http://dx.doi.org/10.25673/123346

Automatisierung der Verarbeitung heterogener Daten für eine datengetriebene Werkzeugauslegung von Stanzbiegeprozessen mittels Asset Administration Shell

Henning Peters[1], Lukas Kersting[2] und Ansgar Trächtler[3]

Abstract: Die Asset Administration Shell (AAS) gilt als ein vielversprechender Ansatz für die industrielle Umsetzung eines digitalen Zwillings und somit für eine Erhöhung des Automatisierungsgrades. Eine innovative Anwendung der AAS stellt hierbei die hybride, datengetriebene Werkzeugauslegung von Umformprozessen dar. Der hybride Ansatz bezieht hierbei neben klassischen Modelldaten ebenfalls reale Prozessdaten sowie Erfahrungswissen mit ein. Hierdurch entsteht ein heterogener Datensatz, bestehend aus einer hohen Anzahl an Daten mit unterschiedlichen Modalitäten. Dieser Beitrag untersucht anhand des Stanzbiegeprozesses eine Automatisierungsarchitektur mittels AAS-Einbindung, die die heterogenen Datensätze automatisiert akquiriert, verarbeitet und maschinenlesbar zur Verfügung stellt. Hierdurch wird einem Machine Learning Modul ermöglicht, die Wirkzusammenhänge zwischen Prozessparametern und Messdaten zu erlernen und anhand dessen eine optimierte Werkzeugauslegung für spezifische Produktgeometrien auszugeben. Ein Fokus liegt auf der Schnittstelle der heterogenen Prozessdatenrepräsentation, mit der sowohl Anwender als auch ML-Modul interagieren. Diesbezüglich werden zwei Ansätze analysiert und hinsichtlich ihrer Performanz sowie Skalierbarkeit bewertet, um so die Basis für ein anwenderorientiertes Assistenzsystems zur Werkzeugauslegung für Umformprozesse zu bilden.

Keywords: Digitaler Zwilling, Asset Administration Shell, Stanzbiegen, Prozessoptimierung

1 Einleitung

Die Integration der Asset Administration Shell (AAS, Verwaltungsschale) in Industrie 4.0-Anwendungen stellt eine vielversprechende Möglichkeit zur Erhöhung des Automatisierungsgrades und Effizienzsteigerung dar, die aktuell in einer Vielzahl an Veröffentlichungen diskutiert wird. Der Schwerpunkt liegt hier bislang insbesondere im Bereich der Prozessplanung [MK22], der Predictive Maintenance [Wu24] und des standardisierten Informationsaustauschs [Lö21]. Eine innovative Anwendung, die allerdings bislang in der Literatur nur selten untersucht wurde, ist die Kombination der AAS mit datengetriebenen Modellierungsmethoden zur Optimierung der Werkzeugauslegung von umformtechnischen Fertigungsprozessen. Hier liegen neue Potenziale der AAS-Anwendung. Diese sol-

[1] Fraunhofer IEM, Scientific Automation, Zukunftsmeile 1, 33102 Paderborn, henning.peters@iem.fraunhofer.de, https://orcid.org/0009-0000-0145-0247
[2] Fraunhofer IEM, Scientific Automation, Zukunftsmeile 1, 33102 Paderborn, lukas.kersting@iem.fraunhofer.de, https://orcid.org/0000-0002-9733-7528
[3] Heinz Nixdorf Institut, Universität Paderborn, Regelungstechnik und Mechatronik, Fürstenallee 11, 33102 Paderborn, ansgar.traechtler@hni.uni-paderborn.de, https://orcid.org/0000-0001-9987-1655

len in diesem Beitrag am Anwendungsbeispiel des Stanzbiegeprozesses aufgezeigt werden. Der Stanzbiegeprozess ist ein Umformprozess, in dem aus Metallstreifen oder -drähten mithilfe von aufeinanderfolgenden Richt-, Stanz- und Biegeoperationen Produkte wie Federelement, elektronische Kontakte oder Halterungen geformt werden. Eine große Herausforderung dabei sind variierende Krümmungen und Eigenspannungen, die bei Drahtherstellung und -transport in das Halbzeugmaterial induziert werden. Diese wirken sich mittelbar auch auf den Stanzbiegeprozess als Prozessabweichung z. B. in Form von abweichenden Rückfederungseffekten aus [Gr19]. In der Industrie werden diesen Abweichungen anhand von Erfahrungswissen und Faustformeln in der Prozessauslegung sowie in der Produktionsphase manuell und iterativ entgegengewirkt. Aufgrund der komplexen Wechselwirkungen zwischen Halbzeugeigenschaften und Umformwerkzeugen ist dies jedoch nicht immer erfolgsversprechend [ARS11, Gr18]. Um den Entwurfsprozess der Werkzeugauslegung sowie Prozessanpassungen zu verbessern, bedarf es einer datengetriebenen Prozessmodellierung und -optimierung, die als Teil eines Assistenzsystems die benötigte Werkzeuggeometrie und Prozessanpassungen zum Erreichen der gewünschten Bauteilgeometrie dem Anwender ausgeben kann. Hierfür bietet sich insbesondere ein hybrider datengetriebener Ansatz an, der sowohl Daten von klassischen Modellen (analytisch, empirisch, numerisch) als auch Realdaten des Stanzbiegeprozesses miteinbezieht. Klassische Modelle erlauben simulative Untersuchungen an einer großen Anzahl von Werkzeugkonfigurationen, ohne diese im Vorfeld anfertigen zu müssen. Zudem lassen sich auf diese Weise Effekte aufnehmen, die andernfalls nur schwer oder nicht messbar sind. Allerdings basieren sie auf Annahmen und Vereinfachungen, was zu einer Abweichung verglichen mit den realen Gegebenheiten führen kann. Die Hinzunahme von Realdaten erweitert den Datensatz um störgrößenbehaftete Daten, die von den klassischen Modellen nicht berücksichtigt werden, um eine ganzheitliche Prozessabbildung und somit ein robustes Modell zu erhalten [Li22]. Dieser hybride Ansatz benötigt jedoch eine große Anzahl an Daten in heterogenen Datenmodalitäten wie bspw. Zeitseriendaten, Einzel-Sensorsignale, Bilddaten, Datenpunktwolken oder tabellarische Daten. Aufgrund der großen Anzahl an Daten ist eine automatisierte Datenakquise und -verarbeitung notwendig, was das Potenzial der AAS-Anwendung, die als digitaler Zwilling fungieren soll, für die datengetriebene Modellierung des Stanzbiegeprozesses unterstreicht.

