LaiLa Modellfabrik - Eine Validierungsplattform für Künstliche Intelligenz im Bereich Cyber-Physischer Produktionssysteme im Leichtbau

Anna Nordhausen*, Jonas Ehrhardt,
Nantwin Möller
Institute of Automation
Helmut Schmidt University
Hamburg, Germany
*anna.nordhausen@hsu-hh.de

***Kurzfassung* – Neue Methoden aus den Bereichen Künstliche Intelligenz (KI) und Maschinelles Lernen (ML) sind häufig datengetrieben. Um eine erfolgreiche Anwendung in KI oder ML zu garantieren, müssen Datensätze breite Fehlerverteilungen sowie hohe Varianzen in der Fertigungssystemkomplexität und dem Einsatz verschiedener Fertigungsverfahren besitzen. Existierende Datensatze spiegeln dies zumeist nicht wider. Aus diesem Grund wird im Forschungsprojekt "LAboratorium für Intelligente LeichtbAuproduktion" (LaiLa) eine Modellfabrik für mehrstufige Produktions- und Fertigungsprozesse im seriellen Leichtbau geschaffen. Mithilfe der Modellfabrik sollen unter anderem realistische Datensätze aufgezeichnet werden, welche von verschiedenen Verfahren aus KI und ML sowie variierenden Zielstellungen verwendet werden können. Im Folgenden werden drei Zielstellungen, welche mit drei verschiedenen ML Verfahren im Rahmen des Forschungsprojekts LaiLa adressiert werden, vorgestellt: Roboterpfadregelung beim Ultraschallschweißen von Thermoplasten mit Reinforcement Learning, Generative Modelle zur Erstellung von Trainingsdatensätzen bei der Fehlerklassifikation von additiv gedruckten Bauteilen und das Lernen von Repräsentationen von Produktionsprozessen bei der Planung neuer oder veränderter Prozesse. Mithilfe des Modellfabrikkonzepts können diese Verfahren, neben existierenden artifiziellen Benchmarks, validiert werden.**

Stichworte - Künstliche Intelligenz, Maschinelles Lernen, Reinforcement Learning, Generative Modelle, Repräsentationslernen

I. EINLEITUNG

Digitalisierungs- und Automatisierungsthemen halten in der Industrie weiterhin Einzug. Je mehr Prozesse automatisiert und digitalisiert werden, desto mehr Prozessdaten können hierzu aufgenommen und mithilfe neuer Verfahren analysiert werden. In vielen Fällen haben sich Automatisierungslösungen bereits in Unternehmen etabliert, jedoch bleiben die Erkenntnisse häufig ungenutzt oder es findet nur eine teilweise Nutzung statt.

Es kommt hinzu, dass es nur sehr wenige reale Datensätze gibt, die der Forschung zur Verfügung gestellt werden. Dies liegt daran, dass Unternehmen oftmals befürchten, zusammen mit den Daten auch Unternehmensgeheimnisse preiszugeben. Ebenso umfassen reale Datensätze häufig nur geringe Varianzen und Variabilitäten. Fehler finden in realen Szenarien nur selten statt, sodass diese oft nicht in den Datensätzen enthalten sind. [1]

Des Weiteren ist die Auslastung von Realsystemen in Industrieunternehmen häufig so hoch, dass eine Nutzung für Forschungszwecke oft nicht möglich ist. Die Folge ist, dass nur wenige ausreichende Tests durchgeführt werden können und die Datenquantität, wie auch -qualität nicht ausreichend sind.

Im Rahmen des Forschungsprojekts "LAboratorium für Intelligente LeichtbAuproduktion"(LaiLa) wird aktuell eine Modellfabrik geschaffen, welche unter anderem die Möglichkeit bietet, in einem industriellen Umfeld unter Realbedingungen, Datensätze verschiedenster Art, insbesondere für Methoden der Künstlichen Intelligenz (KI) und des Maschinellen Lernens (ML), aufzunehmen. Ebenso können eine Vielzahl von Forschungsansätzen in den Bereichen Digitalisierung und Automatisierung vorangetrieben werden, um neue Sprunginnovationen zu erreichen. Kern des Laboratoriums ist eine intelligente Modellfabrik, welche als Demonstrations-, Schulungs- und Validierungsplattform für neue Ideen, Konzepte und Verfahren in der Domäne Leichtbau dienen soll. Sie besteht aus modernen Cyber-Physischen Produktionssystemen. [2]

