processing component is able to generate empirical distributions and other control data used by the simulation component. A short presentation of the distributions is given in Section 3.3. With the use of our data processing unit the only requirement to create all distributions is to load the hospital data into our database and push a button.

We decided to use the Simio simulation software to implement the simulation component because of its strictly object oriented modelling approach. Every part of the created model is an object with its own logic. Furthermore, the basic simulation logic and the behavior of the simulation model is determined by the interaction of the objects. We use the standard interface to a MySQL database in order to pass empirical distributions and control data to the simulation model. For a detailed look at the simulation model see Section 3.4.

The architecture of our proposed system provides various options for adaptation and reuse. First, the proposed decision support system provides customization options at the architecture level. Changes can be carried out with reasonable effort due to the modular structure of the system. If parts of the system are changed it does not affect the other components as long as the new components provide an interface to the database. If we want to change the simulation model, we have to ensure that the new model uses the same distributions and control data. Otherwise we have to alter the data processing unit and the database too.

Furthermore this implementation is independent from the observed hospital, because we can use generic objects to automatically build the simulation model with the help of the provided data. So if we want to use this system to evaluate another hospital we only have to load the new data and start the system.

In general, our system offers a simple process to evaluate different scenarios in different hospitals. This process consists of six steps that are independent from the hospital investigated (see Figure 2). First, the user has to store the raw data in the database. After that, he uses the data processing component in order to generate distributions and control data. With help of this data the simulation component automatically generates a model and the user is able to configure the scenarios he wants to evaluate. After running the model, he is able to evaluate the generated outputs.

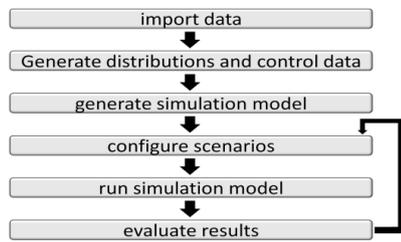


Figure 2. Process of DSS usage

3.2. Data

In order to generate the distributions and the simulation model, input data provided by the hospital is needed. To ensure an easy-to-use system, we focused on simple data every hospital should record or should have access to. Building the model is based on infrastructure data and patient data of a hospital. To generate a model, we only need a list of wards and a list of available rooms according to the wards and the amount of beds in each room (see Table 1).

Infrastructural data		
wards	rooms	amount of beds

Table 1. Required infrastructural data

Patient data we need is a record about every patient case passing the considered wards. If a patient visits four wards during its treatment at the hospital we need four records of this particular patient. Once more we focus on data which should already be recorded at the hospital like gender, LOS or whether this patient has an infectious illness (e.g. multi-resistant germs). The structure of patient data needed is shown in Table 2.

Patient data			
ID	time of admission	ward	LOS
Gender	time of discharge	previous ward	infectious

Table 2. Required patient data

For German hospitals, all these data can be found in the billing data set every hospital is obliged to create once a year due to the §21-KHentgG.

3.3. Data processing and distributions

The data described in the previous section is needed to generate empirical input data distributions. These distributions are mainly used to control the patient flow in the simulation model. In order to generate the distributions we use the data processing unit. Hence we calculate the number of arrivals for each day of week and arrival times. Additionally, we generate several other distributions describing for example the length of stay or the next ward a patient has to be transferred to. An overview of the distributions used in the simulation is given in Table 3.

distributions for arrival		
nr	name	conditioned on
1	number of arrivals	ward, day of week
2	number of arrivals ED	day of week
3	time of arrival	ward
4	time of arrival ED	day of week
distributions for patients		
nr	name	conditioned on
1	gender distribution	ward
2	gender distribution ED	
3	infectious	ward
4	infectious ED	
5	number of wards to visit	ward, gender
6	number of wards to visit ED	gender
distribution for wards		
nr	name	conditioned on
1	next ward	ward, gender
2	LOS	ward, day of week
3	LOS ED	gender

Table 3. Distributions needed by simulation

Each presented distribution is conditioned on certain attributes. For example the distribution of the next ward depends on the gender of the patient and on the current ward. Because of that we have to calculate a distribution for the next ward for every ward and every gender. Furthermore we did not notice any seasonal fluctuations in arrivals or other data. Thus, we decided to generate these distributions to fit a representative week. A more detailed presentation of the distributions and their relationships is given in our previous study [11].

3.4. Simulation model

To achieve our main goal, to develop a hospital-wide simulation model for evaluating occupancy cluster configurations, we implemented a simulation model based on two inpatient flows. The flow of emergency patients and the flow of elective patients. The difference between these groups of patients is the starting point in the hospital. Emergency patients start their treatment unplanned in the ED, whereas elective patients can be scheduled and are directly admitted to a ward. At the ward, both patient groups compete for hospital beds. A schematic overview of the considered patient flows is given in Figure 3.

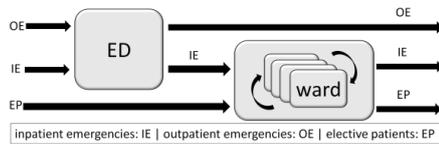


Figure 3. Patient flows

The presented patient flows were implemented in an object-oriented simulation model. Basically, this model consists of four custom objects we have developed using Simio. These objects represent the different departments of the hospital: hospital entrance, ED, ward and hospital exit, see Figure 4. The first object is the hospital entrance. Here the patients are generated and properties for each patient are set. Based on the computed distribution within the database each patient has the following set of properties: gender, infectious germ status and whether he is an elective or an emergency patient. Second, there is an object which describes the ED. The other components include the wards and the hospital exit. In the ED or at the wards, patients are treated.¹ The hospital exit is used to collect several statistics. These

objects altogether form the hospital which contains an additional allocation heuristic.

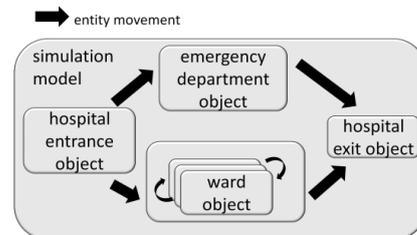


Figure 4. Model structure

A special feature of using an object oriented modelling approach is that the generated objects contain the processing logic. In our case the treatment process is encapsulated in the ward object. Basically, a patient is admitted to a ward, gets a treatment and is then discharged from the hospital or transferred to another ward. With these ward objects and the computed distributions we can easily create our model automatically. Furthermore the concept of object oriented programming offers additional concepts like inheritance or composition. For example, changing the behavior of some wards is easily done by inheritance. In that case a new type of ward object will be created including some new logic without altering the original ward object. As stated before in Simio the simulation model itself is an object. Because of that we are able to build models of different hospitals and compose them to a model of a hospital infrastructure of a city for example. This can probably be done with reasonable effort.

To ensure a maximal possible number of patient allocations meeting all practical constraints on a ward after patient relocation, which is actually carried out by the hospital staff in practice, we implemented a separate patient room allocation heuristic. We consider two special constraints during the relocation, namely gender separation in rooms and isolation of infectious patients. The heuristic is triggered every time a patient should move to a new ward, to find a valid bed allocation on this ward. It consists of the following three steps:

¹ In detail, the ED object is an inherited ward object without any special characteristics so far. We created it as proof-of-concept.

1. All patients with an infectious disease are isolated distributed to the smallest rooms.
2. All remaining patients are distributed to the other rooms starting with the largest room: (case 2.a) if there are more men among the remaining patients, the largest available room is occupied by men. (case 2.b) If there are equal or more women, the next largest room will be occupied by women.
3. The heuristic ends if all patients were successfully distributed (valid assignment) or if no more rooms are available for the remaining patients (invalid assignment). In that case the heuristic fails.

If the heuristic fails, all patients that could not be assigned to a valid bed will be assigned to a **virtual bed** instead. We decided to use this concept because of the following reason: The provided data for the LOS on a ward consists of medically necessary stay time and a possible waiting time on relocation. Unfortunately, there is no possible way separate these times from the total LOS. If the patient in our model would have to wait for relocation, his LOS will be greater than in reality. In other words, the patient has to be relocated in the model after his LOS has been reached, because in reality this happened too. But where should the patient be located in reality when

scenarios. Through changing the control data and model settings several scenarios can be combined. The proposed model enables the user to combine a clustering of wards with other scenarios. Thus, opportunities for capacity reduction, for increasing the number of patients and the change of admitting rules are offered. These possibilities can be freely combined.

4. Occupancy Cluster Configurations

The University Hospital Halle (Saale) consists of 47 wards and one ED. The hospital has a total number of approx. 1,000 beds and approx. 33,000 patients are treated every year. To increase the flexibility of bed allocation the management decided to implement ward occupancy clusters. Each cluster will contain a number of wards. Within a cluster all kinds of patients could be nursed by each containing ward. At first every ward basically tries to use its own beds. If there is no more capacity for another patient, this patient will be admitted to another ward of the cluster which has available capacities.

The management created the cluster configurations (CC) shown in Table 4 based on organizational and medical reasons. These configurations should be evaluated in order to find the most efficient usage of

cluster configuration 1 (CC-1)			cluster configuration 2 (CC-2)			cluster configuration 3 (CC-3)		
Nr	description	# wards	nr	description	# wards	nr	description	# wards
1	stomach cluster	10	1	stomach cluster	9	1	surgery cluster	11
2	chest cluster	8	2	chest cluster	7	2	head cluster	9
3	bone cluster	6	3	bone cluster	2	3	internal med. cluster	12
4	oncology cluster	3	4	oncology cluster	7	4	children/GEB/ZRA	5
5	children/GEB/ZRA	8	5	children/GEB/ZRA	5	5	oncology cluster	6
6	head cluster	9	6	head cluster	9	6	bone cluster	2
7	unassigned wards	3	7	internal med. cluster	6	7	unassigned wards	2
			8	unassigned wards	2			

Table 4. Cluster configurations

there is no valid bed available?

In practice, the hospital staff is quite creative in bridging the time until a valid bed is available. Thus we couldn't model all real world possibilities, but we could measure them in our model. We do this by using the concept of virtual beds. This concept is also the key to evaluate the occupancy policies later on. If a policy leads to a higher amount of virtual beds more cheating has to be done because of occurring occupancy problems.

Summarizing the design of our object-oriented model approach, the used concepts enable the user to automatically create the simulation model and change or modify existing objects easily. Thus, the model offers many ways to adapt it to changing conditions. In addition the model can be used for different

existing bed capacities. As mentioned in the introduction, our study in [11] shows benefits when considering flexible strategies for bed allocation to patients among nearby wards. The clustering concept should raise these benefits even more.

5. Results

5.1. Validating the Model

In order to get correct evaluation results for the different cluster configurations we compare the behavior of the initial model with the hospital data. This model represents the current situation at the University Hospital Halle (Saale) without any clusters

implemented. Because of comparing the different amount of needed virtual beds and the utilization rate of each ward later on, it suffices to make sure that all aspects of treatment capacity are correctly modeled. These aspects are: the total amount of elective and emergency patients treated within one year, the average LOS on each ward and the patient flows through the hospital.

According to the data of 2011, 24,598 patients were treated as elective patients and 9,087 patients entered the hospital as emergency cases. The following results based on 100 replications with a simulation time of one year. The average total number of patients generated in the simulation model were 24,707 elective and 9,064 non-elective Patients and matches the data.

As shown in Figure 5 the average LOS also shows only a slight difference to the sample data. The deviation varies between 2.1 % and -1.6 % and an average difference of 0.23 % could be achieved. Based on this the computed distributions for LOS are correctly.