2 Hybride Datenquellen

Die Daten, die zur hybriden datengetriebenen Modellierung des Stanzbiegeprozesses und somit zur Optimierung der Werkzeugauslegung verwendet werden sollen, können in drei hybride Datenquellen eingeteilt werden: reale Prozessdaten, Simulationsdaten und historische Daten. Diese beinhalten wiederum unterschiedliche Datenmodalitäten, welche in Tab. 1 aufgeführt werden und für die datengetriebene Werkzeugauslegung automatisiert in einem standardisierten Format vereint werden müssen. Des Weiteren werden die Prozess- und Werkzeugkonfigurationen als eingehende Daten gelistet.

Datenquelle	Parameter	Datenmodalität
Realer Prozess	Kräfte, Krümmung, Biegewinkel	Zeitseriendaten, einzelne Sensorwerte, Bilddaten
Simulation	Kräfte, Biegewinkel, Eigenspannungen, Dehnungen	Zeitseriendaten, einzelne Sensorwerte, Datenpunktwolken
Historische Daten (analyt. Modelle, exp. Untersuchungen)	Kräfte, Biegewinkel	Tabellarische Daten
Prozesskonfiguration	Werkzeuggeometrien, Prozesseinstellungen, Materialeigenschaften	Einzelne Parameterwerte, Messkurven

Tab. 1: Hybride Datenquellen und deren zugehörige Parameter und Datenmodalitäten für die hybride datengetriebene Werkzeugauslegung für Stanzbiegeprozesse

Die *realen Prozessdaten* werden in der in Abb. 1 dargestellten Versuchsstrecke aufgenommen. Der aufgebaute Stanzbiegeprozess besteht aus einem Coil mit drahtförmigem Halbzeugmaterial, einem mechatronische Richtapparat und einer Stanzbiegemaschine. Der in [Ba23] entwickelte mechatronische Richtapparat besteht aus sieben Richtrollen (3 oben, 4 unten), zwischen denen der Draht alternierend umgeformt wird. Die oberen drei Richtrollen sind hierbei jeweils mit einem Schrittmotor verbunden und können somit über die Anlagensteuerung verfahren werden. Zur Erfassung der Effekte des Richtens auf das Halbzeug wurde an den oberen drei Richtrollen jeweils ein Kraftsensor integriert. So können die resultierenden Umformkräfte erfasst werden. Die Kraftmessungen werden dabei als Zeitseriendaten aufgenommen. Mittels einer optische Offline-Messung wird die Drahtkrümmung vor bzw. nach dem Richten bestimmt. Hierbei nimmt eine Industriekamera mehrere Koordinatenpunkte der Drahtkontur auf, um nachfolgend die Drahtkrümmung als einzelnen Sensorwert bestimmen zu können. Im Anschluss wird der Draht vom Richtapparat zur Stanzbiegemaschine geführt, um hier durch aufeinanderfolgende Stanz- und Biegeoperationen die gewünschte Produktgeometrie zu erhalten. In der Stanzbiegemaschine wird der resultierende Biegewinkel des Stanzbiegeprodukts ebenfalls mit einer optischen Messung erfasst. Dies geschieht inline mithilfe der Objekterkennung der Kamerasoftware. Diese bestimmt die geometrischen Eigenschaften des Produktes und gibt im Anschluss einen einzelnen Sensorwert für den Biegewinkel aus. Bei mehreren Biegeoperationen wird dementsprechend pro Biegeoperation ein Sensorwert für den jeweiligen Winkel ausgegeben. Zur Nachvollziehbarkeit der Umformeffekte wurde ebenfalls eine Kraftmessung in die Stanzbiegemaschine integriert, die die anliegenden Biegekräfte am Biegestempel als Zeitserie erfasst. Alle Daten werden der speicherprogrammierbaren Steuerung (SPS) zugesendet. Der Versuchsstand nutzt hierfür die Automatisierungssoftware TwinCAT der Firma Beckhoff (Verl).