Dieser Beitrag befasst sich mit verschiedenen Möglichkeiten des Einsatzes von Methoden der KI, die sich aus der Nutzung der Modellfabrik in LaiLa ergeben. Der Beitrag ist wie folgt aufgeteilt. Kapitel II befasst sich mit der Modellfabrik im Allgemeinen. In Kapitel III wird ein Konzept zur Nutzung von Bestärkendem Lernen im Kontext von LaiLa vorgestellt. Anschließend werden im Abschnitt IV Generative Modelle im industriellen Kontext erklärt, woran Abschnitt V über das Repräsentationslernen anschließt. Der Beitrag schließt mit einer Zusammenfassung und einem Ausblick ab.

II. MODELLFABRIK

Im folgenden Absatz wird das Konzept der Modellfabrik erläutert. Der Aufbau wurde basierend auf einem Demonstratorprodukt (s. Abb. 2), in annähernd an dessen Fertigungsprozess, konzeptioniert. Ein übergeordnetes Datensammelkonzept ermöglicht die Aufzeichnung hochqualitativer Datensätze für KI und ML Anwendungen in verschiedenen Domänen.

Da es sich beim Forschungsprojekt LaiLa um ein Laboratorium für Leichtbautechnik handelt, wurden die damit einhergehenden Produktionstechniken bei der Herstellung des Demonstratorprodukts berücksichtigt (s. ABBILDUNG 1). Das Demonstratorprodukt besteht aus einer konvexen, gepressten Thermoplastschale, auf der, wie im Flugzeugbau üblich, Versteifungsstreben befestigt sind. Um das gängige, jedoch aufwendige, Verfahren des Vernietens der Einzelteile abzulösen sind die Versteifungsstreben des Demonstratorprodukts mithilfe des Ultraschallschweißverfahrens gefügt. Es werden zwei unterschiedliche Versteifungsstrebenprofile verwendet, um eine umfangreiche Evaluierung der alternativen Fügemethode zu ermöglichen. Des Weiteren sind auf der Schale Halteschellen aufgebracht, welche additiv gefertigt wurden. Diese sind durch Klebeverbindungen gefügt und dienen als Aufnahme eines, mit vorimprägnierten Kohlefasern gewickelten, Wasserstofftanks. Die Herausforderung bei dieser Anordnung besteht in der Genauigkeit und Qualität, da die Aufnahme des Tanks durch Steckachsen erfolgen soll. Die Aufnahmetechnik durch Stäbe soll das Fügen von Aufhängungsstrukturen in Seitenleitwerken von Flugzeugen wiederspiegeln und die Validierungsplattform für einen automatisierten Klebeprozess darstellen.

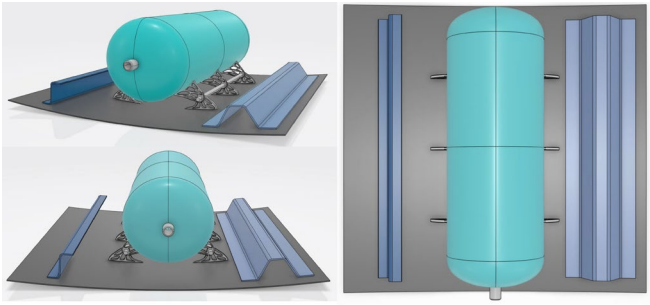

ABBILDUNG 1: DEMONSTRATORPRODUKT DER LAILA MODELLFABRIK. AUF EINER KONVEXEN THERMOPLASTSCHALE SIND VERSTEIFUNGSSTREBEN AUFGESCHWEIßT. GEKLEBTE HALTESCHELLEN NEHMEN EINEN, MIT KOHLEFASERN GEWICKELTEN, WASSERSTOFFTANK ÜBER EINE STECKACHSENVERBINDUNG AUF. [2]