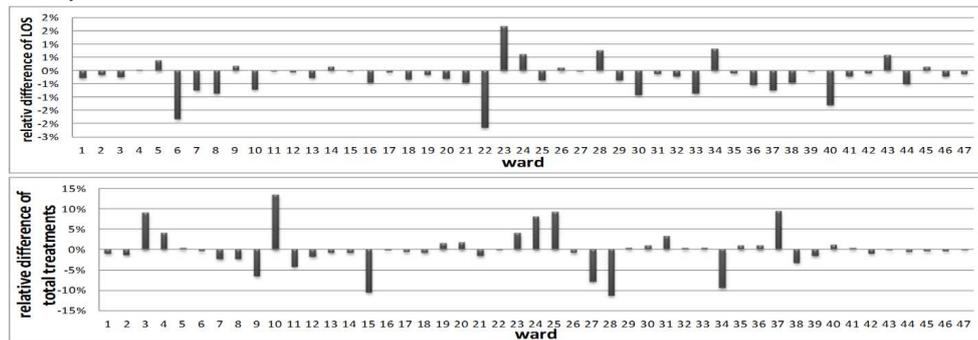


Figure 5. Results of model validation

To compare the patient flow of our model with the given data we take a closer look on the total amount of treated patients within each ward. In general a patient is treated by more than one ward. That's why we measured the total amount of treated patients in the hospital and on every ward. If our patient flows based on the computed distributions are correct, each ward will treat as many patients as in the data. Our model generated 45,013 treatments in total, which approx. equals 45,172 total treatments given by the data. Figure 5 shows the difference in treated patients at each ward. It ranges from -11 % to 13 %. With respect to only three wards having a difference in treatments of more or less than 10 %, we assume that our model reflects the patient flows of the hospital sufficiently correctly.

Based on the results the validation of our model is successful. The computed distributions and the adoption of the represented week are working correctly. In summary, the model has a sufficient level of detail for evaluation occupancy policies.

5.2. The Influence of Practical Constraints

In this section, we address our second goal: showing that practical constraints which are important in daily routine of hospital must not be ignored in studies focusing on occupancy management. As mentioned in Section 3.4 we implemented two kinds of constraints, gender separation and isolated treatment. On the one hand, gender separation makes sure that in each room of a normal ward, only male or female patients stay. On the other hand, isolated treatment ensures that a patient with an infectious germ will stay alone in a room. We assume that these constraints strongly restrict the allocation of free beds, ignoring them will lead to a misleading models.

We used our initial model as validated before and compared the amount of virtual beds needed with and without these constraints. As mentioned in Section 3.4 the usage of a virtual bed means that usually the patient could not be admitted and some kind of "cheating" has to be done. In the initial model, there was a usage of approximately 9,000 beds. By omitting these constraints less than the half (4,325) of virtual beds are needed. This difference confirms our assumption: Without these constraints the results of our study would be heavily biased.

5.3. Evaluation of Cluster Configurations

In order to evaluate the performance of the cluster configurations and to reach our third goal, we use two key performance indicators (KPI), the amount of needed virtual beds and the average utilization rate of the wards. As described in Section 3.4 represent each virtual bed needed an event of undersupply with available beds which have to be take care of. The utilization rate for each ward is computed by:

$$\frac{\sum \text{occupied beds} + \sum \text{blocked beds}}{\text{number of beds}}$$

Occupied beds are beds where a male or female patient is assigned. *Blocked beds* are beds within a room where an infectious patient is assigned. These beds can't be used by other patients. We compute the utilization rate at 00:00 o'clock simulation time each day like the hospital does in reality. To thoroughly evaluate all cluster configurations, the actual scenario with current state of bed resources and patient flow is evaluated together with two prospective scenarios, one with less bed resources allowing 85% utilization rate; the other with 50% more elective patients:

- [S1] compare each cluster configuration with the initial model
- [S2] raise the utilization rate of each ward to approx. 85% by removing beds
- [S3] increase the amount of elective patient cases treated in the hospital by 50%

To enable the usage of the cluster within our model, we simply modified the allocation heuristic (see Section 3.4.). Now, before assigning patients to virtual beds if a ward has no bed available, the heuristic tries to find a valid allocation within the whole cluster. If even this fails, virtual beds of the actual ward will be allocated.

Figure 6 shows the total number of used virtual beds in [S1]. The initial model uses 9,135 virtual beds. In CC-1 746 beds were used. A further reduction

occurred by using CC-2 (347 beds) and CC-3 (341 beds). The considerable reduction of virtual beds of

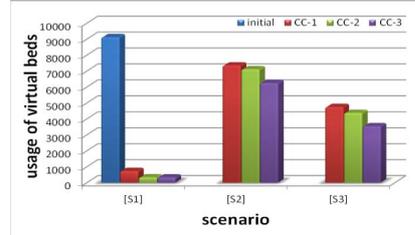


Figure 6. Usage of virtual beds

almost 92% for CC-1 and more than 96% for CC-2 and CC-3 underlines the great potential of increasing flexibility in using resources. Regarding our second KPI, the utilization rate (shown in Figure 7) there has been no change. Values between 55 % and 56 % have been measured. Furthermore, high utilization rates could be eliminated by clustering the capacities. Based on these results, clusters that obviously are able to handle load peaks which means almost all patients could be treated with regularly available capacities.

Based on the results of [S1], we computed how many beds should be removed from each ward in order to obtain an average utilization rate of 85 %. We computed the amount of approx. 354 beds that has to be removed from the hospital in total. To maximize flexibility within the wards, we removed beds to get as many small rooms as possible.

Figure 6 shows the amount of needed virtual beds and Figure 8 the average utilization rate for [S2]. The results show a distribution of work load between the wards and less unused capacities. However, this strategy aiming at an average utilization rate of 85 % has big disadvantage because of less possibilities to respond to peaks. As result, the usage of virtual beds in all cluster configurations nearly reach the same level as the initial model. However, removing approx.

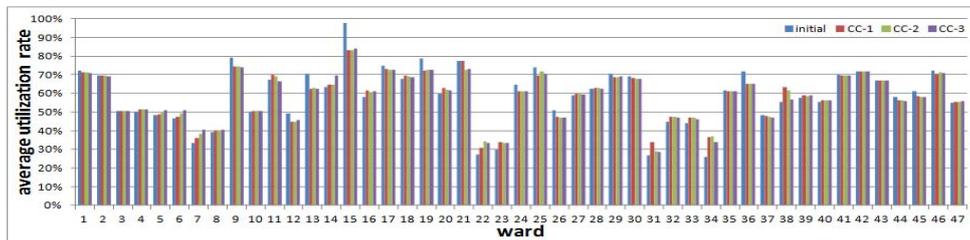


Figure 7. Average occupancy rate of wards for scenario [S1]

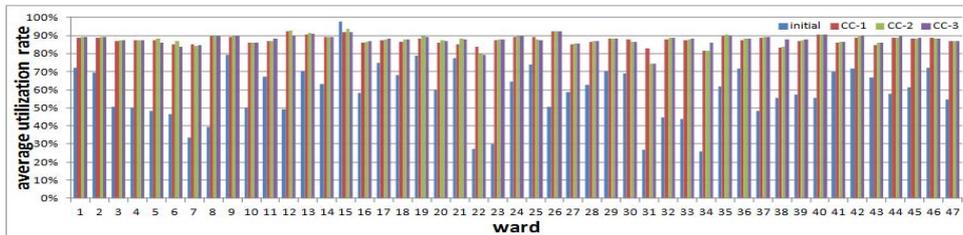


Figure 8. Average occupancy rate of wards for scenario [S2]

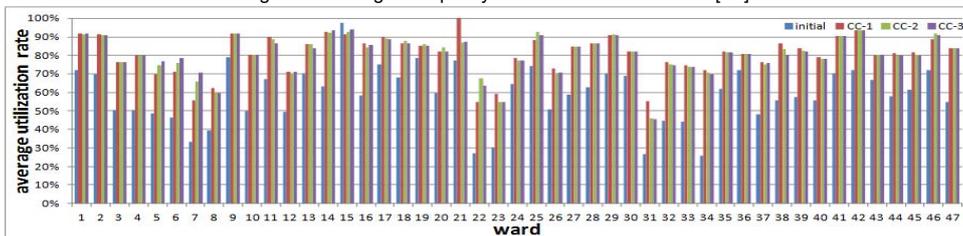


Figure 9. Average occupancy rate of wards for scenario [S3]

one third of all beds and the use of occupancy clusters still needs up to 31 % less virtual beds than the initial model in the current state [S1].

To evaluate [S3], we increased the amount of treated elective patients by 50 % to a total number of approx. 38,000. We didn't change the amount of emergency patients, because the hospital can't influence this figure. As shown in Figure 6 and 9, the average utilization rate increase as desired. The average utilization rate is now at 81 % and the utilization of virtual beds ranges from 4,759 (CC-1) to 3,552 (CC-3).

Summarizing the evaluation results implementing occupancy clusters is better than the current state of the hospital in any case. Each cluster configuration is capable of handling peak loads in patient arrival. With regard to the number of needed virtual beds, CC-3 was best in all scenarios. However, the performance of a configuration is highly dependent on its composition because the improvement of efficiency is based on the more flexible usage of idle bed capacities within a cluster. If patient flows of wards belonging to a cluster are too similar, it is possible that no idle capacities are available when needed.

Furthermore our results indicate that the loss of flexibility by reducing capacity to increase the utilization rate leads to more problems in occupancy management than an increase of patient numbers.

6. Conclusion and Future Research

We successfully reached our main goal and developed a DES model of a whole hospital which is

able to evaluate different occupancy cluster configurations. Improving bed allocation flexibility by implementing occupancy cluster had reduced the usage of virtual beds up to more than 96 %. In all three scenarios (current state, reduce capacity and increase number of patients) the CC-3 had the best results.

From a medical point of view for the hospital, the introduction of an internal medical cluster in CC-2 and its extension in CC-3 seems to be crucial for an additional 50% reduction of virtual beds with regard to CC-1 already having 92% reduction. For prospective bottleneck less-resource and more-patient scenarios [S2] and [S3], CC-3 performed best, likely because of an additional big interdisciplinary surgery cluster. In contrast, omitting a big stomach cluster from CC-1 has no negative effects. This kind of results cannot be achieved without considering all patient data and their variations over the year, e.g. by simulation.

Model evaluations confirm our assumption that practical constraints like gender separated rooms and isolated patient treatment must not be ignored to avoid an underestimation of bed requirements.

To enable an easily reuse of our model, we finally embedded it in a data driven decision support system architecture. By doing this we could reach a new level of model generality. After entering hospital own data, we were able to automatically build the whole model including structure and distributions by pushing a button, instead of simply changing parameters.

In future research, we will try to find optimal cluster configurations by combining other operational research techniques like mathematical programming within our system.