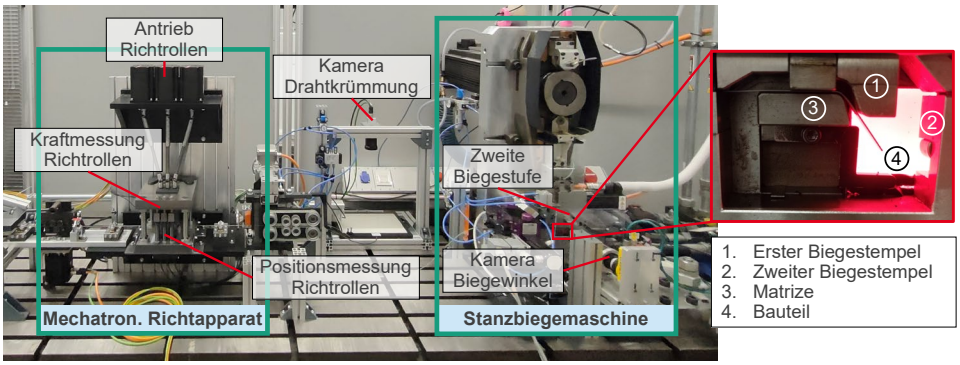

Abb. 1: Mechatronisierter Stanzbiegeprozess, bestehend aus Richtapparat und Stanzbiegemaschine

Simulationsdaten werden mit der FE-Software Abaqus akquiriert. Neben Kräften und geometrischen Merkmalen können ebenfalls Eigenspannungen und Dehnungen aufgenommen werden. Dabei werden die Werte den Knotenpunkten des FE-Netzes zugewiesen. Dementsprechend liegen diese Daten in den jeweiligen Zeitschritten der FE-Simulation als Datenpunktwolken vor. Die Richteffekte sind als variierende Materialeigenschaften, wie bspw. E-Modul, Streckgrenze und Zugfestigkeit, in der Simulation integriert. Neben einzelnen Materialkennwerten wird auch der Wertverlauf der Fließkurve berücksichtigt. Der Begriff *historische Daten* umschreibt bereits vorliegende Daten aus experimentellen Untersuchungen oder Daten von analytischen Modellen in tabellarischer Form.

3 Automatisierungsarchitektur zur hybriden datengetriebenen Modellierung

Der digitale Zwilling bildet die Schnittstelle zwischen den hybriden Datenquellen, dem Anwender und dem sogenannten Machine Learning Modul (ML-Modul), das die datengetriebene Modellierung beinhaltet. Die erforderliche Funktionalität des digitalen Zwillings hinsichtlich einer automatisierten Aufnahme, Sicherung, Verarbeitung und Weiterleitung heterogener Daten wird hierbei anhand des technologieneutralen Standards der AAS realisiert. Auf diese Weise können Daten aus unterschiedlichen Quellen und unterschiedlichen Modalitäten miteinander vereint und maschinenlesbar dargestellt werden [Al25]. Die automatisierte Handhabung heterogener Daten mittels AAS erfordert hierbei mehrere Komponenten, die in Abb. 2 dargestellt sind. Diese Komponenten stellen die Automatisierungsarchitektur der automatisierten Werkzeugauslegung dar, welche den digitalen Zwilling innerhalb des hybriden Machine Learning Moduls (HML-Moduls) bildet.

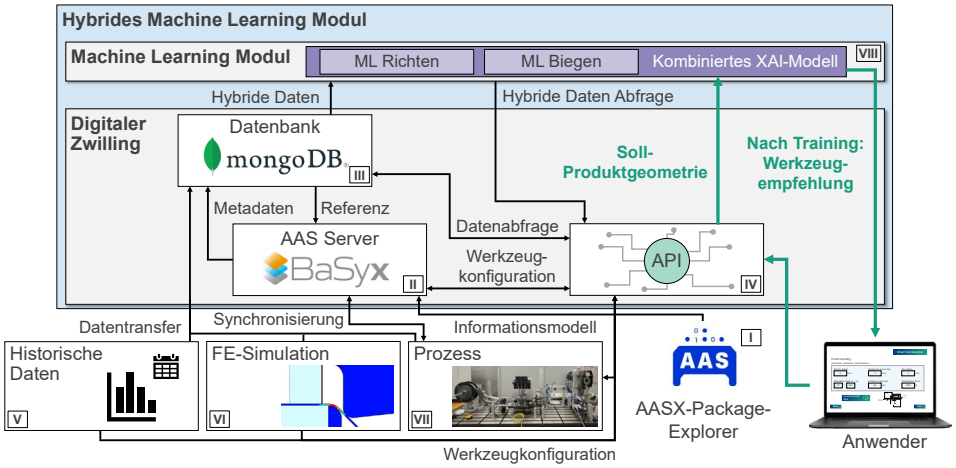

Abb. 2: Schematische Darstellung der Automatisierungsarchitektur des hybriden Machine Learning Moduls (HML-Moduls) bestehend aus dem AAS-basiertem digitalen Zwilling