Die einzelnen Fertigungstationen des Herstellungsprozesses wurden so gewählt, dass einzelne, zu erprobende Verfahren, auch losgelöst von einem seriellen Fertigungsfluss getestet und evaluiert werden können. Alle Fertigungstationen können mit einem Automated Guided Vehicle (AGV) entweder aus dem Materialeingang oder dem Lager beliefert werden. Im Materialeingang befindet sich neben einer Eingangsprüfstation eine NC-Schneidemaschine, die für den Zuschnitt von Kohlefasertextilen und anderen Halbzeugen verwendet werden kann. Halbzeuge können von dort entweder direkt an Fertigungsstationen geliefert oder in einem Lager zwischengelagert werden. Die erste Fertigungsstation befasst sich mit der automatischen Faserablage zur Herstellung von gewickelten Wasserstofftanks aus vorimprägnierten Kohlefasern mittels eines Roboters. In einer Laborpresse können die Thermoplastschalen, welche als Grundplatte des Demonstratorprodukts dienen, mit regulierbaren Temperaturen und Drücken umgeformt werden. Die Laborpresse ermöglicht weiterhin die Fertigung von Bauteilen im Resin Transfer Molding Verfahren, welches für zukünftige Produkte und Versuchsaufbauten weitere Verwendung findet. In einer Oberflächenbearbeitungsstation können Grate oder Unebenheiten entfernt, sowie Oberflächen für die Folgeverfahren vorbereitet werden. Eine Ultraschallschweiß- und Klebezelle ermöglicht das automatisierte Auftragen von Fügungspasten mit Robotern. Des Weiteren ist die Zelle mit einer Sonotrode zum robotergestützten Ultraschallschweißen ausgestattet. Eine optische Vermessungsstation ermöglicht eine quantitative Evaluation der eingesetzten Fertigungsverfahren.

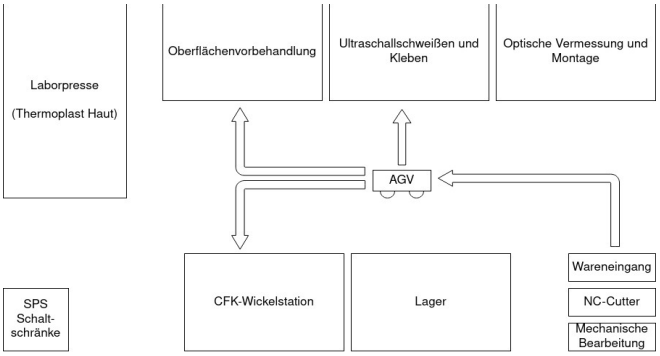

ABBILDUNG 2: KONZEPTIONELLE AUFTEILUNG DER LAILA MODELLFABRIK. DIE FERTIUNGSSCHRITTE SIND SEQUENTIELL IN EINER RINGFORM ANGEORDNET. ALLE STATIONEN LASSEN SICH MIT EINEM AUTOMATED GUIDED VEHICLE BELIEFERN. IN ANLEHNUNG AN [2]

Jede Station der LaiLa Modellfabrik wird mit einem Edge Device ausgestattet, das sowohl kontinuierliche, als auch diskrete Daten aus den vernetzten Anlagen aufzeichnet. Die Daten werden in einheitlichem Format in einem SCADA System abgelegt und für Forschungszwecke sowie intern zugänglich gemacht.

III. BESTÄRKENDES LERNEN

Bestärkendes Lernen oder auch Reinforcement Learning (RL) ist neben Supervised und Unsupervised Learning ein Teilgebiet von ML. Beim RL versucht ein sogenannter Agent durch numerische Belohnungen zu lernen und ein gesamtheitlich betrachtetes Problem zu lösen. Ziel ist es hierbei, die Gesamtheit der Belohnungen zu maximieren. Neben dem lernenden Agenten gehören eine Umgebung (environment), eine Strategie (policy), ein Belohnungssignal (reward) und eine Wertefunktion (value function) bzw. ein Modell der Umgebung [3] zur Idee des RL. Das bedeutet, dass RL Agenten explizite Ziele verfolgen, Aspekte der Umgebung wahrnehmen können und Aktionen wählen, die die Umgebung beeinflussen. Durch die Strategie wird festgelegt, wie sich der Agent zu einem bestimmten Zeitpunkt verhalten soll. Sie stellt somit ein Abbild der wahrgenommenen Zustände der Umgebung auf in diesen Zuständen ausführbare Aktionen dar. Mit dem Belohnungssignal wird das Ziel in einem RL-Problem beschrieben, da dieses langfristig maximiert werden muss. [3]