7. References

- [1] Augurzky, B. *Krankenhaus Rating Report 2013: Krankenhausversorgung zwischen Euro-Krise und Schuldenbremse*. medhochzwei-Verl., Heidelberg, (2013).
- [2] Barado, J., Guergué, J.M., Esparza, L., Azcárate, C., Mallor, F., and Ochoa, S. A mathematical model for simulating daily bed occupancy in an intensive care unit*. *Critical Care Medicine* 40, 4 (2012), 1098–1104.
- [3] Black, D. and Pearson, M. Average length of stay, delayed discharge, and hospital congestion: A combination of medical and managerial skills is needed to solve the problem. *BMJ: British Medical Journal* 325, 7365 (2002), 610.
- [4] Blum, K., Löffert, S., Offermanns, M., and Steffen, P. *Krankenhaus Barometer 2013*. Düsseldorf, (2013).
- [5] Brailsford, S.C., Harper, P.R., Patel, B., and Pitt, M. An analysis of the academic literature on simulation and modelling in health care. *Journal of Simulation* 3, 3 (2009), 130–140.
- [6] Costa, A.X., Ridley, S.A., Shahani, A.K., Harper, P.R., De Senna, V., and Nielsen, M.S. Mathematical modelling and simulation for planning critical care capacity*. *Anaesthesia* 58, 4 (2003), 320–327.
- [7] Eldabi, T., Paul, R.J., and Young, T. Simulation modelling in healthcare: reviewing legacies and investigating futures. *Journal of the Operational Research Society*, (2006).
- [8] Günal, M.M. and Pidd, M. Discrete event simulation for performance modelling in health care: a review of the literature. *Journal of Simulation* 4, 1 (2010), 42–51.
- [9] Günal, M.M. A guide for building hospital simulation models. *Health Systems* 1, 1 (2012), 17–25.
- [10] Harper, P.R. and Shahani, A.K. Modelling for the Planning and Management of Bed Capacities in Hospitals. *The Journal of the Operational Research Society* 53, 1 (2002), 11–18.
- [11] K. Helbig, T. Stoeck, M. Gragert, and T. Mellouli, „Simulation stationsübergreifender Patientenflüsse zur Evaluation flexibler Bettenbelegungsszenarien aufgrund der Jahresdatenanalyse eines Universitätsklinikums“, in *MKWI 2014; Tagungsband*, Paderborn, 2014, S. 749–762.
- [12] Jacobson, S.H., Hall, S.N., and Swisher, J.R. Discrete-event simulation of health care systems. In *Patient flow: reducing delay in healthcare delivery*. Springer, (2006), 211–252.
- [13] Jun, J.B., Jacobson, S.H., and Swisher, J.R. Application of Discrete-Event Simulation in Health Care Clinics: A Survey. *The Journal of the Operational Research Society* 50, 2 (1999), 109–123.
- [14] Khare, R.K., Powell, E.S., Reinhardt, G., and Lucenti, M. Adding More Beds to the Emergency Department or Reducing Admitted Patient Boarding Times: Which Has a More Significant Influence on Emergency Department Congestion? *Annals of Emergency Medicine* 53, 5 (2009), 575–585.e2.
- [15] Kim, S.-C., Horowitz, I., Young, K.K., and Buckley, T.A. Analysis of capacity management of the intensive care unit in a hospital. *European Journal of Operational Research* 115, 1 (1999), 36–46.
- [16] Klein, R.W., Dittus, R.S., Roberts, S.D., and Wilson, J.R. Simulation Modeling and Health-care Decision Making. *Medical Decision Making* 13, 4 (1993), 347–354.
- [17] Kolker, A. Process Modeling of ICU Patient Flow: Effect of Daily Load Leveling of Elective Surgeries on ICU Diversion. *Journal of Medical Systems* 33, 1 (2009), 27–40.
- [18] Kumar, A. and Mo, J. Models for Bed Occupancy Management of a Hospital in Singapore. *Proceedings of the 2010 International Conference on Industrial Engineering and Operations Management*, (2010).
- [19] Marckmann, G. Zwischen Skylla und Charybdis: Reformoptionen im Gesundheitswesen aus ethischer Perspektive. *Gesundheitsökonomie & Qualitätsmanagement* 12, 2 (2007), 96–100.
- [20] McClean, S. and Millard, P.H. A decision support system for bed-occupancy management and planning hospitals. *Mathematical Medicine and Biology* 12, 3-4 (1995), 249–257.
- [21] Mustafee, N., Katsaliaki, K., and Taylor, S.J.E. Profiling Literature in Healthcare Simulation. *SIMULATION* 86, 8-9 (2010), 543–558.
- [22] Proudlove, N., Gordon, K., and Boaden, R. Can good bed management solve the overcrowding in accident and emergency departments? *Emergency Medicine Journal* 20, 2 (2003), 149–155.
- [23] Roche, K.T., Rivera, D.E., and Cochran, J.K. A control engineering framework for managing whole hospital occupancy. *Mathematical and Computer Modelling* 55, 3-4 (2012), 1401–1417.
- [24] Vanberkel, P.T., Boucherie, R.J., Hans, E.W., Hurink, J.L., and Litvak, N. A survey of health care models that encompass multiple departments. (2009). <http://eprints.eemcs.utwente.nl/15762/>.
- [25] Vere, D.W. Assessing and allocating beds in acute medicine in east London. *British medical journal (Clinical research ed.)* 287, 6395 (1983), 849.
- [26] Villa, S., Barbieri, M., and Lega, F. Restructuring patient flow logistics around patient care needs: implications and practicalities from three critical cases. *Health Care Management Science* 12, 2 (2009), 155–165.

E. Data-Driven Patient Flow Management via Mining Clinical and Operational Knowledge and Evaluation by Hospital-Wide Simulation

Albrecht, T, Mellouli, T, Masmoudi, M (2022)

In: Working Paper

Working Paper manuscript No.
(will be inserted by the editor)

Data-Driven Patient Flow Management via Mining Clinical and Operational Knowledge and Evaluation by Hospital-Wide Simulation

Thomas Albrecht · Taïeb Mellouli · Malek Masmoudi

the date of receipt and acceptance should be inserted later

Abstract Economic pressure in the healthcare market and restrictive governmental regulations force hospitals to ensure their competitiveness by improving their performance, which directly depends on increasing their occupancy rate. This can be achieved by treating more patients and managing higher levels of patient flow across the hospital through clever patient flow management and without additional investment in department or bed capacities and increased medical staff. Attempts to attain the highest occupancy rates will inevitably involve strain situations. To manage and balance sporadic demand fluctuations between departments, we propose new flexible policies for smoothing the patient flow based on different types of patient admissions, redirections and relocations. As they depend on determining suitable alternative departments, we design a data-mining approach generating alternatives based on medical needs and service quality provided by departments. The resulting data-driven situational decision-making tool for hospitals uses standardized data to ensure wider applicability. In addition to this decision making-tool being used for local situation-dependent decisions, the global effects were evaluated using a generic object-oriented, hospital-wide simulation model. The current practice of the hospital shows that for 9 % of patients, an individual non-documented ad hoc decision has to be made to ensure admission. Our policies, creating a structure for these decisions, allow for the admittance of 97% of patients

without decreasing the overall quality. The evaluation shows that the rate of patients experiencing high-quality service increases from 87% to 92%. These results confirm that operational policies using redirections and relocations can overcome short-term strain situations without decreasing overall treatment quality.

Keywords Knowledge Acquisition · Decision Making · Flexibility · Strain Situation · Simulation

Highlights

- Ad-hoc decisions in operational patient flow management are structured by policies based on patient redirections and relocations. They rely on the possibility to admit or transfer patients to alternative departments during periods of pressure based on treatment-based patient-centered suitability ratings.
- A multi-phased knowledge acquisition approach based on standardized data is designed to extract clinical (medical needs of patients) and operational (medical suitability of departments) knowledge as prerequisite for an efficient operational decision support.
- Since hospital-wide simulation is one of the most powerful tools to evaluate operational policies, we utilize a object-oriented generic model to investigate long-term effects of operational policy changes.
- The portability of the presented approach is ensured by the standardized structure of the data. Every hospital in Germany is obliged to collect and report this data.
- The finding suggests that it is possible to generate suitable alternative departments and that policies utilizing functional interdependencies between departments are able to boost the efficiency of patient flow management without degrading the treatment quality.

T. Albrecht and T. Mellouli
Martin-Luther-University Halle-Wittenberg
Institute of Business Information Systems and Operations Research
06108 Halle, Germany
E-mail: {thomas.albrecht,mellouli}@wiwi.uni-halle.de

M. Masmoudi
University of Lyon, University Jean Monnet Saint-Etienne
Faculty of Sciences and Techniques
42000 Saint-Etienne, France
E-mail: malek.masmoudi@univ-st-etienne.fr

1 Introduction

“Healthcare is the most difficult, chaotic and complex industry to manage and the hospital is altogether the most complex human organization ever devised” [9]

This famous statement shows the dilemma of modern hospitals. First, they are an essential part of modern society that must be kept alive at any rate. Second, they are among the most complex organizations present, composed of several interacting subsystems such as medical cluster, departments or wards. The planning and management of patient flows, which refers to the movement of patients through the whole process of care [2] (Fig. 1), is directly influenced by the type and degree of interactions between subsystems. An organizational form, mostly visible in larger general hospitals, is the division into interdependent departments, meaning a treatment can be provided by more than one department. Such structures require more complex and sophisticated management approaches for planning and operations. Especially managing single parts of the hospital, as proposed in numerous research papers, is not enough to optimize the hospital as a whole. In this spirit, a system of local optima is not an optimal system [12] and a quantitative analysis of the patient flow in a hospital consisting of interdependent subsystems shows that a local improvement in the emergency department does not result in a performance improvement for the entire system [18]. Hence, this paper does not focus on local improvements in an interdependent setting but on providing hospital-wide policies for managing the patient flow.

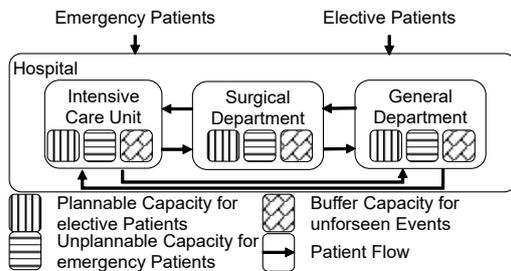


Fig. 1 General Patient Flow in Hospitals

1.1 Utilizing Interdependencies for Efficient Patient Flow Management

Policies for operational patient flow management should be designed in such way that they provide degrees of flexibility to resolve strain situations with flexible yet high-quality decisions. This is directly related to the urge of the hospital

to maximize its occupancy rate. In our opinion this can be achieved with the following two components:

1. Driving the elective patient flow to the maximum which inevitably provides minimum capacities for emergency patients
2. Using operational policies providing high-quality decisions for resolving strain situations inevitably caused by (1)

Within this paper, we show that maximizing the occupancy rate is possible without lowering the capability to react to strain situations by using the provided intelligent data-driven approach learning suitable knowledge from historic data.

During strain situations, ad hoc decisions are made by experts to circumvent capacity bottlenecks. As these decisions are unstructured and not documented, the decision-maker needs policies to structure the decision-making process and to ensure fast and high-quality decisions.

Recapturing the complexity of a hospital, it is clear that policies focusing on single departments are insufficient to deal with strain situations. Hospital-wide policies utilizing interdependencies are promising ways to efficiently resolve local strain situations. Interdependencies can be divided into six categories [27] which are further differentiated into two groups [21]. The first group includes interdependencies integrable into analytical solutions for planning problems at tactical or strategical levels. Containing functional- and patient-based interdependencies, the second group aims at the operational management. Especially, functional interdependencies, meaning the suitability of several departments for one specific treatment, are able to release the pressure induced by the interwoven flows of elective and emergency patients. Especially, emergency patients are highly unpredictable and are causing capacity-based strain situations.