Die AAS-Spezifikation wird über die semantische Modellierung einer digitalen Repräsentation des Stanzbiegeprozesses eingebracht. Diese wird mit der Software AASX Package Explorer (**I**) entworfen. Der Schwerpunkt der Untersuchungen liegt hierbei auf der Integration der Werkzeug- und Prozessparameter sowie der Sensoren, um den technologieneutralen Austausch der Prozesseingangsdaten und -ausgangsdaten mit dem angebundenen ML-Modul (**VIII**) zu ermöglichen. Für die Integration der AAS und des modellierten Informationsmodells in den digitalen Zwilling gibt es in der Literatur mehrere open-source Implementierungen. In [Ka25] wird eine Übersicht von verfügbaren Implementierungen sowie ein Vergleich dieser vorgestellt. Hierbei wird ersichtlich, dass Eclipse BaSyx die Anforderungen an eine automatisierte Verarbeitung hybrider Daten am besten erfüllt. Aufgrund dessen wird es als sogenannter AAS-Server (**II**) im digitalen Zwilling integriert und erlaubt so die Interaktion mit dem Informationsmodell. Die Kommunikation wird mittels HTTP/REST innerhalb einer Docker-Umgebung realisiert, an die ebenfalls der Realprozess angebunden wird. Durch die aufgebaute Synchronisierung der Prozessdaten mit dem digitalen Zwilling werden so zum einen Sensordaten im AAS-Server dargestellt, zum anderen können jedoch auch über den AAS-Server Aktoreinstellungen vorgenommen werden, die im Anschluss von der Anlage ausgeführt werden. Auf diese Weise können bspw. Empfehlungen des ML-Moduls direkt in der Anlage umgesetzt werden. Die Datenbank (**III**) stellt eine weitere entscheidende Komponente des digitalen Zwillings dar. Hierin werden alle heterogenen Prozessdaten sowie Prozess- und Werkzeugparameter hinterlegt. Um jedoch die verschiedenen heterogenen Datenformate von unterschiedlichen Datenquellen in ein standardisiertes Format zu vereinen, wurde durch die Autoren dieses Beitrags in [Pe26] eine Datenbankstruktur entworfen (vgl. Abb. 3), um die untersuchten Werkzeugkonfigurationen den jeweiligen Messungen bzw. FE-Simulationen zuzuweisen. Jeder Werkzeugparameter sowie die Kombination aller Parameter, die für die Messung/Simulation verwendet werden, erhalten jeweils eine eigene ID, die dann einer jeweiligen

Messung/Simulation und den entsprechenden aufgenommenen Daten zugeteilt wird. Die Generierung und Zuteilung der IDs erfolgt hierbei zentral über eine in Python entworfene Anwendungsprogrammierschnittstelle (API, **IV**). Kernfunktion der API ist, die unterschiedlichen Datenquellen (historische Daten aus Referenzversuchen oder analytischen Modellen (**V**), Simulationsdaten (**VI**), Realdaten (**VII**)) automatisiert in ein einheitliches, maschinenlesbares Format für die hybride datengetriebene Modellierung des Stanzbiegeprozesses zu überführen. Infolgedessen können die akquirierten hybriden Daten an das ML-Modul (**VIII**) transferiert werden, um so die Wirkzusammenhänge zwischen den Prozessparametern und den ermittelten Produkteigenschaften zu erlernen. Nach dem Training erlauben die verwendeten ML-Algorithmen des ML-Moduls, welche von den Autoren in [Ma25] vorgestellt wurden, anhand der erlernten Wirkzusammenhänge optimierte Prozessanpassungen und Werkzeuggeometrien an den Anwender zurückzugeben.

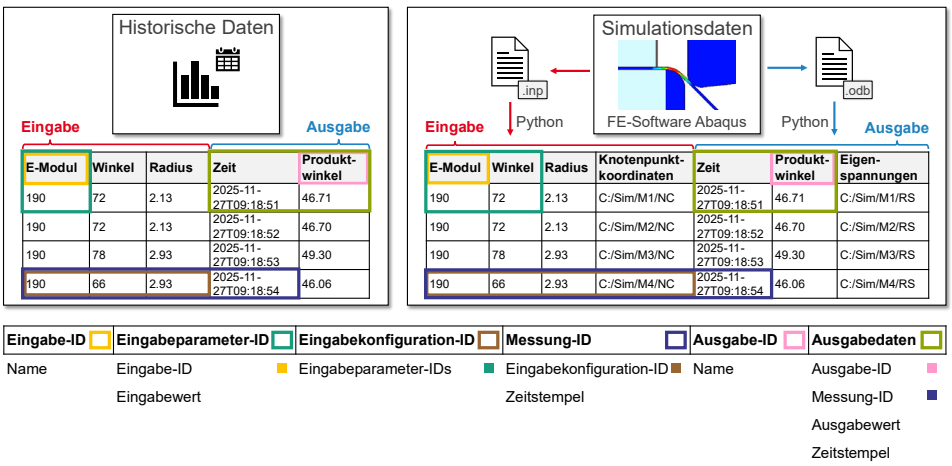

Abb. 3: Schematische Darstellung der Datenbankstruktur für eine standardisierte Ablage heterogener Daten hinsichtlich einer hybriden datengetriebenen Modellierung nach [Pe26]

Die Funktionsabfolge der automatisierten Datenakquise für die datengetriebene Modellierung wird in einen Ablauf für Realdaten und in einen Ablauf für Simulationsdaten bzw. historische Daten unterteilt. Bei Realdaten erfolgt die Datenaufnahme über die Anlagensteuerung. Hierfür werden den Messungen die notwendigen IDs mittels API-Anfragen zugeteilt und anschließend automatisiert in die Datenbank transferiert. Die Initialisierung einer solchen Messung wird über den AAS-Server vollzogen. Im Gegensatz dazu werden Simulationsdaten und historische Daten nicht direkt in die Datenbank übertragen. Es wird angenommen, dass alle historischen Daten in einem tabellarischen Format (.csv) vorliegen müssen. Die in Abaqus erstellten FE-Simulationsdaten sind jedoch ausschließlich in dem .inp-Format sowie dem proprietären .odb-Format exportierbar. Daher müssen die Daten zunächst in das tabellarische Format transformiert werden. Hierfür wird ein eigens entwickelter Parser verwendet. Dieser Prozess ist schematisch in Abb. 3 dargestellt. Im Anschluss werden die Prozessparameter und Ergebnisse mittels der API ausgelesen und in