Im RL wird der sogenannte 'trial-and-error'-Ansatz verfolgt, welcher besagt, dass dem lernenden Agenten im Vorhinein nicht bekannt ist, welche Handlungen bzw. Aktionen zielführend sind. Vielmehr müssen diese durch Ausprobieren herausgefunden werden. Hierbei spielt die Verteilung zwischen Exploration, dem Ausprobieren, und Exploitation, dem Nutzen von Wissen, eine entscheidende Rolle. Der Agent muss, um eine optimale Lösung zu finden, eine Vielzahl von Aktionen ausprobieren, um nach und nach die Aktionen zu wählen, die die höchste Belohnung herbeiführen. Belohnungssignale sind unmittelbar, wohingegen Wertefunktionen langfristig einen Aufschluss darüber geben, welche Aktionen sinnvoll sind. Das

Umgebungsmodell dient dazu, Ruckschlüsse auf das Verhalten der Umgebung zuzulassen. [3]

A. . *Use Case Regelung und Anomalieerkennung im Ultraschallschweißen*

Das Projekt LaiLa fokussiert sich im Use Case 'Ultrasonic Welding' auf die Qualitätssicherung durch Digitalisierungsaspekte im automatisierten Ultraschallschweißprozess. Hierfür sollen Sensor- und Schweißdaten genutzt werden, um ein vollumfängliches Konzept zur Qualitätssicherung zu erstellen (s. ABBILDUNG 3). Die Speicherung der aufgenommenen Daten ist daher unumgänglich. Mithilfe eines Reinforcement Learning Ansatzes soll zukünftig der Schweißbahnprozess korrigiert sowie Anomalien erkannt werden. [4]

Derzeit besteht keine Möglichkeit, Prozessparameter während des Schweißprozesses, welcher nur einige Sekunden andauert, zu andern bzw. anzupassen. Aufgrund äußerer und innerer Einflüsse führt dies dazu, dass eine Abweichung der Schweißqualität entlang der Schweißnaht entstehen kann. Ebenso werden die derzeit aufgenommenen Prozessdaten auf einem lokalen Datenträger, mit begrenzter Aufzeichnungsrate, gepeichert und sind nicht global zuganglich. Mithilfe eines RL-Ansatzes soll zukünftig gelernt werden, wie Prozessparameter während des Prozesses geregelt werden können und Anomalien entgegengewirkt werden kann. [4]

Laut aktuellen Forschungsergebnissen, ist heute noch kein generalisierbarer RL-Ansatz für die Anomalieerkennung in Industrieunternehmen vorhanden. Je nach Problemschwerpunkt, werden unterschiedliche Verfahren eingesetzt. [5] Der Ansatz von Pang et al. ist beispielsweise sinnvoll, wenn man einen überwachten Anomalieerkennungsansatz mit wenigen gelabelten Daten trainieren möchte. Dieser stößt jedoch bei zu geringer Dimensionalität der Daten an seine Grenzen. [6] Sollten die Dimensionsräume der Daten zu groß sein, wird es notwendig, diesen auf das Notwendigste zu reduzieren, um entsprechende Merkmale, zur verbesserten Vorhersage, extrahieren zu können. Mit einem so genannten Differenzialgorithmus kann mit hochdimensionalen Merkmalsraumen¨ umgegangen werden und die Robustheit, auch bei nichtlinearen Beziehungen, bleibt bestehen. [7] [8] Weiterhin kann mit dem RL-Ansatz von Jomaa et al. die beste Konfiguration der Hyperparameter eines Prozesses gelernt werden, um eine Anomalieerkennung möglichst wenig einzuschränken. [9]

B. *Konzept*

RL stellt, aufgrund der Fähigkeit, komplexes Verhalten in hochdimensionalen Daten zu lernen [5], ein interessantes

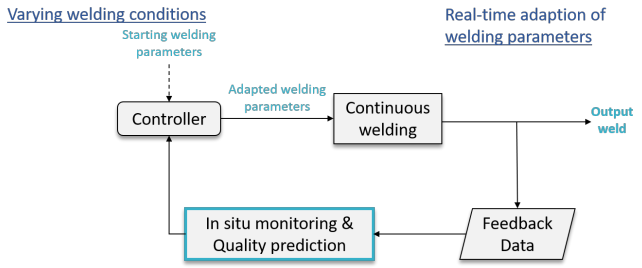

ABBILDUNG 3: SKIZZE DES ZUKÜNFTIGEN CLOSED-LOOP ULTRASCHALLSCHWEIßPROZESSES IN ANLEHNUNG AN [4].