The most common approach for operationally reacting to capacity-based strain situations is using otherwise unused capacities at other departments. Despite the inherent flexibility provided by these strategies, several authors, for example [25], show that they can extend the length of stay of patients and decrease the quality of care as the choice of departments is generally not tailored to the specific patient. Unlike other approaches, we do not understand these transfers as simply placing patients in other departments until the designated department is available but as operational service shifts to suitable alternative departments. These operational service shifts are driven by functional interdependencies of departments. In our case, we are dealing with a 1000-bed maximum care provider where several departments can potentially offer the same treatments. Hence, a relocation in this setting does not necessarily lead to a decrease in the quality of care, but the flexibility can be efficiently used to overcome strain situations. Moreover, on a conceptional level we

further distinguish these transfers into a redirection prior to hospitalization and a relocation during hospitalization.

The main question arising is, how to choose suitable alternatives. As the treatment of a diagnosis is a complex process, predefined alternatives based on department similarities can lead to a chaining effect which is summarized as follows: the most similar department to the designated department for a patient is not necessarily the best department for this patient since some of the needed treatments are not provided by the most similar, but by another little less similar department. To overcome this effect, patient-centered individual decisions are needed. To efficiently support these decisions, we provide a data-driven approach to gather treatment specific suitability knowledge of departments.

1.2 Data-Driven Knowledge Acquisition and Evaluation

Clinical and organizational knowledge, needed to choose suitable alternatives, is normally hidden inside domain experts. To not solely rely on medical experts and to provide a more generic form of decision support, this paper provides a data driven approach to gain the needed knowledge. In an extensive literature review [19] it is shown that data-driven knowledge acquisition is a rich research area on its own. They conclude that the type of knowledge extracted depends on the used data-set. A majority (80%) of the papers examined used operational and clinical data mixed together to derive knowledge without differentiating between the organizational and clinical part of operational knowledge. Opposing current research, we want to clearly differentiate between organizational and clinical knowledge as we strongly encourage that medical and organizational knowledge are independent major prerequisites for operational decisions. To lower the effort for data collection, we intentionally use standardized medical controlling data mixing the clinical and operational view of patient flows. To efficiently extract knowledge, we disentangle these views by extracting the clinical knowledge using the factual treatment executions to mine individual treatment paths and, based on treatment frequencies, the suitability of departments to represent the organizational knowledge.

The outcome of operational policies during inevitable strain situations can be evaluated system-wide by simulation taking interrelations of department occupancy states in different periods into account. Simulation models are an ideal tool for evaluating the performance of policy changes [4]. Therefore, we will utilize a previously validated and tested hospital-wide simulation model [15] to evaluate the quantitative impacts of the proposed approach.

1.3 Goals and Structure of the Paper

The high-level goal of this paper is to provide a set of easy-to-use policies to support a hospital decision-maker during strain situations. To achieve this goal, we provide a data-driven knowledge acquisition approach to identify suitable departments and policies to utilize these departments according to the current state of the hospital at operations. Finally, the complete approach is quantitatively evaluated with the help of a hospital-wide simulation model.

The remainder of the paper is structured as follows: section two discusses the research outline in combination with the current state-of-the-art, sections three and four detail the proposed approach divided into data-driven knowledge acquisition and situational decision making, and the fifth section summarizes the paper and gives further research perspectives.

2 Research Outline and State-Of-The-Art

As this paper opens up a complex field, the research outline will be presented divided into a general discussion of patient flows and operational service shifts, followed by a presentation of the general problem of suitability and availability of departments. This section is closed by a discussion of hospital-wide simulation models.

2.1 Views on Patient Flows and the Nature of Operational Treatment Service Shifts

The main task of every healthcare system is to cover the whole patient flow. An extensive literature review [2] extends the definition of patient flows by differentiating a clinical, meaning the progression of the health status, and operational, describing the movement of patients through departments, view. To gain fruitful insights, this differentiation has to be further detailed. In contrast to [2] there is not only the differentiation between these views. The patient's movement through the hospital depends on the clinical needs of a patient and the suitability of departments for specific treatments. To not rely on predefined similarities between departments, approximating the suitability of a department for groups of patients, a new organizational view on patient flows is needed.

From a clinical point of view, a patient or a group of patients have a set of symptoms (S) leading to a diagnosis (D) In correspondence with a medical expert, a treatment (T) is chosen. Depending on the healthcare provider, for example a maximum care hospital, a rural hospital or a specialized hospital, T can differ significantly. Moreover, one healthcare provider can offer different T for a single D , for example T_1 in Fig. 2 can be an invasive treatment while T_2 is

a minimal-invasive treatment. As T is a complex process, it can be further detailed to several treatment items (t) which describe the single procedures done by medical experts.

From an organizational point of view, a hospital offers medical and nursing services to treat patients. To offer this, a hospital consists of several departments or functional units providing resources and skills. Their combination is denoted as function describing the capability to provide a complete T or a set of t . Bringing both sides together, every T needs a unique composition of functions provided by departments (Fig. 2).

In a complex interdependent structure, an ambiguous association between T and several departments is present. In most cases there is one designated department, covering most patients with a specific T and other possible departments serving as alternatives in case the disease is more severe or capacity shortages appear. This leads to more complex planning approaches because several departments have to be planned in an integrated manner. Still, this complex structure provides advantages during strain situations. In addition to generally known possibilities to overcome strain situations such as delaying or rejecting patients, this structure enables the possibility to flexibly use capacities from other departments which means patients planned for one department can be transferred to other departments. As flexibility is one of the most promising ways to overcome strain situations, this paper will focus on complex interdependent structures provided by a 1000-bed maximum care hospital.

Interdependent structures enable redirection and relocation of patients. Having crucial differences, redirections consider a service shift at planning level, while relocation refer to a physical transfer during treatment. An operational redirection changes the previously planned path for a certain patient to ensure the admission even if the designated ward has no available capacity. A relocation in contrast means a physical transfer during a treatment. An operational, previously not planned, relocation can be used for explicit patients to free capacity for other patients (Fig. 3).

Summarizing, operational service shifts are used to manage patient flows during strain situations to ensure treatment for as much patients as possible. For using service shifts, the hospital needs profound knowledge about their organizational and treatment structure which is provided by the mining approach described in the next section.

2.2 Disentangle the Clinical and Organizational Structure of Patient Flows to Generate Operational Knowledge

In general, research about patient flow concentrates either on abstract patient flows or on different types of patient flows. According to [2] abstract patient flows are often investigated by queueing models and markov chains, while, because of

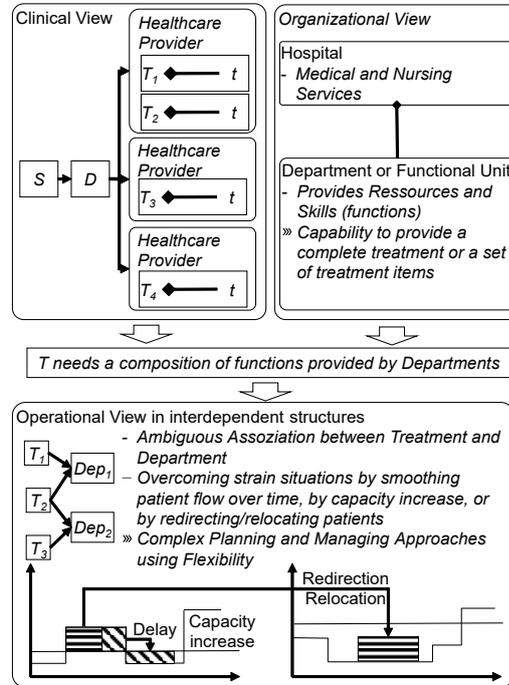


Fig. 2 Different Perspectives of Patient Flows

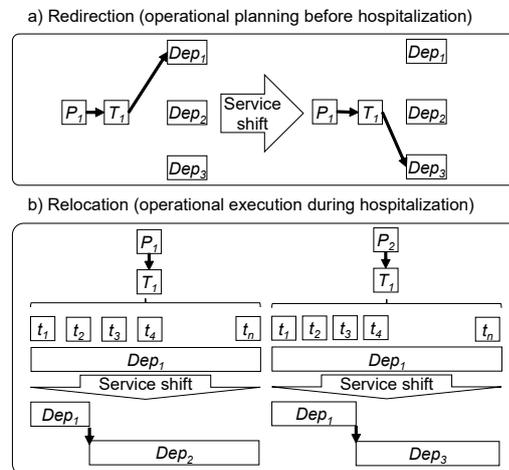


Fig. 3 Redirection and Relocation as Operational Service Shifts

the complexity, different patient flow types are investigated by simulation models. To utilize these approaches, the patient flow is represented by organizational units and distributions and transfer probabilities for the movement between these units. This research view is backed by a recent review [19] where 85% of the reviewed articles (217) focus on a combination of clinical and organizational knowledge extracted by process mining. Unfortunately, as stated by several researchers [16,22,26], this leads to spaghetti like process structures unsuitable for operational decision support. To analyze the performance of a system, this level of detail is sufficient. But for decision support, a clear separation of the clinical and organizational perspective is needed. To further refine the preparation of suitable alternatives, we distinguish the clinical (treatment set mining) and the organizational (department-treatment capability) perspective as shown in Fig. 4 to combine them to operational knowledge usable for detailed patient flow management.

[14] first disentangle the mining of treatment sequences from the knowledge of which departments performed these treatments. Thus, they show an interesting approach to use data-driven knowledge generation enabling optimization. In [14,23] this separation is hierarchical using the operational view to allocate bed resources and afterwards scheduling treatments. For a tactical planning this hierarchy is reasonable, as bed resources are a prerequisite for scheduling. In our case, we are dealing with a patient-centered operational decision and it is important to choose alternative based on the medical needs. Hence, the operational decision where to admit or transfer a patient depends on the medical needs and the organizational structure of the hospital.

According to [19] the sequence of treatment items is often only partially defined with a set of treatments following a strict sequence and some treatments scheduled independently. Hence, where to admit or transfer a patient does not depend on the sequence of treatment items and thus the composition of T , denoted as treatment set (TS) is sufficient. In [23], a first reduction was made by grouping treatments and path restrictions to generate an individual patient path. We take this approach even further by grouping treatments day-wise, only considering strict inter-day restrictions. This deliberate reduction in complexity to medical needs allows simpler data mining techniques for knowledge generation and makes the mining results more understandable.

To mine organizational knowledge, we want to decouple the decision of which department is suitable from historical organizational decisions. Thus, we calculate the suitability of a department not based on an entire TS , but on individual t , assuming that a department can provide a TS when it can perform the underlying t . Hence, even if a department is not designated for treating a particular diagnosis, it could be possible to use it if a certain treatment coverage is ensured.

For each combination of t and department, a competency value and thus the suitability is calculated.

The combination of TS and the detailed calculation of the suitability leads to a more precise calculation of the service suitability of a department, forming the operationally needed patient specific knowledge to quickly react to strain situations.

2.3 Operational Decision-Making during Strain Situations

A hospital has several opportunities to react to capacity-based strain situations operationally. The most promising way to operationally react to strain situations is to pool capacity. The scientific literature provides different approaches like overflow wards for general wards [1,7,17] or intensive care units [6], or lending capacities of nearby wards [13]. For most of these approaches, medical suitability is not the most important factor for the decision. Pooling capacities with the help of ward clustering [15] leads to an approximate consideration of suitability. Nevertheless, most of these approaches focus on formulating a strategy rather than providing policies for operational decision-making. Within the scope of this paper, [20] and [5] have developed decision approaches for generating alternative wards, including the medical needs of a patient as a part of the decision. In general, approaches combining complex reactions to strain situations with data-driven decision support as proposed in this paper are not covered in the literature.

