

Konzepte zur Integration additiver Fertigungsprozesse mittels Graph Neural Networks

Additive Prozesse in der virtuellen Inbetriebnahme

A. Kienzlen, M. Nistler, A. Verl, O. Riedel

ZUSAMMENFASSUNG Die virtuelle Inbetriebnahme ist für den simulationsbasierten Test von Produktionssystemen etabliert. Klassisch werden logische, kinematische und Materialflussmodelle verwendet. Bei der Übertragung auf additive Prozesse mit neuen Kollisionsgefahren ist eine geometrisch genaue, recheneffiziente Modellierung herausfordernd. Der Beitrag diskutiert als Konzept Graph Neural Networks nach *Sanchez-Gonzalez et al.* [1] als partikelbasierter, gelernter Simulator. Voruntersuchungen zeigen die Machbarkeit.

STICHWÖRTER

Additive Fertigung, Simulation, virtuelle Inbetriebnahme

Additive processes in virtual commissioning

ABSTRACT Virtual commissioning has been established as a method for simulation-based testing of production systems. Typically used are logical, kinematic, and material flow models. The transfer to additive processes with new collision risks poses a challenge in regard to geometrically accurate, computationally efficient modelling. The article discusses graph neural networks, as proposed by *Sanchez-Gonzalez et al.* [1], as a particle-based, trained simulator. Preliminary studies demonstrate the feasibility of this approach.

1 Einleitung

Die additive Fertigung eröffnet neue Gestaltungsmöglichkeiten für komplexe Bauteile und nimmt daher an Bedeutung für die Produktionstechnik zu. Konventionelle Fertigungsverfahren wie abtragende oder umformende Verfahren stoßen an Grenzen, wenn aufwendige Geometrien zur Optimierung der Bauteileigenschaften benötigt werden oder zusätzliche Funktionalitäten wie Sensoren direkt in die Bauteile integriert werden sollen. Vor allem die Möglichkeit, Materialeigenschaften wie die Dichte lokal zu variieren, eröffnet neue Optimierungspotenziale für Leichtbau und Funktionalisierung. Durch die Kombination verschiedener Materialien in einem Fertigungsschritt entstehen zudem monolithische Strukturen mit weniger Schnittstellen und verbesserter Zuverlässigkeit. Auch erlaubt die additive Fertigung eine bedarfsgerechte und ressourcenschonende Produktion, was im Kontext nachhaltiger Entwicklung an Bedeutung gewinnt. Zudem können die Entwicklungszyklen teilweise verkürzt und die Leistungsfähigkeit der Produktionssysteme erhöht werden.

Die additive Fertigung ist ein zunehmend wichtiger Bestandteil moderner Produktionssysteme, jedoch keine isolierte Technologie. Eine erfolgreiche Integration erfordert die Betrachtung im Kontext des gesamten Produktionssystems, wodurch die Produktionsplanung und -steuerung neu durchgeführt werden muss. Die Verfahren der additiven Fertigung erlauben eine bedarfsgerechte Produktion von Kleinserien oder individualisierten Produkten, was eine flexible Anpassung der Produktionsprozesse erfordert. Hybride Fertigungskonzepte, bei denen die additive Fertigung mit konventionellen Verfahren kombiniert wird, bieten zusätzliche Potenziale zur Optimierung der Bauteilperformance und Redukti-

on der Fertigungskosten. Beispielsweise können hochbeanspruchte Bereiche eines Bauteils additiv gefertigt und anschließend durch spanende Bearbeitung veredelt werden. Um die gesamten Abläufe zu testen und die Effizienz zu optimieren, müssen die Vorgänge der additiven Fertigung gemeinsam mit der restlichen Produktion analysiert werden.

Die virtuelle Inbetriebnahme (VIBN) ist eine etablierte Methode zur Analyse der Produktionsabläufe, sowie zur Fehlerdetektion und -verbesserung [2]. Die Idee der VIBN ist die Durchführung eines Steuerungstests anhand einer Simulation, wobei nicht nur die Steuerung, sondern auch weitere Aspekte wie Ablauffehler, Konstruktionsfehler, Fehler in der Elektrik oder Prozessfehler getestet werden können. Dies wird möglich, da zum Zeitpunkt der VIBN erstmals im Entwicklungsprozess die verschiedenen Disziplinen in den Gesamtablauf integriert werden. Der Umfang der VIBN ist abhängig von der Testkonfiguration und von den verwendeten Modellen. Klassisch werden insbesondere logische und kinematische Modelle eingesetzt.