Forschungsfeld dar, wenn die Regelung und Anomalieerkennung komplexer Industrieprozesse untersucht werden soll. Das verfolgte Konzept (s. ABBILDUNG 4) basiert auf zwei Teilbereichen, die aufeinander aufbauen. Zunächst wird mittels der aktuellen Sensordaten sowie Prozessparameter eine Regelung des Ultraschallschweißprozesses angestrebt. Mittels einer Simulation können potenzielle Algorithmen trainiert, validiert und getestet werden. Hierbei wird der Agent bei einem korrekten Regelschritt positiv belohnt. Andernfalls erhalt der Agent eine negative Belohnung. Die Bewertungsfunktion wird auf Grundlage der Toleranzwerte und Restriktionen erstellt. Die Validierung verschiedener RL-Ansätze gibt Aufschluss über die Nutzbarkeit der Algorithmen.

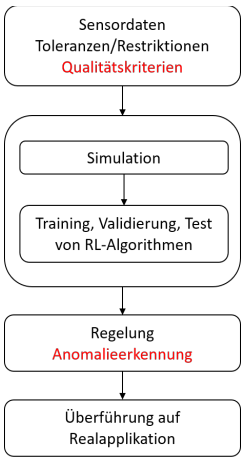

ABBILDUNG 4: KONZEPTSKIZZE DER REGELUNG MIT RL IM ULTRASCHALLSCHWEIßPROZESS UND DIE ERWEITERUNG ZUR ANOMALIEERKENNUNG (ROT.)

Weiterhin wird untersucht, inwiefern sich RL-Algorithmen für eine Anomalierkennung eignen. Neben den Toleranzwerten und Restriktionen, werden zusätzlich Qualitätskriterien für den Ultraschallschweißprozess berücksichtigt. Es muss daher sichergestellt werden, dass während des Prozesses die aufgenommenen Daten zügig verarbeitet und zurückgegeben werden, sodass eine Prozessanpassung erfolgen kann. Dies stellt lediglich eine der Herausforderungen dar. Ziel ist es, ein Assistenzsystem zu erstellen, welches auf Unregelmäßigkeiten reagieren und diesen bereits während des Prozesses entgegenwirken kann.

IV. GENERATIVE MODELLE FUR DIE ADDITIVE¨ FERTIGUNG

Ist ein bestehender Datensatz zu klein bzw. zu homogen, wirkt sich dies negativ auf das Ergebnis des ML aus. In solchen Fällen werden Generative Modelle genutzt, um die Merkmalsverteilung einzelner Klassen in Trainingsdatensätzen zu erlernen. Darauf basierend können anschließend neue, realitatsnahe Daten generiert und somit die Datenbasis, für das Trainieren von künstlichen neuronalen Netzen (KNN), vergrößert werden. Durch die Vergrößerung des Datensatzes können Homogenitäten kompensiert und Overfitting vermieden werden. Synthetische Bilddatenerweiterung wird aber auch verwendet, wenn bereits eine große Datenbasis besteht. In den meisten Fällen wird dadurch das Lernergebnis verbessert [10]. Dabei ist zu beachten, dass reale Daten besser für das Training sind, als Synthetische. Aktuell werden für die Datengeneration vorwiegend Generative Adversarial Network (GAN) und

Variational Autoencoder (VAE) genutzt, wobei laut [11] mit dem GAN qualitativ bessere Ergebnisse erreicht werden.

A. Use Case Fehlererkennung im 3D-Druck

Die Bauteilqualität stellt eine immer wichtigere Anforderung dar. Aufgrund der langen Herstellungszeit, welche mit den komplexen Strukturen des verwendeten Materials sowie des additiven Prozesses zu tun hat, ist das frühzeitige Detektieren und Klassifizieren von Herstellungsfehlern essenziell. Dies ist im Sinne der Kosten- und Ressourceneinsparung sowie der effizienten Nutzung von Maschinen von höchster Relevanz. Aus diesen Gründen wird im Rahmen dieses Use Cases eine Methode zur zuverlässigen, datengestützten Fehlerdetektion entwickelt. Ziel ist es, den Bauprozess visuell zu überwachen und Defekte zu erkennen, zu klassifizieren und Korrelationen mit den Prozessparametern herzustellen.