A list of suitable departments can serve as input for the actual operational decision. The local decision on which a suitable department is currently available must be made based on the hospital's current situation. To efficiently support this decision, we provide several situation-dependent policies. The first policy for normal situations is a direct admission to the designated department. During strain situations, and based on our suitability calculation, three additional policies are possible. As simple policy, a redirection is possible if a high-quality alternative is present. In case a redirection is not possible or wanted, a relocation of an already admitted to a high-quality alternative can be used to admit a patient during a strain situation. The most complex policy is a redirection in combination with a relocation. Here, the designated and the alternative department are facing a strain situation and a relocation can be performed for an already admitted patient at the alternative department to ensure a redirection for the initial patient. Tab. 1 shows an overview of the possible policies. These policies can be combined to complex decision strategies used at operations.

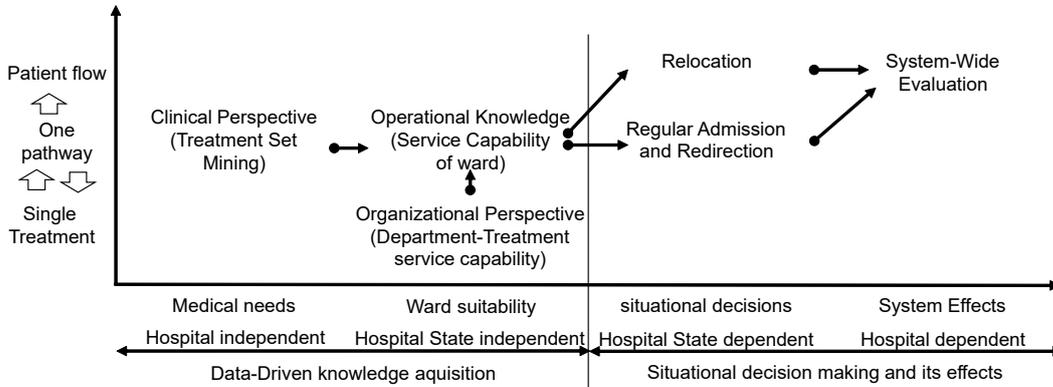


Fig. 4 Concept of Knowledge Acquisition and Decision-Making

Table 1 Operational Policies based on Redirections and Relocations

Name	Description
Direct Admission (Policy 1)	Standard admission during normal situations
Redirection (Policy 2)	Strain situation at designated department and high quality alternative available
Direct Admission with Relocation (Policy 3)	Strain situation at designated department and high quality alternative for an already admitted patient available
Redirection with Relocation (Policy 4)	Strain situation at designated and alternative department and several high quality alternatives available

2.4 Hospital-Wide Evaluation by Simulation

The evaluation of strategies based on situation-dependent policies is more complex, as the decision depends on the hospitals' current situation. The evaluation would request the generation of several situations. Because of the complexity of a hospital, this would be a time-consuming and effortful task. Moreover, as single situations and corresponding admission decisions are not independent, an evaluation based on single situations is not suitable to gather all effects. Therefore, we need an evaluation over a long enough period to respect interdependent situations. As decision strategies can change the capacity situation and thus assignments of patients to departments, this evaluation must be made regarding the whole organizational structure. Hence, the general evaluation must be hospital-wide in order to cover the full complexity of the decision-making approach and its effects.

In [13, 15], different simulation models that are dealing with hospital-wide strategical questions were implemented.

Various significant insights in simulation modeling for hospitals were found. First of all, a generic simulation model increases the portability of a model. The reuse can be essential for two different aspects: to easily adapt to different hospital organizations and change the decision component according to different study focusses. Second, a data-driven model allows the user to easily configure the model for different hospitals and scenarios. General features of generic models are: simple model structures, flexibility in model configuration, and intuitive usage [11]. Respecting these features, several setting-specific models are reported in the literature [8, 10, 24, 28]. Unfortunately, these models focus on just one organizational unit and are unable to capture the whole complexity of a hospital. Hospital-wide models are very scarce in the literature. The complexity of these models prevents a stronger focus on inter-organizational decision-making [3, 11]. For the simulation model in this paper, a generic object-oriented approach is adopted from [15]. Notably, with the implementation of the proposed decision policies and using real-world patients, we have removed all stochastic parts of the simulation model.

3 Data-Driven Knowledge Acquisition

To detail the knowledge acquisition, we present the used data format (3.1), the mining algorithm (3.2) and the suitability calculation (3.3 and 3.4). This section is closed by a statistical analysis showing the appropriateness of this approach for operational decision making.

3.1 Data Structure

The analyses in this paper are based on standardized German DRG data provided according to §21-KHentgG, a German

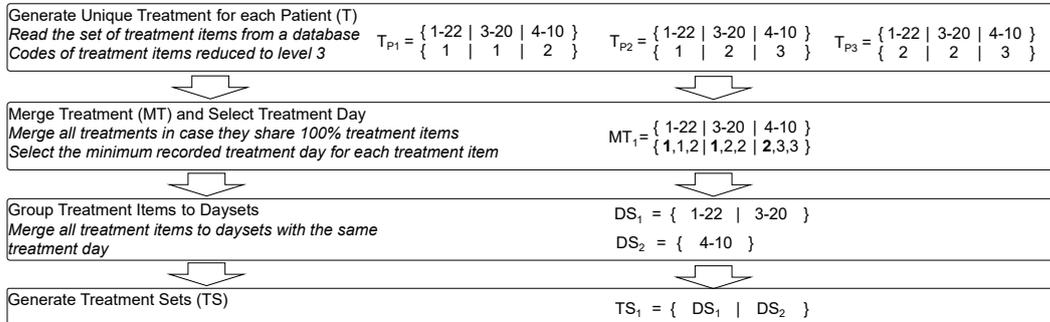


Fig. 6 Clinical Mining Algorithm and Example

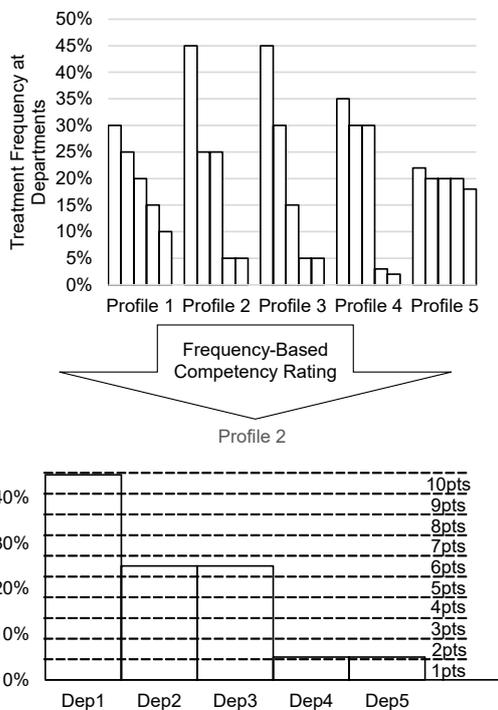


Fig. 7 Different Frequency Profiles of Treatments and Competency Rating

suitable alternatives are seen. However, with a simple ordering, the gaps between the first and the other alternatives are large, and the small differences between these alternatives are lost i.e. considered as not equivalent. For the next two profiles (profile 3 and 4), the same argumentation holds. The fifth profile is a special profile, where all alternatives are suitable with almost the same frequency. With a simple ordering, the equivalence between departments is neglected,

and the decision could be biased. Thus, to cope with this issue, we consider a calculation depending on the differences between the frequencies (see Fig. 7).

To normalize the frequencies, we developed a method to assign competency points to a department. All departments with a frequency higher than 0% are considered as suitable. To assign competency points, we divide the range of frequency into ten equal groups. For example, for Profile 2 in Fig. 7 the maximum frequency is 40%. The range between 0% and 40% is relevant for our calculation. This range is segmented into parts of 4%. That means, every 4% the assigned points are changed. Hence all departments with a frequency between 40% and 36% are rewarded with 10 points. In this case only department 1 has 10 points. For every segment, the corresponding departments are assigned with the corresponding points. It is notable that if a range is not filled with a department, the points are not given. With these left out ranges, this approach can keep the information about the big difference in frequency between departments. Furthermore, the approach keeps the information about similar frequencies. By calculating the rating for every treatment and every department, a suitability matrix is constructed for the whole hospital.

3.4 Generating Lists of Suitable Departments

Once the daysets and the suitability matrix are generated, it is possible to generate a list of suitable departments covering each case. To support hospital decision-makers and to manage hospitals operations, some preconditions besides suitability must be respected. As discussed previously, the challenge of treating patients is linked to the capability to provide as much needed treatments as possible. Naturally, the decision-maker would choose a department with high coverage of treatments and a high quality. During strain situations, this is not always possible. Therefore, less suitable alternatives must be chosen. As they are unlikely to cover

all needed treatments, every treatment not provided by the alternative must be done by medical staff from the initially desired ward.

Suitable departments are sorted by the overall average quality. To possibly increase the number of alternatives, the number of considered daysets can be decreased. With a decreasing number of daysets, the amount of considered treatments also decreases. With an increased number of treatments, the generalization of a department must be higher in order to cover all treatments. In contrast, a decreased amount of considered treatments enables the approach to include more specialized departments in the suitable alternatives list. Hence, it is possible to calculate a list of suitable departments based on a *TS* by extracting the corresponding column of the suitability matrix for each treatment.

Diagnosis: H40 | Treatment Set: {1-22,3-20,4-10}

Department	Dayset 1		Dayset 2		Overall AVG Quality
	Treatment 1-22	3-20 Quality	Treatment 4-10	Quality	
Dep ₁	10	9	8	8	9
Dep ₂	5	9	10	10	8
Dep ₃	3	10	4	4	5.6
Dep ₄	2	3	3	3	2.6

Decision Day1 Decision Day 2

Fig. 8 List of Suitable Departments

Fig. 8 shows an example result for two daysets and four departments. This example offers the medical expert the opportunity to choose three admission strategies. The first and obvious strategy is to use *Dep₁* as designated department for the whole *TS*. In general, this corresponds to the medical guideline and ensures a high overall treatment quality and no transfers during the hospitalization. The second alternative when *Dep₁* is facing a strain situation is to use *Dep₂* for the whole *TS*. The patient receives a high overall quality and no transfer has to be made. Another possibility is to admit the patient to *Dep₁* and mark the patient as a candidate for relocations after completing *DS₁*.

3.5 Hospital State Independent Results

To gain insights into whether the data-driven knowledge acquisition system can be used to derive patient admission strategies, a rigorous statistical analysis on a real database provided by a hospital of maximum care is performed. This data represents a cross-section of the medical reality in Germany and contains 46,000 patients. Using the presented approach, 17,273 *TS* covering 1054 different diagnoses are generated. The number of *TS* per diagnosis varies, ranging from one to 40. The boxplot in Fig. 9 shows the result without statistical outliers. The median is seven, and the

0.75 quantile is 18. Since most diagnoses have a manageable amount of *TS*, we can use them as an input for decisions.