Die additive Fertigung wird aufgrund aufwendiger Modelle bisher nicht in der VIBN betrachtet. Somit werden Fehler im Zusammenspiel zwischen dem gesamten Produktionsablauf und den additiven Fertigungsprozessen in der Regel erst bei der realen Inbetriebnahme entdeckt, was die Behebung aufwendig und teuer machen kann. Dies könnte durch frühere, virtuelle Tests des Gesamtsystems verbessert werden.

Ein Lösungsansatz ist die Verwendung von datenbasierten Ersatzmodellen anstelle der klassischen, rechenaufwendigen Modelle für die VIBN. Hier sind gelernte Modelle vielversprechend, welche das Verhalten basierend auf den Ein- und Ausgangsdaten trainieren [3]. Vor allem Graph Neural Networks (GNNs) sind

für den Anwendungszweck aussichtsreich, da sich das Material als Graphen abbilden lässt [4], mit denen direkt gerechnet wird. Physikalische Wechselwirkungen werden lokal im Graphen berücksichtigt, während zugleich globale Systemeffekte abgebildet werden. GNNs wurden speziell für die Verarbeitung von Daten in graphbasierten Strukturen entwickelt. Jedes Graphenelement (Knoten) sammelt über die Verbindungen (Kanten) zwischen den Elementen Informationen von seinen benachbarten Elementen. Diese Informationen werden kombiniert und mit einer Updatefunktion aktualisiert [5]. So ermöglichen GNNs direkt die Modellierung von Beziehungen und Interaktionen über die Kanten im Gegensatz zu regelmäßigen Matrixstrukturen, wie Bildern, oder sequenziellen Daten, wie Vektoren. Darüber hinaus sind die Graphen auf unterschiedliche Größen skalierbar [1], was die Generalisierbarkeit des Ansatzes erhöht.

In dieser Arbeit soll ein Grobkonzept vorgestellt werden, um die additive Fertigung mittels gelernter Modelle, speziell mit GNNs, zu approximieren. Dies soll es ermöglichen, das relevante Verhalten additiver Prozesse in die VIBN zu integrieren, indem existierende Modelle mit einem additiven Modell kombiniert werden. Ein exemplarisches Szenario, bei dem ein Roboter als kinematisches Modell mit einem Schweißauftrag als additivem Modell gekoppelt werden könnte, ist in **Bild 1** dargestellt.

Im Folgenden wird zunächst der Stand der Forschung und Technik zur Modellierung und zu Methoden des maschinellen Lernens für die VIBN sowie für die Simulation von additiven Prozessen dargelegt (Kapitel 2). Davon werden die Anforderungen an Simulationsmodelle für die VIBN zur Integration additiver Fertigung abgeleitet und darauf basierend ein Konzept mit GNNs samt vier Varianten entworfen, erste Voruntersuchungen zeigen die prinzipielle Machbarkeit (Kapitel 3). Abschließend werden die Erkenntnisse zusammengefasst und nächste Schritte vorgeschlagen (Kapitel 4).

2 Stand der Forschung und Technik

Im Folgenden wird der aktuelle Stand der Forschung und Technik zu verschiedenen Modellen dargelegt: Modelle in der virtuellen Inbetriebnahme als Ausgangssituation, Modelle mit GNNs als neuer Ansatz und Simulation additiver Fertigung als Anwendungsfall und Abgrenzung.

2.1 Modelle in der virtuellen Inbetriebnahme

Die Simulationsmodelle für die VIBN setzen sich in der Regel aus verschiedenen Teilmodellen zusammen [6]. Für die Auswahl der Modelle müssen Modelltiefe, -breite und -umfang festgelegt werden [7]. Es werden logische, kinematische und physikalische Modelle eingesetzt, außerdem werden Sensoren und Aktoren, die Kommunikation und der Materialfluss abgebildet [8]. Ein weiterer Aspekt, der im Folgenden nicht weiter betrachtet wird, ist die Visualisierung. Diese dient der Interaktion mit dem Bediener, der Veranschaulichung von Vorgängen und Fehlern und ist stark von der verwendeten Software abhängig. Ursprünglich lag der Fokus der VIBN neben Sensoren, Aktoren und Kommunikation auf dem Ablauf, der Kinematik und der Dynamik von Achsen und Maschinen [9]. Dies ist darin begründet, dass zunächst einzelne Maschinen und deren Interaktion mit der Steuerung betrachtet wurden (Modellumfang) und der Schwerpunkt die Analyse von Abläufen und Kollisionen war (Modellbreite). Zudem war die Detaillierung




Bild 1 Idee der additiven Fertigung in der virtuellen Inbetriebnahme (VIBN) anhand eines Schweißroboters. Grafik: ISW, Universität Stuttgart

(Modelltiefe) durch die Rechenleistung begrenzt. Vor allem im Bereich physikalischer Modelle gab es seitdem viele Neuerungen und eine große Bandbreite an Modellen. Diese können neben der Dynamik auch verschiedene Prozesse und Effekte integrieren wie den Materialabtrag.