B. Konzept

Für die Detektion von Fehlern in komplexen Bildern sind neuronale Netze besonders geeignet, da sie Klassifikationsraten von über 95% erreichen. Jedoch werden für das Training dieser Netze umfangreiche Datensätze benötigt. Da ein entsprechender Datensatz für diese Anwendung noch nicht zur Verfügung steht, wird eine Methode erarbeitet, mit der ein solcher generiert werden kann.

Im Fokus steht hier das Generative Adversarial Network (GAN). Dieses Artefakt soll sowohl für den Anwendungsfall, als auch für weitere artverwandte Anwendungsfälle nutzbar sein. Voraussetzung für das Training des GAN ist eine Menge x realer Bilder, die während des Druckprozesses von Bauteilen im Bauraum aufgenommen werden. Dazu wird ein Kamerasystem, ein 3D-Drucker sowie die gerätespezifischen Informationen (z.B. Große des Bauraums, Ausrichtung der Kamera in Relation zum Bauraum) benötigt. Außerdem sollen 3D-Modelle von Druckbauteilen, als weitere Informationsquelle, genutzt werden. Die Deep Convolution-Architektur eignet sich besonders zur Verarbeitung von Bilddaten. Die Conditional-Architektur ist notwendig, um nach abgeschlossenem Training, gezielt Bilder einer bestimmten Klasse zu generieren. Der Multiconditional-Ansatz ist ebenfalls erforderlich, da die Eingabe aus mehreren Komponenten besteht. Mit dem StyleGAN können Teilbereiche des Bildes mit Fehlermerkmalen versehen werden.

Ist das GAN trainiert, kann ein Datensatz erzeugt werden, der abhängig von der Vorgabe neuer 3D-Modelle, entsprechende synthetische aber realistische Bilder dieses Bauteils im Bauraum beinhaltet. Auch soll die Möglichkeit bestehen, den Blickwinkel auf alte bzw. bekannte Bauteile, die Szenerie des genutzten 3D-Druckers sowie das Einbringen von Defekten zu variieren. Mit diesem individualisierten Datensatz kann anschließend ein klassifizierendes neuronales Netz (z.B. ein CNN) trainiert werden, um die im laufenden Druckprozess aufgenommenen Bilder auf Fehler zu inspizieren und eine Klassifikation vorzunehmen.

V. Repräsentationslernen für die Planung von Produktionsprozessen

Repräsentationslernen ist eine Domäne aus dem Bereich ML. Das Repräsentationslernen beschäftigt sich mit dem Erlernen möglichst informationsreicher und eindeutiger Repräsentationen von Daten. [12] Diese ermöglichen eine verbesserte Leistungsfähigkeit von existierenden Algorithmen sowie Netzwerken. Insbesondere zum Transferlernen, also der Fähigkeit eines Lernalgorithmus Ähnlichkeiten zwischen verschiedenen Lernaufgaben auszunutzen, um seine statistische Aussagekraft zu starken, sind informationsreiche Datenrepräsentationen hilfreich. So kann der Raum ähnlicher Features aufgeweitet werden. [12].

Neben dem klassischen Repräsentationslernen, also dem Lernen von Datenrepräsentationen, lassen sich auch Repräsentationen mathematischer Zusammenhänge aus Daten erlernen und in neuronalen Netzen encodieren. Hierbei werden, durch sich wiederholendes Training, komplexe Gleichungssysteme vom latenten Raum neuronaler Netze nachgebildet. Durch das Lernen aus Beobachtungen und Messungen, ermöglicht sich so beispielsweise das Nachbilden physikalischer Materialmodelle, welche als Eingabe des neuronalen Netzes dienen.

A. Use Case Planung in der Modellfabrik und im Ultraschallschweißen

Die Planung von Produktionsprozessen stellt eine Kernkompetenz für produzierende Unternehmen dar [13]. Während symbolische Planungsverfahren, wie auf semantischen Beschreibungen basierende Suchverfahren, logische Agenten oder Grammatiken schon einen Korpus an Literatur aufweisen können, sind subsymbolische Planungsverfahren noch wenig erforscht. [14], [15] Subsymbolische Planungsverfahren stutzen sich insbesondere auf numerische Daten, die keine Semantik oder Symbolik enthalten.