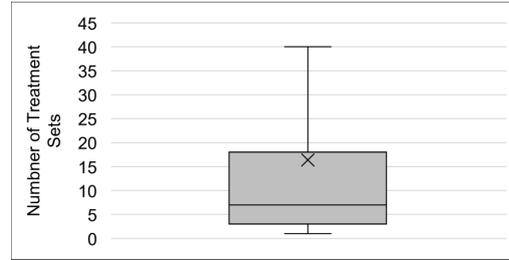


Fig. 9 Analysis of the Number of diagnose-specific Treatment Sets

In Fig. 10 the length of *TPs* according to the number of daysets is shown. It is obvious that the majority of *TP* have up to three *DS* and longer *TP* are unusual. Note that the number of *DS* not necessarily correlates with a long length of stay (LOS) but an increase in *ds* could lead to more department changes during a stay of a patient. But 80% of all *TP* can be treated with a maximum of two *DS*. Therefore, even if every *DS* needs a different department, the number of department changes would still be acceptable.

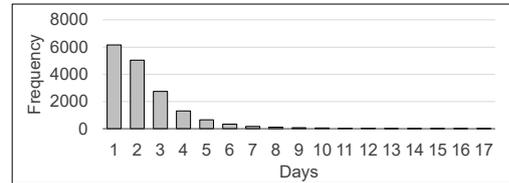


Fig. 10 Number of Daysets in a Treatment Set

Looking at the suitability matrix, we see 221 different treatments and 26 departments. That means the approach generates 5746 different competency ratings. Over all treatments, the median of capable departments is 3. Moreover, we could not identify treatments that are provided by all departments. That means that all treatments must be included into the calculation of capable departments. Additionally, for 75% of treatments, we have identified at least two capable departments, increasing the possibility of successfully using alternatives based on several treatments.

We have calculated the number of capable and suitable departments (Fig. 11). Here different percentages of covered treatments with at least four points of quality are shown. With increasing coverage, the number of alternatives decreases. If a diagnosis has only one alternative, only one department can provide the needed treatments, and primary relocations cannot be used to release strain situation related

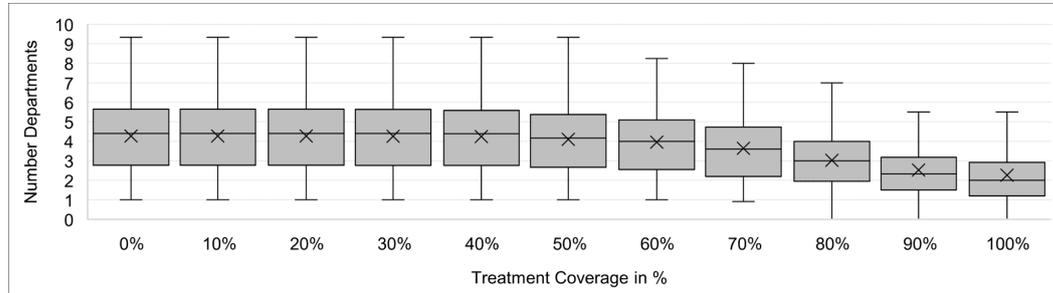


Fig. 11 Number of Alternative Departments over all diagnoses

to this diagnose. Moreover, it is shown in Fig. 11 that coverage of at least 80 % results in diagnoses with no alternatives. That means that for specific *TS*, no single department can provide the treatment and planned transfers are needed to successfully treat patients. To minimize patient transfers and to find general rules, a coverage of 60 % is needed. To further distinguish insights and to substantiate the positive effects of relocations, we divide the whole treatment set into two halves. This analysis is done considering three of the most frequent diagnoses in Germany.

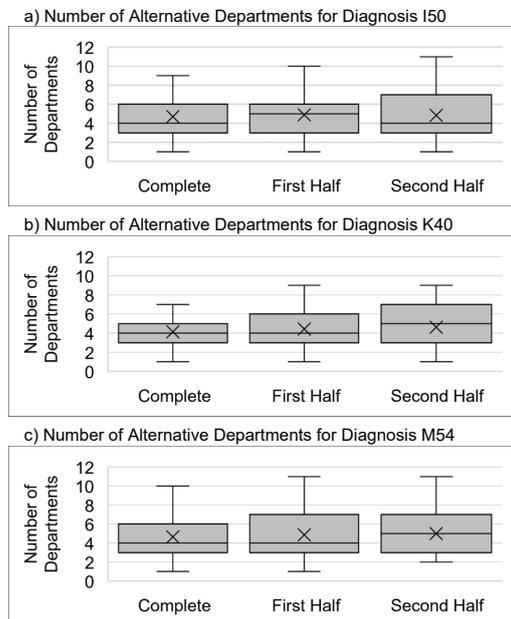


Fig. 12 Number of Alternative Departments during different Stages of Hospitalization

A statistical analysis of diagnoses *I50* (Fig. 12 a), *K40* (Fig. 12 b), and *M54* (Fig. 12 c) for a coverage of 60 % is provided. Here significant differences in the number of alternatives are shown. Considering *I50* and all daysets, a minimum of one alternative, a maximum of nine alternatives and a median of four alternatives are observed. The lower quartile is three and the upper quartile is six. Considering the first half of daysets, these values do not change significantly. Only the maximum number of alternatives increases to 10. For the second half of daysets, the upper quartile increases to seven and the maximum of alternatives increases to 11. Similar results are for diagnoses *K40*. For the second half, the upper quartile is increased from five to seven alternatives, which is the maximum of alternatives considering all daysets. Interestingly, for *M54*, the results for the first and the second half are nearly identical, except for the minimum number of alternatives increasing from one to two alternatives.

This analysis showed that the mined knowledge could provide alternatives based on standardized data. Moreover, with the detailed analysis of several diagnoses, it was shown that the number of alternatives would increase during the second half of hospitalization. This strengthens the assumption that relocations during hospitalization can boost the efficiency of a hospital.

4 Flexible Decision-Making Based on Situational Dependent Policies

A flexible decision strategy based on redirections and relocations for single situations will be presented and discussed (4.1). To evaluate the decision strategy, we use a hospital-wide simulation model (4.2) to investigate a real-world case study (4.3).

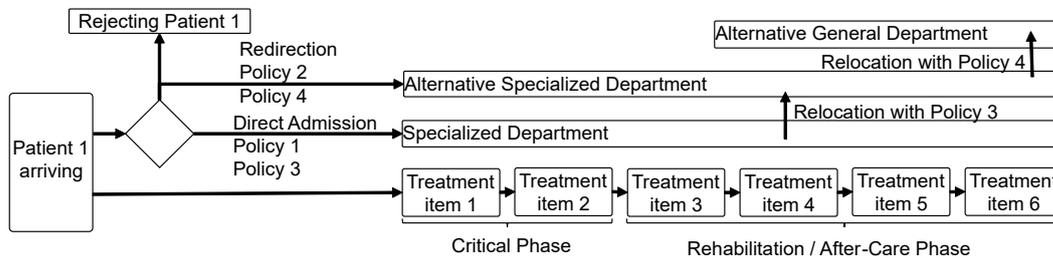


Fig. 13 Visualization of Redirections and Relocations

4.1 Building Policy-Based Strategies

At operations, every decision is linked to a specific situation and state of the hospital, which is characterized by the current resource usage, the current patient to admit and the staffing of the hospital. To support the hospital decision-maker, four different admission policies are developed (Tab. 1). The first policy aims at the hospital being in a normal situation, meaning there is enough capacity available to admit the current patient at the designated department. Notably, this normal situation refers to one department. Even though other departments are in a strain situation, the designated department could be in a normal situation. However, in a normal situation a direct admission is possible, meaning that this policy is the regular decision. During strain situations, the decision-maker is able to use other policies. The choice of policy depends on the nature of the strain situation. We distinguish two forms of strain situations. An acceptable strain situation describes a capacity bottleneck at the designated department and available capacities at alternative departments. A critical strain situation is characterized by a simultaneous capacity bottleneck at several departments. For acceptable strain situations, the decision-maker could use two different policies. Policy two uses a redirection of the current patient. Based on our suitability calculation, an alternative department can be chosen without deteriorating the treatment quality. This enables the decision-maker to quickly admit the patient. Without the suitability calculation, this redirection could refer to known reactions to strain situations like off-service placement. But our pre-calculation minimizes the negative effects related to the known reactions. In case a redirection is not possible, policy three proposes a new variant of freeing capacities. A relocation refers to a transfer of an already admitted patient. As seen in Fig. 13 a treatment can be divided into a critical phase, for example a surgery and the direct aftercare, and a rehabilitation phase, meaning wound management or similar treatment items. We think, that during the rehabilitation phase, a transfer of a patient can be done without lowering the treatment quality. Hence, a patient can be relocated to another department. This could be another specialized de-

partment or, in case the treatment is already progressed, a general department. With the help of relocations, an acceptable strain situation can be released without lowering the overall treatment quality. In a critical strain situation, the reaction is more complex. A direct admission, even with the relocation of another patient, and a redirection is not possible. But it is possible to select a patient for a relocation from an alternative department to free capacities for a redirection. This fourth policy raises the grade of flexibility a hospital decision-maker can use to release strain situations.

Using redirections and relocations, the decision-maker must make trade-off decisions, weighting possible quality gains or losses for the patients. As the reaction in a strain situation is time-dependent and complex, the decision-maker must be supported by a predefined decision strategy. To support the decision-maker, we propose a strategy based on the described policies (Fig. 14). At first Policy one is checked and in case this check is true, the patient can be admitted directly. If a direct admission is not possible, we set the current acceptable quality level (AQL) to 10. Afterwards, policies two, three and four are checked based on the AQL. In case all of these checks are false, the AQL is lowered by one and the checks are repeated until a suitable policy is found or the AQL is below a quality acceptance boarder (QAB), which describes minimum required quality for a treatment and therefore the service level of the hospital. If no usable policy was found and the AQL is lower than the QAB, the patient has to be rejected. Iteratively lowering the AQL approximates the trade-off decision. As the strategy starts with the highest possible quality, the best decision for this patient is made. This strategy is denoted as all policies strategy (APS). To further investigate the influence of the newly proposed relocations, we propose a second decision strategy, denoted as redirection strategy (RS), using only policy one and two.

4.2 Hospital-Wide Simulation Model

To evaluate the presented policy, we utilize the simulation model from [15]. The general architecture is given in Fig.

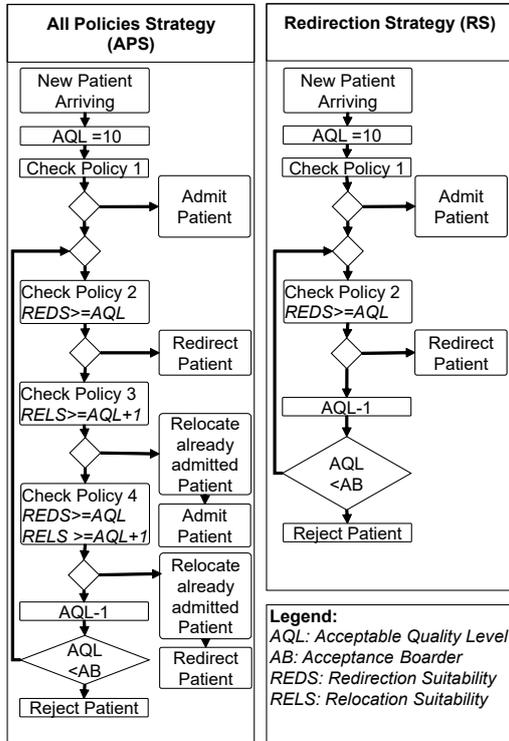


Fig. 14 Redirection and Relocation Strategies

15. Every class in this model reflects some main processes of the hospital. The entrance generates patients with all relevant attributes and the department class provides an abstract form of the treatment process, where a patient occupies a bed and stays until his personal length of stay is reached. The core class for decision making is the routing node. Inside this node a decision is made to which department the patient should be routed and whether it has available capacities left. The model structure was tested and approved by hospital decision makers.