die Datenbank überführt. In Abb. 4 ist beispielhaft der Ablauf anhand der historischen Daten bzw. Simulationsdaten in einem Sequenzdiagramm dargestellt. Im Abschnitt *Datentransfer in Datenbank* werden die Daten nach einer möglichen Umwandlung in das tabellarische Format der API bereitgestellt. Innerhalb der API werden die tabellarischen Daten zunächst in Eingangs- und Ausgangsdaten aufgeteilt. Dies ist für die korrekte Zuteilung der Daten in die Datenbankstruktur erforderlich, was im Anschluss erfolgt. Alle in der Datenbank aufgenommenen Messungen bzw. Simulationen werden hierbei ebenfalls auf dem AAS-Server referenziert. Im Abschnitt *Datentransfer zum ML-Modul* wird dann über das ML-Modul nach neu hinzugefügten Daten gesucht. Je nach gewähltem Ansatz der Prozessdatenrepräsentation gibt es hierbei zwei unterschiedliche Abfolgen: Ansatz 1 und 2. Beide Ansätze werden im nachfolgenden Kapitel näher beleuchtet. Die Daten werden anschließend mittels API in die jeweiligen Klarnamen und -daten entschlüsselt und an das ML-Modul ausgegeben. Abhängig davon, ob das ML-Modul bereits trainiert wurde oder nicht, werden die neuen Daten entweder zum Finetuning oder zum initialen Trainieren des ML-Moduls verwendet. Das trainierte ML-Modul kann dann im letzten Abschnitt (*Ausgabe der Prozesskonfigurations-Empfehlung)* für eine vom Anwender definierte Zielgeometrie eine entsprechende Empfehlung der Werkzeugauslegung an den Anwender bzw. die Anlage über BaSyx zurückgeben.

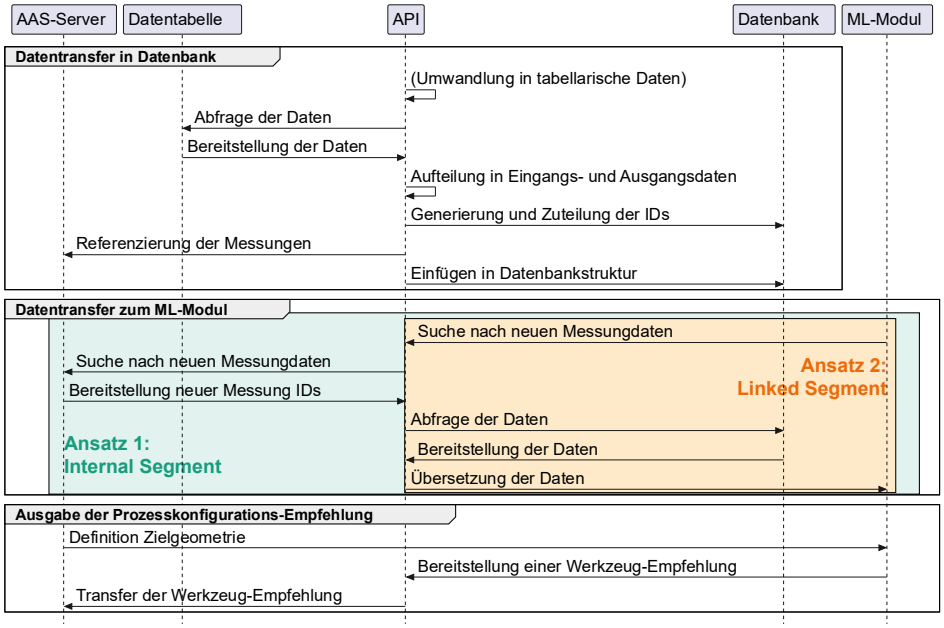

Abb. 4: Sequenzdiagramm der automatisierten Datenakquise und -verarbeitung hinsichtlich der datengetriebenen Werkzeugauslegung am Beispiel von Simulationsdaten und historischen Daten

4 Repräsentation der hybriden Daten in der Asset Administration Shell

Für eine maschinenlesbare als auch für den Anwender geeignete Interaktionsmöglichkeit mit den akquirierten hybriden Daten bedarf es eine entsprechende semantisch modellierte Repräsentation. In diesem Kapitel wird dementsprechend näher auf das zugrundeliegende Informationsmodell der Automatisierungsarchitektur aus Kapitel 3 eingegangen und es werden zwei Ansätze der Prozessdatenrepräsentation bzw. -interaktion in Anlehnung an das von der Industrial Digital Twin Association (IDTA) konzipierte *Time Series Data* Submodel Template vorgestellt.

Das AAS-Informationsmodell des Stanzbiegeprozess unterteilt sich in seine einzelnen Prozessstufen und -elemente. Dies resultiert in einer durch die Autoren dieses Beitrags in [Pe25] vorgestellten hierarchischen Struktur, die mit dem Asset des Stanzbiegeprozesses als übergeordnete AAS modelliert wird. Diesem untergeordnet sind die einzelnen Prozessstufen wie das Richten, die Stanzbiegeoperation sowie die Abschnitte vor, zwischen und nach den Umformstufen, um die Halbzeug- bzw. Produkteigenschaften zu repräsentieren. Jede Stufe wird durch eine eigene AAS dargestellt. Diese Ebene wird wiederum von den AAS der einzelnen Prozesselementen wie Sensoren, Aktoren, Werkzeugen, Material oder Simulationen beschrieben. Die AAS können weiter in Submodels unterteilt werden um Metadaten bspw. technische Daten, Dokumente oder CAD-Daten zu hinterlegen und so eine ganzheitliche Repräsentation des Prozesses zu erhalten. Aufgrund des Ziels einer datengetriebenen Werkzeugauslegung liegt der Fokus primär auf der Repräsentation der Prozessdaten sowie der Darstellung der verwendeten Eingangsparameter wie der Werkzeugkonfiguration oder der Materialdaten, um anhand dessen die Wirkzusammenhänge zu erlernen. Während Echtzeit-Daten der Sensoren an die jeweiligen AAS der Sensoren übertragen werden, werden resultierende Mess- und Simulationsdaten mittels einer gesonderten AAS repräsentiert, um so eine zentrale Schnittstelle für Anwender und ML-Modul zu schaffen.