Im Projekt LaiLa werden in zwei Use Cases subsymbolische Planungsverfahren erforscht. Der Use Case Ultraschallschweißen beschäftigt sich mit dem automatisierten Ultraschallschweißen von Thermoplasten. Die Schweißdaten des Ultraschallprozesses können dazu verwendet werden, eine Repräsentation der physikalischen Prozesse im Material während des Schweißprozesses zu erlernen. Daraus können Ruckschlüsse auf neue Materialpaarungen gezogen werden. So kann bei der Planung von neuen Produkten mit variierenden Materialeigenschaften und -geometrien auf kostspielige Experimente, zur Ermittlung der Schweißparameter, verzichtet werden.

Im größeren Kontext lassen sich so in der LaiLa Modellfabrik für jeden Produktionsschritt Repräsentationen in neuronalen Netzen erlernen, welche eine Vorhersage von Eingabedaten, Ausgabedaten und Parametrisierung ermöglichen.

B. Konzept

Das Erlernen von Repräsentationen von Prozessschritten basiert auf der Annahme, dass es sich bei Produktionsprozessen um Funktionen handelt, welche eine Eingabe unter dem Einfluss von Umgebungsvariablen in eine Ausgabe transformieren (s. Abbildung 5) [16]. Jeder Prozessschritt stellt hierbei ein eigenständiges Differenzialgleichungssystem dar und wird von einem eigenen neuronalen Netz erlernt. Anhand dieser Netzwerke können Vorhersagen über Ein- und Ausgaben, sowie die Prozessschrittparametrisierung getroffen werden.

In einem weiteren Schritt werden die einzeln angelernten Netzwerke zu einem Graphen zusammengefasst. Basierend auf dieser Struktur lassen sich Pfade durch den Graphen erzeugen, die basierend auf Ein- und Ausgangsdaten, eine Abfolge von Produktionsschritten mit entsprechender Parametrisierung, einen Plan, erzeugen.

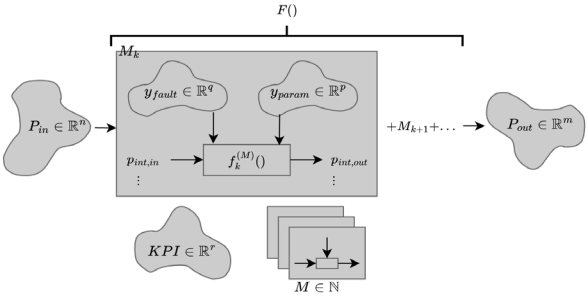

ABBILDUNG 5: FORMALISIERUNG EINES PRODUKTIONSPROZESSES INNERHALB EINES PRODUKTIONSSYSTEMS. DER PRODUKTIONSPROZESS $F()$ BESTEHT AUS k PROZESSSCHRITTEN $f^M()$ UND TRANSFORMIERT EINGABEN p_{in} IN AUSGABEN p_{out} UNTER BERÜCKSICHTIGUNG VON UMGEBUNGS-, PARAMETRISIERUNGS-, UND FEHLERVARIABLEN y_{fault} UND y_{param} [16].

Das vorgeschlagene Konzept kann mithilfe der Daten aus dem Use Case Ultraschallschweißen und der Modellfabrik validiert werden. Generalisierungen auf andere Produktionssysteme, auch aus der Verfahrenstechnik, sind möglich.

VI. ZUSAMMENFASSUNG

Zusammenfassend kann festgehalten werden, dass die im Projekt LaiLa verfolgte Umsetzung der Modellfabrik, welche einen Herstellungsprozess eines Wasserstofftanks abbildet, einen erheblichen Einfluss auf die Datengenerierung und -verarbeitung hat. Die dort erzeugten Daten sind realitäts- sowie industrienah und bieten die Möglichkeit unterschiedlichste Verfahren zu erforschen, zu validieren und zu evaluieren.

Hierunter fallen ebenso verschiedene Ansätze aus KI und ML. Mit der Überarbeitung der Infrastruktur auf Systemebene sollen Daten für alle internen Mitarbeiter zugänglich und nutzbar sein. So kann die Forschung in Bezug auf die Digitalisierung stetig vorangetrieben werden.

Derzeit werden Themen aus den Bereichen RL, Generative Modelle sowie Repräsentationslernen erforscht, welche zukünftig in unterschiedlichen industriellen Anwendungen implementiert werden können. Da der konstruierte Wasserstofftank viele verschiedene Herstellungsprozesse abbildet, bietet sich die Modellfabrik auch für Anwendungen in den Bereichen Fertigungstechnik und Automatisierung an.