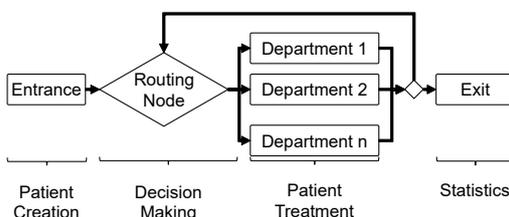


Fig. 15 Architecture of the Simulation Model

In contrast to [15], we removed all stochastic distributions inside the model. For the patient generation, the distributions for patient arrivals and attributes are replaced by factual patients from the data. Moreover, the decision where to admit or transfer a patient, previously done by a distribution, is represented either by the APS and RS. To better evaluate these strategies, a benchmark policy (BP), consisting of the factual department choices in the data, is additionally implemented.

These replacements change the nature of the simulation model drastically. A stochastic simulation model seeks for a reliable evaluation by using a sufficient number of replications to reduce the impact of statistical errors. By eliminating all stochastic influences, we change it into a deterministic model. Hence, we can use the model to mimic a real-world experimental study, where BP is the control group and the proposed strategies are the study group. Crucial advantage of using simulation as a tool for experimental study is that the control and study group contain the same patients and organizational units. Therefore, the significant difference between these two groups is the decision-making algorithm, allowing us to deeply evaluate the influence of more advanced decision algorithms.

4.3 Real-World Evaluation with Different Required Quality Levels

To evaluate the proposed approach, different scenarios are evaluated using simulation. Generally, all analyses are based on real patient data. We used a subset of the data used in section 3.5. Patients recorded from February to July are considered. Within this timespan, 16,740 patients were admitted to the hospital. We excluded patients from January from the evaluation but not from the simulation to not bias the evaluation by starting with an empty hospital. All recorded patients in the data are used to generate schedules of real situations of the hospital with all relevant information about patients. For each patient, the gender, the diagnosis, the day of admission, and the length of stay are included. In the case of BP, additional information for department pathways of each patient is inserted. For the strategies, every patient is linked to a TS according to their diagnosis.

The overall performance of the APS compared to the BP is evaluated, and the possibility to evaluate different QAB is provided. To evaluate the performance, we will focus on several important key performance indicators (KPI). The main KPI is the acceptance ratio (AR) representing the percentage of admitted patients among the total number of patients presented to the hospital. This AR can be seen as the general service level of the hospital. To increase the revenue, the hospital tries to maximize the AR with the existing capacity and increase the number of admitted patients. The

Table 2 KPI used to Evaluate the Case Studies

KPI	Description
Adm	Number of Patients Admitted to the Hospital
AR	Percentage of Admitted Patients
REJ	Number of rejected patients
REDC	Number of redirected patients
REDQA	Average quality change for redirections
RELC	Number of relocated patients
RELQA	Average quality change for relocations
PER	0.1 percentile of provided quality
GQ	Percentage of patients with good quality

second group of *KPIs* is quality-based. The first measurement is the overall average quality provided by the hospital. To evaluate the quality in a more detailed way, the 0.1 percentile of the provided quality of care (*PER*) is used, which allows saying that 10% of patients receive a quality below this value and, vice versa, 90% of all patients receive treatments with a quality higher than this value. To further investigate the quality, patients were divided into two groups. The first group receives a treatment quality of at least seven points (good quality). The second group receives a treatment quality between the minimum required quality and seven points (acceptable quality). The percentage of patients with a good quality (*GQ*) is an important *KPI* for a hospital's performance. In a secondary analysis, the use of the flexibility provided by the admission strategy is evaluated. Here, the number of redirections (*REDC*) and their corresponding quality change (*REDQA*), as well as the number of relocations (*RELC*), with the calculation of the corresponding quality loss or gain (*RELQA*), are evaluated. The *KPI* are summarized in Tab. 2.

In Fig. 16 and Tab. 3, the *KPI* values are shown. First, it is surprising that the *BP* cannot admit all patients, although it was possible in reality. An *AR* of 91.17 % indicates that for 8.83 % of the patients, a flexible and not documented decision was made. We deduce that the hospital uses a non-transparent admission rule during strain situations which accounts for the gap between the data and reality. This gap can be efficiently closed by the *APS*. As discussed before, the *QAB* determines the grade of flexibility. To set a reasonable grade of flexibility, *QABs* from one to 10 are evaluated. For the choice of a *QAB*, the *AR* and the *GQ* are the main factors.

Interestingly, setting *QAB* to 0 results in an *AR* of 99.99 % and a *PER* of 6.8 which is higher than the results of the *BP*. This indicates that flexibility during the treatment can improve the reaction of a hospital to strain situations. If the example hospital tries to reach the *REJ* of the benchmark instance, it can set the *QAB* to seven points. Here 971 patients were rejected, which leads to an *AR* of 94.2 %. Remarkably, all patients receive their treatment with at least seven points (*GQ*=100 %) and the *PER* is 8.2. That means that 90 % of all admitted patients receive treatment with at least 8.2 points.

Table 3 Evaluation

<i>QAB</i>	Adm	REJ	AR	PER	<i>GQ</i>
10	9529	7211	56.92 %	10	100 %
9	12501	4239	74.68 %	9.3	100 %
8	14224	2516	84.94 %	8.6	100 %
7	15199	1541	90.79 %	8	100 %
6	15875	865	94.83 %	7.5	95.12 %
5	16251	489	97.08 %	7.15	92.36 %
4	16451	289	98.27 %	7	90.70 %
3	16584	156	99.07 %	6.79	89.47 %
2	16671	69	99.59 %	6.66	88.69 %
1	16686	54	99.68 %	6.66	88.63 %
0	16690	50	99.70 %	6.66	88.61 %
<i>BP</i>	15262	1478	91.17 %	6.25	87.67 %

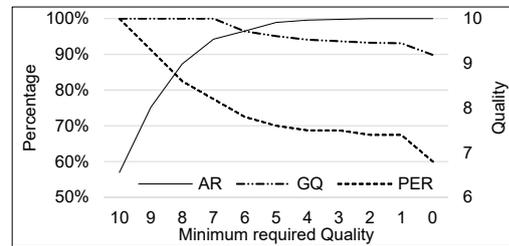


Fig. 16 Evaluation of APS

Naturally, lowering the *QAB* leads to an increasing *AR* while the treatment quality slightly decreases. Lowering the *QAB* from seven to five results in an acceptance increase of 4.73 %, while the *PER* only decreases by 0.6 points. This shows that treatments with quality near the *QAB* are only used as a worst-case option during strain situations.

In most cases, it is possible to find high quality alternatives for patients. Tab. 4 shows that, with a *QAB* of five, 179 patients were rejected and 1319 patients were considered for a redirection. The *REDQA* is 2.01 points related to their initially planned department. 983 patients were relocated, resulting in an average quality change of -0.55 points which underlines that an additional relocation can boost efficiency and quality. The downside of this approach is the increased number of unplanned patient transfers because every relocation is linked to a physical transfer of the patient. The decision-maker has to be aware of that transfers should be limited to a reasonable number. The *APS* outperforms the *BP*, which indicates that the proposed strategy enables the hospital to react to nearly all strain situations without making investments in new infrastructure.

Fig. 17 shows the difference between the *APS* and the *RS*. The *REJ* of the *BP* is shown as an indicator line of the performance of the proposed strategies. The *REJ* is lower for every strategy and for every *QAB* shown in this figure. Still, the total number of redirections and relocations is higher than the *REJ* in *BP* and rises while the *QAB* decreases. This

Table 4 Evaluation of Redirections and Relocations

QAB	REJ	REDC	REDQA	RELC	RELQA
6	582	969	1.73	820	-0.76
5	179	1319	2.01	983	-0.55
4	79	1435	2.16	923	-0.56

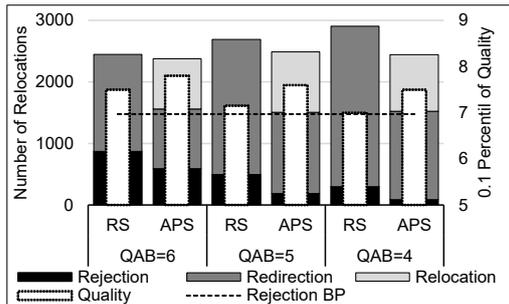


Fig. 17 Evaluation of APS and RS

shows the complexity of this approach as not every rejection in the *BP* can be replaced by one redirection or relocation. In *APS*, all investigated *QAB* show a low *REDC*. As the *REJ* is also lower; we can conclude that relocations have two important impacts on admission decisions and treatment of patients. First, the *REJ* is further reduced and, therefore, the *AR* and the potential revenue of the hospital is increasing. Second, the number of patients receiving their initial treatment without redirections is rising. As the first part of the treatment process generally contains crucial treatments, a rising amount of granted first choices increases the treatment quality and, therefore, the potential outcome of the treatment, which is shown in Fig. 17. To summarize, the first level of flexibility (redirection) will significantly increase the hospital's performance, and the second level of flexibility (relocation) will raise the performance and treatment quality even more.

5 Conclusion

The combination of artificial intelligence (data mining), situational decision making (redirection and relocation policies), and operations research (simulation) can improve the efficiency, occupancy rate, and overall treatment quality of a hospital. Moreover, the provided approach can react to strain situations and solve them before overcrowding states appear. One important tenet of this paper is that local optimizations are not suitable to improve the general efficiency. Utilizing interdependencies is the most promising way to optimize hospital-wide operational decision-making. Therefore, we developed hospital-wide policies to structure ad-hoc decisions in operational patient flow management. Internally

distributing patients during strain situations raises the acceptance rate and minimizing the rejection of patients. We further differentiate into redirections at the planning level and physical relocations during hospitalization.

As not every department is suitable for treating every disease, choosing suitable alternatives during strain situations should be based on the medical needs of patients and the medical capability of a department. We support this decision by developing a data-mining approach to generate suitable alternatives based on treatments needed and the competency provided by departments for these treatments. We intentionally decouple the generation of treatment sets (medical needs) and the quality of treatments provided by a department (department suitability). These two parts combined are forming the operational knowledge a human decision-maker needs to efficiently manage the patient flow.

Using real-world data of a 1000-bed hospital providing maximum care with approximately 46,000 patient records, we found 17,273 different treatment sets covering 1,054 different diagnoses and 5746 department-treatment suitability ratings are calculated. Combining the medical needs and the department suitability to operational knowledge, this paper shows that a median of four alternative departments is present for each treatment set. The detailed analysis of relevant diagnoses indicates that the number of alternatives increases during the hospitalization. This implies that a physical relocation can boost the efficiency of a hospital.