Für die Modellierung von Submodels werden durch die IDTA sogenannte Submodel Templates für verschiedene Anwendungsfälle und Domänen entwickelt und zur Verfügung gestellt. Submodel Templates stellen Vorlagen für die einheitliche Erstellung von Submodels dar, um so eine Interoperabilität zwischen verschiedenen Anwendungen und Nutzern zu erhalten. Durch die Verwendung der Templates kann somit eine mögliche Transferierbarkeit des hybriden datengetriebenen Ansatzes erleichtert werden. Für die Repräsentation der Messergebnisse wird das sog. *Time Series Data* Template eingesetzt. Anhand der definierten SubmodelElements innerhalb des Templates lassen sich für den beschriebenen Ansatz unter Verwendung der Datenbankstruktur aus Kapitel 3 neben den Zeitseriendaten ebenfalls die anderen Datenmodalitäten beschreiben. Durch das Submodel Template *Provision of Simulation Models* können weiterhin die Metadaten der Simulationen abgebildet werden. Im *Time Series Data* Template selbst werden drei Arten an Repräsentationen von Messergebnissen definiert. Beim *InternalSegment* werden Messdaten direkt in der AAS verwaltet. Das *LinkedSegment* beschreibt eine externe Datenverwaltung

außerhalb der AAS (Referenz auf Endpunkt) und schafft so eine Repräsentation der Messdaten. Beim *ExternalSegment* wird hingegen auf eine Datei von Datenpunkten (Referenz auf Datei) verwiesen [In23]. Für das Informationsmodell der datengetriebenen Werkzeugauslegung wird aufgrund der vorliegenden Datenformate die Darstellung über das *InternalSegment* bzw. das *LinkedSegment* in Betracht gezogen. Im Folgenden sollen beide Repräsentationsansätze gegenübergestellt und hinsichtlich ihrer Performanz untersucht werden.

Die Integration beider Ansätze in die Automatisierungsarchitektur wird in der bereits im vorherigen Kapitel erläuterten Abb. 4 im Abschnitt des *Datentransfers zum ML-Modul* dargestellt. Bei einer direkten Verwaltung innerhalb des AAS-Servers mittels des *InternalSegments* wird die Anfrage des ML-Moduls nach neuen Messdaten über die API an den AAS-Server gesendet. Innerhalb des AAS-Servers werden hierbei alle Messungen durch das Referenzieren im Abschnitt *Datentransfer in Datenbank* mittels ihrer Messung-ID dargestellt. Aus Sicht des Anwenders können auf diese Weise alle Messungen und Simulationen als ID sowie deren Metadaten eingesehen werden (vgl. Abb. 5). Die tatsächlichen Messdaten sind jedoch in der Datenbank aufgeführt. Beim Ansatz des *LinkedSegments* wird direkt auf den im Submodel hinterlegten Endpunkt einer externen Datenverwaltung - der Datenbank - zugegriffen. Somit werden die Messung-IDs nicht aufgeführt. Der Anwender bekommt jedoch die Gesamtanzahl der übertragenen Messung sowie die Anzahl der bereits erlernten Messungen (*RecordCount, TrainedCount*) angezeigt. Neben den Messung-IDs wird bei beiden Ansätzen ebenfalls der Status (*übertragen, trainiert*) aufgeführt. Anhand dessen kann das ML-Modul ableiten, auf welchen Daten noch trainiert werden muss und welche Daten bereits erlernt wurden.

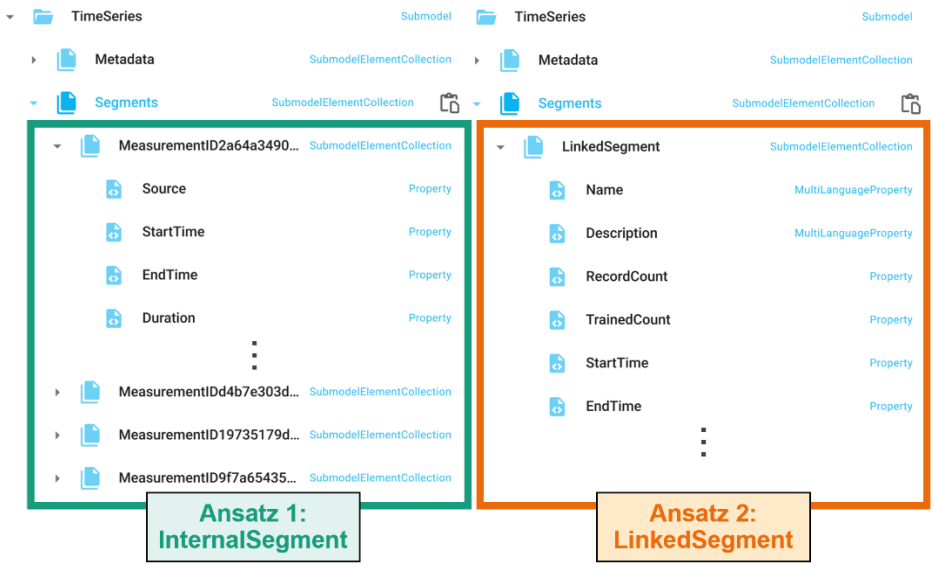

Abb. 5: Darstellung der Prozessdatenrepräsentation innerhalb der BaSyx-Nutzeroberfläche

Für einen Vergleich der Übertragungszeiten beider Ansätze wurde ein Datensatz bestehend aus 663 Simulationen [PPH26] verwendet. Der Datensatz lässt sich in 10 Eingangsparameter und 16 Ausgangsparameter unterteilen. Des Weiteren wurden zusätzlich zu den bereits transferierten 663 Simulationen weitere 663 Simulationen übertragen, um das Verhalten der Automatisierungsarchitektur bei einem nachträglichen Hinzufügen von Daten im Sinne eines kontinuierlichen Lernprozesses des ML-Moduls zu untersuchen. Die Ergebnisse sind in Tab. 2 dargestellt.