Damit Modelle in der VIBN eingesetzt werden können, müssen sie mehrere Anforderungen erfüllen [2, 10]:

- **Schnittstellen:** Die Modelle müssen mit der Steuerung interagieren, daher müssen sie auf die Signale der Steuerung reagieren (Aktorsignale) und die gleichen Signale für die Steuerung bereitstellen wie das reale Produktionssystem (Sensorsignale).
- **Rechenzeit:** Die Steuerung gibt die Geschwindigkeit in Form des Steuerungstakts vor und die Simulation muss entsprechend schnell genug berechenbar sein. Diese Anforderung kann nicht alleine durch die Modellkomplexität erfüllt werden, sondern wird auch durch die verwendeten Simulationsintegratoren und durch die Rechnerhardware beeinflusst.
- **Genauigkeit:** Die durchzuführenden Tests und Analysen bestimmen die benötigte Genauigkeit beziehungsweise den Detailgrad der Modelle.
- **Robustheit:** Die Anforderung der Robustheit beschreibt, dass die Modelle in jedem Schritt „gültige“ Ergebnisse bereitstellen [10] oder dass die Modelle numerisch stabil gelöst werden [9]. Die Literatur zeigt, dass Modelle für die VIBN hohe Anforderungen erfüllen müssen, daher werden viele Prozesse bisher nicht berücksichtigt.

2.2 Modelle mit Graph Neural Networks

Je komplexer, detaillierter oder umfangreicher und damit rechenaufwendiger die Prozesse sind, die in die VIBN integriert werden sollen, desto herausfordernder wird es, die Anforderung der Rechenzeit zu erfüllen. Bei umfangreichen Modellen ist es möglich, der Herausforderung mit Co-Simulationsansätzen zu begegnen und das Modell auf verschiedene Solver zu verteilen [7]. Für komplexe oder detaillierte Modelle sind andere Ansätze nötig.

Wenn neue Prozesse hinzugefügt werden sollen, dann muss genau analysiert werden, welche Informationen benötigt werden. Häufig liefern konventionelle Modelle mehr Details als für die VIBN relevant sind. In diesem Fall ist ein Ansatzpunkt die Entwicklung von Ersatzmodellen. Für den Aufbau datengetriebener




Bild 2 Funktionsweise des Encoders mit beispielhaftem Knoten n_i , Kante e_i und globalem Attribut u . Grafik: ISW, Universität Stuttgart angelehnt an [1]

Ersatzmodelle kommen in anderen Disziplinen inzwischen häufig Verfahren des maschinellen Lernens (ML) zum Einsatz. Auch im Bereich der VIBN existieren dazu erste Untersuchungen für den Materialfluss und für Verformungen [3, 11]. Als recheneffizienter und zugleich genauer Ansatz wurden dabei GNNs identifiziert, mit denen Objekte und deren Interaktionen gelernt werden können und die bereits für Vorwärtsdynamiken angewendet werden [1].

Die Idee bei GNNs besteht darin, dass ein neuronales Netz auf Graphen, bestehend aus Knoten, Kanten und Attributen, statt auf Vektoren gelernt wird [5]. In der Architektur von *Sanchez-Gonzalez et al.* [1], die darauf ausgelegt ist, allgemein physikalisches Verhalten zu lernen, wird zunächst aus den Daten ein Graph kodiert (Encoder, **Bild 2**), aus diesem ein nächster Schritt gelernt (Prozessor), und dieser wieder dekodiert (Decoder).

Partikel in einem Szenario werden als Knoten angenommen, die als Attribute eine Position und eine Geschwindigkeit haben. Es können unterschiedliche Partikel kombiniert werden, indem die Knoten ein zusätzliches Attribut für den Knotentyp bekommen. Als globale Attribute können allgemeine Eigenschaften wie Gravitationskraft angegeben werden. Die Kanten stellen die Beziehungen zwischen den Partikeln dar, wovon in jedem Schritt andere bestehen können. Diese werden vom Encoder basierend auf der Entfernung der Knoten voneinander bestimmt. Wenn die Distanz zwischen zwei Knoten den Konnektivitätsradius unterschreitet, werden die Knoten mit Kanten verknüpft. Die Aggregation und Aktualisierung der Informationen im Prozessor werden als Message-Passing bezeichnet. Damit wird die Geschwindigkeit der Knoten im nächsten Schritt vorhergesagt. In iterativen Simulatoren wird das GNN rekursiv angewendet, wodurch sich Fehler akkumulieren können. Dem kann durch das Einbringen von Trainingsrauschen oder durch Long-Horizon-Training anstelle einzelner Schritte entgegengewirkt werden.