To evaluate the decision-making strategy, we utilize a data-driven hospital-wide simulation model that contains all relevant organizational units of a hospital and mimics the intelligence of a human decision-maker. Using the simulation model, we show that flexible distribution strategies can significantly raise the efficiency of a hospital. The admission rate increases from 91% to 98% while the treatment quality increases from 6.25 points to 7.6 points. This means that using the proposed approach enables the hospital to admit 7% more patients with a better quality of care. Remarkably, this is achieved without making investments in new resources, equipment or staff.

Implementing this approach in a decision support system, each subphase can be enhanced by the influence of human decision-makers. During clinical knowledge mining, a physician could reject or alter a mined treatment set in order to adjust the results to the specific needs of a patient. While generating the operational knowledge, a treatment can be marked as necessary or weighted according to their importance. Hence, the choice of suitable departments can be even more tailored to the patient's medical needs and the hospital's organizational structure. Currently not regarded aspects should be included as additionally policies. As a possible enhancement, the inclusion of future admission dates of the planned patient as an input for decisions could benefit the hospital and patients. Moreover, the fairness of relocations

is not measured and not included. In general, every relocation is linked to a possible loss in quality for this patient. Within the described strategy, it is not forbidden to relocate a patient repeatedly. Hence, it could be possible that a patient is relocated multiple times while other patients are not relocated at all.

Although used for reactive decisions, the mined knowledge can be used to identify transfer points during hospitalization to quickly release capacities in high demand departments by default which proactively avoids strain situations.

Concluding, after evaluating the quantitative outcomes of the simulation study, we are convinced that the proposed approach is a great opportunity for implementing quality-based operational decision support to assist medical experts during strain situations.

Conflict of interest

The authors declare that they have no conflict of interest.

Ethics approval

Was not needed in this paper since data is anonymized and mostly aggregated.

References

- Best, T.J., Sandıkcı, B., Eisenstein, D.D., Meltzer, D.O.: Managing Hospital Inpatient Bed Capacity Through Partitioning Care into Focused Wings. *M&SOM* **17**(2), 157–176 (2015). DOI 10.1287/msom.2014.0516. URL <http://pubsonline.informs.org/doi/10.1287/msom.2014.0516>
- Bhattacharjee, P., Ray, P.K.: Patient flow modelling and performance analysis of healthcare delivery processes in hospitals: A review and reflections. *Computers & Industrial Engineering* **78**, 299–312 (2014). DOI 10.1016/j.cie.2014.04.016. URL <https://linkinghub.elsevier.com/retrieve/pii/S0360835214001272>
- Busby, C.R., Carter, M.W.: Data-driven generic discrete event simulation model of hospital patient flow considering surge. In: Proceedings of the 2017 Winter Simulation Conference (WSC), pp. 3006–3017. IEEE, Las Vegas, NV (2017). DOI 10.1109/WSC.2017.8248022. URL <http://ieeexplore.ieee.org/document/8248022/>
- Butler, T., Reeves, G., Karwan, K., Sweigart, J.: Assessing the impact of patient care policies using simulation analysis. *Journal of the Society for Health Systems* **3**(3), 38–53 (1992)
- Chalgham, M., Khatrouh, I., Masmoudi, M., Walha, O.C., Dammak, A.: Inpatient admission management using multiple criteria decision-making methods. *Operations Research for Health Care* **23**(100173), 1–13 (2019). DOI 10.1016/j.orhc.2018.10.001. URL <https://linkinghub.elsevier.com/retrieve/pii/S2211692317301856>
- Chan, Y.C., Wong, E.W.M., Joynet, G., Lai, P., Zukerman, M.: Overflow models for the admission of intensive care patients. *Health Care Manag Sci* **21**(4), 554–572 (2018). DOI 10.1007/s10729-017-9412-8. URL <http://link.springer.com/10.1007/s10729-017-9412-8>
- Dai, J.G., Shi, P.: Inpatient Overflow: An Approximate Dynamic Programming Approach. *M&SOM* **21**(4), 894–911 (2019). DOI 10.1287/msom.2018.0730. URL <http://pubsonline.informs.org/doi/10.1287/msom.2018.0730>
- Di Mascolo, M., Gouin, A.: A generic simulation model to assess the performance of sterilization services in health establishments. *Health Care Manag Sci* **16**(1), 45–61 (2013). DOI 10.1007/s10729-012-9210-2. URL <http://link.springer.com/10.1007/s10729-012-9210-2>
- Drucker, P.F.: They're Not Employees, They're People. *Harvard Business Review* **80**(2), 70–77 (2002)
- Fletcher, A., Halsall, D., Huxham, S., Worthington, D.: The DH Accident and Emergency Department model: a national generic model used locally. *Journal of the Operational Research Society* **58**(12), 1554–1562 (2007). DOI 10.1057/palgrave.jors.2602344. URL <https://www.tandfonline.com/doi/full/10.1057/palgrave.jors.2602344>
- Günal, M.M., Pidd, M.: DGHPSIM: Generic simulation of hospital performance. *ACM Trans. Model. Comput. Simul.* **21**(4), 1–22 (2011). DOI 10.1145/2000494.2000496. URL <https://dl.acm.org/doi/10.1145/2000494.2000496>
- Goldratt, E.M., Cox, J.: *The Goal*. North River Press (2004)
- Helbig, K., Mellouli, T., Stoeck, T., Gragert, M., Jahn, P.: Simulation stationsübergreifender Patientenflüsse zur Evaluation flexibler Bettenbelegungsszenarien aufgrund der Jahresdatenanalyse eines Universitätsklinikums. In: Tagungsband der Multikonferenz Wirtschaftsinformatik 2014, pp. 749–762. Paderborn (2014)
- Helbig, K., Römer, M., Mellouli, T.: A Clinical Pathway Mining Approach to Enable Scheduling of Hospital Relocations and Treatment Services. In: H.R. Motahari-Nezhad, J. Recker, M. Weidlich (eds.) *Business Process Management*, vol. 9253, pp. 242–250. Springer International Publishing, Cham (2015). DOI 10.1007/978-3-319-23063-4_17. URL http://link.springer.com/10.1007/978-3-319-23063-4_17. Series Title: Lecture Notes in Computer Science
- Helbig, K., Stoeck, T., Mellouli, T.: A Generic Simulation-Based DSS for Evaluating Flexible Ward Clusters in Hospital Occupancy Management. In: Proceedings of the 48th Annual Hawaii International Conference on System Sciences, pp. 2923–2932. IEEE (2015). DOI 10.1109/HICSS.2015.354. URL <http://ieeexplore.ieee.org/document/7070169/>
- Huang, Z., Lu, X., Duan, H.: On mining clinical pathway patterns from medical behaviors. *Artificial Intelligence in Medicine* **56**(1), 35–50 (2012). DOI 10.1016/j.artmed.2012.06.002. URL <https://linkinghub.elsevier.com/retrieve/pii/S0933365712000656>
- Izady, N., Mohamed, I.: A Clustered Overflow Configuration of Inpatient Beds in Hospitals. *M&SOM* **23**(1), 139–154 (2021). DOI 10.1287/msom.2019.0820. URL <http://pubsonline.informs.org/doi/10.1287/msom.2019.0820>
- Kolker, A.: Interdependency of Hospital Departments and Hospital-Wide Patient Flows. In: *Patient Flow: Reducing Delay in Healthcare Delivery*, no. 206 in International Series in Operations Research & Management Science, second edition edn., p. 21. Springer, New York (2013)
- Manktelow, M., Iftikhar, A., Bucholc, M., McCann, M., O'Kane, M.: Clinical and operational insights from data-driven care pathway mapping: a systematic review. *BMC Med Inform Decis Mak* **22**(1), 43 (2022). DOI 10.1186/s12911-022-01756-2. URL <https://bmcmmedinformdecismak.biomedcentral.com/articles/10.1186/s12911-022-01756-2>
- Masmoudi, M., Chalgham, M., Ben Houria, Z.: Fuzzy Decision Making for Inpatient Boarding: Case of a Tunisian Hospital. *International Journal of Industrial Engineering: Theory, Applications and Practice* **25**(3) (2018)
- Mellouli, T., Stoeck, T.: AI/OR Synergies of Process Mining with optimal Planning of Patient Pathways for Effective Hospital-

- Wide Decision Support. In: M. Masmoudi, B. Jarboui, P. Siarry (eds.) *Artificial Intelligence and Data Mining in Healthcare*, 1 edn. Springer International Publishing (2021)
22. Rojas, E., Munoz-Gama, J., Sepúlveda, M., Capurro, D.: Process mining in healthcare: A literature review. *Journal of Biomedical Informatics* **61**, 224–236 (2016). DOI 10.1016/j.jbi.2016.04.007. URL <https://linkinghub.elsevier.com/retrieve/pii/S1532046416300296>
 23. Schwarz, K., Römer, M., Mellouli, T.: A data-driven hierarchical MILP approach for scheduling clinical pathways: a real-world case study from a German university hospital. *Bus Res* **12**(2), 597–636 (2019). DOI 10.1007/s40685-019-00102-z. URL <http://link.springer.com/10.1007/s40685-019-00102-z>
 24. Sinreich, D., Marmor, Y.: A Simple and Intuitive Simulation Tool for Analyzing the Performance of Emergency Departments. In: *Proceedings of the 2004 Winter Simulation Conference, 2004.*, vol. 2, pp. 908–916. IEEE, Washington, D.C. (2004). DOI 10.1109/WSC.2004.1371561. URL <http://ieeexplore.ieee.org/document/1371561/>
 25. Song, H., Tucker, A.L., Graue, R., Moravick, S., Yang, J.J.: Capacity Pooling in Hospitals: The Hidden Consequences of Off-Service Placement. *Management Science* **66**(9), 3825–3842 (2020). DOI 10.1287/mnsc.2019.3395. URL <http://pubsonline.informs.org/doi/10.1287/mnsc.2019.3395>
 26. Song, M., Günther, C.W., van der Aalst, W.M.P.: Trace Clustering in Process Mining. In: D. Ardagna, M. Mecella, J. Yang (eds.) *Business Process Management Workshops*, vol. 17, pp. 109–120. Springer Berlin Heidelberg, Berlin, Heidelberg (2009). DOI 10.1007/978-3-642-00328-8_11. URL http://link.springer.com/10.1007/978-3-642-00328-8_11. Series Title: *Lecture Notes in Business Information Processing*
 27. Stoeck, T., Mellouli, T.: A two-dimensional categorization scheme for simulation/optimization based decision support in hospitals applied to overall bed management in interdependent wards under flexibility. In: M. Masmoudi, B. Jarboui, P. Siarry (eds.) *Operations Research and Simulation in Healthcare*, 1 edn. Springer International Publishing (2021)
 28. Weerawat, W., Pichitlamken, J., Subsombat, P.: A Generic Discrete-Event Simulation Model for Outpatient Clinics in a Large Public Hospital. *Journal of Healthcare Engineering* **4**(2), 285–306 (2013). DOI 10.1260/2040-2295.4.2.285. URL <http://www.hindawi.com/journals/jhe/2013/798050/>

Eidesstattliche Erklärung

Ich erkläre an Eides statt, dass ich die vorliegende Promotion selbstständig und ohne fremde Hilfe verfasst, keine anderen als die von mir angegebenen Quellen und Hilfsmittel benutzt und die den benutzten Werken wörtlich oder inhaltlich entnommenen Stellen als solche kenntlich gemacht habe. Weiterhin wurde die vorliegende Arbeit bisher keiner anderen Prüfungsbehörde in gleicher oder ähnlicher Form vorgelegt.

Ort, Datum

(Thomas Albrecht)