	Ansatz 1: InternalSegment		**Ansatz 2: LinkedSegment**	
	Transferzeit zu DB [s]	Transferzeit zu ML [s]	Transferzeit zu DB [s]	Transferzeit zu ML [s]
663 Simulationen	7,72	2,82	6,56	0,33
weitere 663 Simulationen	9,61	3,62	6,37	0,33

Tab. 2: Gegenüberstellung der beiden Datenrepräsentationsansätze hinsichtlich der Übertragungszeiten (Intel Core i7-1260P, 32 GB DDR4 RAM)

Es wird ersichtlich, dass die Anfragen an den digitalen Zwilling mittels HTTP in Ansatz 1 zu einer höheren Übertragungszeit im Vergleich zu Ansatz 2 führen. Dies gilt sowohl für den Datentransfer an die Datenbank, bei der die *InternalSegments* für jede Messung in das Submodel eingefügt werden, als auch für den Datentransfer an das ML-Modul, bei der zunächst das Submodel nach den Messung-IDs angefragt werden muss. Zudem ist zu erkennen, dass das Hinzufügen eines weiteren Datensatzes einen negativen Einfluss auf die Transferzeit bei Ansatz 1 hat, während dies bei Ansatz 2 nicht zu beobachten ist. Die Verringerung der Transferzeit zur Datenbank bei Ansatz 2 lässt sich damit erklären, dass die jeweiligen Parameter in der Datenbankstruktur nicht neu angelegt werden müssen und die Daten direkt eingeordnet werden können. Neben den Transferzeiten weist Ansatz 1 einen weiteren Nachteil auf. Durch das direkte Hinterlegen der Messung-IDs im Submodel werden die entsprechenden Metadaten von BaSyx in einer eigenen MongoDB Collection, im sogenannten Submodel Repository gespeichert. Da *LinkedSegments* als Submodel Element modelliert werden, werden diese nicht als eigenes MongoDB-Dokument, sondern innerhalb eines Dokuments eines Submodels hinterlegt. Diese Verschachtelung führt dazu, dass bei einer hohen Anzahl an Messung die maximale Kapazität eines Dokuments (BSON-Format) von 16 Mebibytes (MiB, entspricht 16,78 Megabytes) überschritten wird. Um dieses Problem zu umgehen, müssten weitere Submodels für die Messdaten angelegt werden. Die Transferzeit würde sich so aufgrund der steigenden Anzahl an Anfragen weiter erhöhen. Eine weitere Möglichkeit wäre der Einsatz der GridFS Spezifikation von MongoDB, welches die Dateien innerhalb eines Dokuments in sog. Chunks unterteilt und so das Speichern von Dokumenten größer als 16 MiB ermöglicht. Diese Spezifikation ist jedoch in der MongoDB Integration von BaSyx bisher nicht berücksichtigt.

Zusammenfassend erweist sich anhand der Analyse der Ansatz 2, die Prozessdatenrepräsentation mittels *LinkedSegments,* als performantere sowie skalierbarere Schnittstelle zu den hybriden Daten im Zuge der hybriden datengetriebenen Werkzeugauslegung.

5 Fazit und Ausblick

Dieser Beitrag beleuchtete eine innovative Anwendung der Asset Administration Shell für die hybride datengetriebene Werkzeugauslegung für Stanzbiegeprozesse. Hierbei wurde die Automatisierungsarchitektur, die die automatisierte Akquise und Verarbeitung hybrider Daten zur automatisierten Werkzeugauslegung für Stanzbiegeprozesse ermöglicht, auf methodischer Ebene untersucht. Insbesondere wurden Einblicke in die Implementierung der Datenbankstruktur gegeben, die mittels spezifischer Identifikatoren Werkzeug- und Prozessparameter sowie die jeweiligen Mess- bzw. Simulationsdaten in einem standardisierten Format vereint und so dem ML-Modul zum Erlernen der Wirkzusammenhänge, maschinenlesbar zur Verfügung stellt. Die in die Automatisierungsarchitektur integrierte API steuert hierbei zentral die Generierung und Zuteilung der IDs. Zudem leitet die API die Referenzen der Messungen/Simulationen an die AAS-Implementierung weiter, um eine Schnittstelle zwischen den hybriden Daten, dem Anwender sowie dem ML-Modul zu ermöglichen. Der Beitrag stellte abschließend einen Vergleich zwischen zwei Ansätzen zur Ausgestaltung dieser Schnittstelle sowie dem zugrundeliegenden Informationsmodell auf. Hierbei zeigte sich, dass die Verwendung von *LinkedSegments* unter Verwendung des *Time Series Data* Submodel Templates ggü. dem Ansatz mit *InternalSegments* auf eine geringere Rechenzeit führt und daher, bedingt durch zeitliche sowie strukturelle Limitierungen, vorzuziehen ist.