VII. AUSBLICK

Zukünftig werden die oben vorgestellten Konzepte vertieft und auf Detailebene dokumentiert. Die Umsetzung der einzelnen Bausteine wird zunächst auf Grundlage von Simulationen stattfinden, bis sie an Realsystemen validiert und getestet werden können. Weiterhin wird nach Anwendungsfeldern für die Forschung gesucht, welche ebenso mit der Infrastruktur der Modellfabrik angegangen werden können.

DANKSAGUNG

Die Autoren bedanken sich für die Förderung bei dtec.bw – Zentrum für Digitalisierungs- und Technologieforschung der Bundeswehr [Projekt LaiLa]

LITERATUR

[1] N. Widulle, J. Ehrhardt, M. Krantz, A. Liebert, A. Nordhausen, and O. Niggemann, *Eine Simulationsumgebung für flexible Cyber-Physische Produktionssysteme zur Generierung realistischer Datensätze für maschinelle Lernverfahren*, ser. Automation 2022: Automation creates Sustainability. Dusseldorf: VDI Verlag, 24.08.2022 2022, pp. 439–452. [Online]. Available: https://doi.org/10.51202/9783181023990-533

[2] C. Hildebrandt, T. Reincke, A. Fay, O. Niggemann, and M. Fette, "Wissenstransfer für die intelligente fabrik," *maschinenbau*, 2022.

[3] R. S. Sutton and A. G. Barto, *Reinforcement Learning: An Introduction*. Cambridge, MA, USA: A Bradford Book, 2018.

[4] Laboratorium Fertigungstechnik, Helmut-Schmidt-Universität LaFT Universität der Bundeswehr, "Laila - labor für intelligente leichtbau-produktion," 06.

[5] P. Michalski, "Anomaly detection in the context of reinforcement learning," 08 2021.

[6] G. Pang, A. Hengel, C. Shen, and L. Cao, "Deep reinforcement learning for unknown anomaly detection," 09 2020.

[7] R. Sali, S. Adewole, and A. Akakpo, "Feature selection using reinforcement learning," 01 2021.

[8] S. M. Hazrati Fard, A. Hamzeh, and S. Hashemi, "Using reinforcement learning to find an optimal set of features," *Computers Mathematics with Applications*, vol. 66, pp. 1892–1904, 12 2013.

[9] H. Jomaa, J. Grabocka, and L. Schmidt-Thieme, "Hyp-rl: Hyperparameter optimization by reinforcement learning," 06 2019.

[10] S. C. Wong, A. Gatt, V. Stamatescu, and M. D. McDonnell, "Understanding data augmentation for classification: When to warp?" in *2016 International Conference on Digital Image Computing: Techniques and Applications (DICTA)*. IEEE, nov 2016.

[11] I. J. Goodfellow, "Nips tutorial generative adversarial networks," *CoRR*, vol. abs/1701.00160, 2017. [Online]. Available: http://arxiv.org/abs/1701.00160

[12] Y. Bengio, A. Courville, and P. Vincent, "Representation learning: A review and new perspectives," *IEEE transactions on pattern analysis and machine intelligence*, vol. 35, no. 8, pp. 1798–1828, 2013.

[13] D. Kiran, *Production planning and control: A comprehensive approach*. Butterworth-heinemann, 2019.

[14] A. Kocher, R. Heesch, N. Widulle, A. Nordhausen, J. Putzke, A. Wind-¨ mann, and O. Niggemann, "A Research Agenda for AI Planning in the Field of Flexible Production Systems," in *IEEE International Conference on Industrial Cyber-Physical Systems (ICPS)*, 2022.

[15] R. Heesch, N. Widulle, A. Kocher, A. Nordhausen, L. M. Vieira da Silva,¨ J. Putzke, and O. Niggemann, *Methoden der künstlichen Intelligenz für die automatisierte Planung von modularen Produktionsprozessen*, ser. Automation 2022: Automation creates Sustainability. Düsseldorf: VDI Verlag, 24.08.2022 2022, pp. 439–452. [Online]. Available: https://doi.org/10.51202/9783181023990-439

[16] J. Ehrhardt, M. Ramonat, R. Heesch, K. Balzereit, A. Diedrich, and O. Niggemann, "An ai benchmark for diagnosis, reconfiguration planning," in *2022 27th IEEE International Conference on Emerging Technologies and Factory Automation (ETFA2022)*, 2022.