Der entwickelte digitale Zwilling bildet somit die Basis für weiterführende Untersuchungen hinsichtlich eines Assistenzsystems zur Werkzeugauslegung, welche verstärkt die Interaktion mit dem Anwender beleuchten sollen. Dies beinhaltet unter anderem die Einbindung von XAI-Methoden in eine anwenderorientierte Benutzerschnittstelle, um Optimierungsempfehlungen nachvollziehbar zu übermitteln. Gleichzeitig soll vorhandenes Expertenwissen seitens des Anwenders für die datengetriebene Optimierung integriert und konserviert werden, was eine Erweiterung des AAS-Informationsmodells zur Folge hat. Ebenfalls ist die Integration weiterer Prozessparameter und Unsicherheiten (epistemisch, aleatorisch) sowie eine Komplexitätssteigerung des Umformprozesses vorgesehen, was eine evolvierbare und skalierbare Automatisierungsarchitektur voraussetzt, die in diesem Beitrag bereits in ihren grundlegenden Strukturen vorgestellt wurde.

Danksagung

Die Autoren danken der Deutschen Forschungsgemeinschaft (DFG) für die Förderung des Projekts Nr. 520459685 „Datengetriebene Modellierung von mehrstufigen Stanzbiegeprozessen“ im Rahmen des Schwerpunktprogramms SPP 2422 „Datengetriebene Prozessmodellierung in der Umformtechnik“.

Literaturverzeichnis

[Al25] Alexopoulos, A. et al.: Why Asset Administration Shells: A Survey on Uses and Challenges. IEEE Access 13, S. 126582–126609, 2025. DOI: https://doi.org/10.1109/ACCESS.2025.3589931

[ARS11] Amor, A.; Rachik, M.; Sfar, H.: Combination of Finite-Element and Semi-Analytical Models for Sheet Metal Leveling Simulation. In (Duflou, J.R. Hrsg.): KEM 473, S. 182–189, 2011. DOI: https://doi.org/ 10.4028/www.scientific.net/KEM.473.182

[Ba23] Bathelt, L. et al.: Novel Straightening-Machine Design with Integrated Force Measurement for Straightening of High-Strength Flat Wire. Sensors 23/22, 2023. DOI: https://doi.org/10.3390/s23229091

[Gr18] Gräler, M. et al.: Assisted setup of forming processes: compensation of initial stochastic disturbances. In (Onori, M: et al. Hrsg.): Procedia Manufacturing 25, S. 358–364, 2018. DOI: https://doi.org/10.1016/j.promfg.2018.06.104

[Gr19] Grüber, M.: Konzepte zur Steuerung des Richtwalzprozesses bei variierenden Richtguteigenschaften. Dissertation, Institut für Bildsame Formgebung, Rheinisch-Westfälische Technische Hochschule Aachen, 2019.

[In23] Industrial Digital Twin Association, IDTA 02008-1-1 Time Series Data (2023), https://github.com/admin-shell-io/submodel-templates/blob/main/published/Time%20Series%20Data/1/1/IDTA%2002008-1-1_Submodel_TimeSeriesData.pdf, Stand: 24.04.2026.

[Ka25] Kaya, F. et al..: Asset Administration Shell Tool Comparison: A Case Study with Real Digital Twins Used in Petrochemical Industry. Sensors 25/7, 2025. DOI: https://doi.org/10.3390/s25071978

[Li22] Liewald, M. et al.: Perspectives on data-driven models and its potentials in metal forming and blanking technologies. Production Engineering 16/5, S. 607–625, 2022. DOI: https://doi.org/10.1007/s11740-022-01115-0

[Lö21] Löcklin, A. et al.: Data administration shell for data-science-driven development. In (Lutters, E. Hrsg.): Procedia CIRP 100/31, S. 115–120, 2021. DOI: https://doi.org/10.1016/j.procir.2021.05.019

[Ma25] Mazur, A. et al.: Studying the Generalization Behavior of Surrogate Models for Punch-Bending by Generating Plausible Counterfactuals. In (Senn, W. et al. Hrsg.): Artificial Neural Networks and Machine Learning – ICANN 2025. LNCS, Springer, Cham, S. 192–203, 2025. DOI: https://doi.org/10.1007/978-3-032-04555-3_16

[MK22] Müller-Zhang, Z.; Kuhn, T.: A Digital Twin-based Approach Performing Integrated Process Planning and Scheduling for Service-based Production. In (Gao, F. Hrsg.): 2022 IEEE 27th ETFA, 2022. DOI: https://doi.org/10.1109/ETFA52439.2022.9921643

[Pe25] Peters, H. et al.: Development of a digital twin for data-driven modeling of punch-bending processes using a graphical modeling notation. at- Automatisierungstechnik 73/3, 2025. DOI: https://doi.org/10.1515/auto-2024-0112

[Pe26] Peters, H. et al.: Method of an Automated Tool Design of Punch-Bending Processes Using the Asset Administration Shell. In (Andrade-Campos, G. Hrsg.): KEM 1049, S. 43-54, 2026. DOI: https://doi.org/10.4028/p-YFY9Oq

[PPH26] Pandey, A. K.; Peters, H.; Homberg, W.: A Dataset for Multi-Stage Straightening and Bending Processes, https://doi.org/10.5281/zenodo.18314007, Stand: 24.04.2026.

[Wu24] Wurm, S. et al.: Service-based tool lifecycle analysis based on AAS. In (Putnik, G. Hrsg.): Procedia CIRP 130/57, S. 1562–1568, 2024. DOI: https://doi.org/10.1016/j.procir.2024.10.283