Es existieren verschiedene Weiterentwicklungen von GNNs hin zu Recurrent GNNs [12] und Dynamic GNNs [13, 14]. Bei Recurrent GNNs wird der Message-Passing-Schritt durch zeitliche Informationen ergänzt, die auf historischen Daten arbeiten. Diese Architektur eignet sich gut, um sequentielle Prozesse abzubilden, jedoch steigt die Modellkomplexität und der Rechenaufwand. Dynamic GNNs modellieren zeitlich veränderliche Graphen, bei denen Knoten- und Kantenanzahl variieren kann. Auch diese bilden einen zeitlichen Prozess ab, jedoch mit anderem Fokus. Die Anforderungen an Modellierung und Training sind noch höher. Zusätzlich existieren generative Graphmodelle, die neue Graphen erzeugen. Im Bereich der gelernten Simulatoren für

physikalisches Verhalten liegt der Fokus aktuell auf klassischen GNNs.

2.3 Simulation additiver Fertigung

Nach DIN EN ISO 17296-2 [15] lassen sich Prozesse der additiven Fertigung in die Kategorien Photopolymerisation im Bad, Werkstoffauftrag, Bindemittelauftrag, pulverbasiertes Schmelzen, Werkstoffextrusion, gerichtete Energieeinbringung und Schichtlaminiierung aufteilen. Während bei Photopolymerisation im Bad, Bindemittelauftrag und pulverbasiertem Schmelzen ein Anteil des vorhandenen Werkstoffes weiterverarbeitet wird, wird beim Werkstoffauftrag, der Werkstoffextrusion, gerichteter Energieeinbringung und Schichtlaminiierung nur der benötigte Werkstoff aufgebracht. **Bild 3** zeigt die Einteilung in bettbasierte Verfahren, bei denen vorhandener Werkstoff im Bett weiterverarbeitet wird, und in Materialauftrag. Je nach Prozess und Geometrie können Stützkonstruktionen notwendig sein, diese werden hier nicht berücksichtigt.

Es existieren verschiedene konventionelle Modelle, um additive Fertigungsprozesse zu simulieren [16, 17]. Auch in kommerziellen Finite-Elemente- oder CFD (Computational Fluid Dynamics)-Tools wie „Abaqus“ oder „Ansys“ sind Funktionen integriert, die zur Simulation additiver Fertigung gedacht sind [18, 19]. In den Simulationen werden Funktionen aus der Mechanik, der Thermik und der Fluidik kombiniert. Damit ist es möglich, den Fertigungsprozess sehr detailliert darzustellen. Oft liegt der Fokus auf strukturellen mechanischen Analysen und für Metalle auf der Betrachtung des Schmelzbads. Damit ist es auch möglich, die resultierenden Geometrien zu bestimmen. Allerdings sind diese Simulationen in der Regel sehr zeitaufwendig.

Im Bereich der additiven Fertigung wird daher auch aktiv an der Verwendung von ML geforscht. Dabei kann zwischen den Einsatzzwecken Entwurf der Bauteile, Prozess- oder Bauteiloptimierung, Qualitätskontrolle und Ansätze zur Prozesssteuerung beziehungsweise Verbesserung des Einsatzes im Kontext von Industrie 4.0 [20, 21] unterschieden werden. Im Folgenden werden einige Beispiele dafür aufgezeigt:

- Um den Entwurf von Bauteilen zu unterstützen, werden häufig featurebasierte Ansätze gewählt, teilweise in Kombination mit Modellen, die Bauteileigenschaften vorhersagen können. Es existieren auch Ansätze, bei denen die dreidimensionale Geometrie additiv gefertigter Bauteile betrachtet wird. Beispielsweise untersuchen *Chen et al.* [22] den Verzug beim Sintern mit einem graphbasierten Ansatz. Dabei wird für jeden Zeit-




Bild 3 Einteilung additiver Fertigungsverfahren. Grafik: ISW, Universität Stuttgart

schritt zunächst eine Voxelisierung ausgeführt und aus dieser Knoten für den Graphen abgeleitet. Als globale Attribute werden zusätzlich eine Sinterkurve und Umgebungseigenschaften mitgegeben. Kassab *et al.* [23] verfolgen ein ähnliches Ziel, wobei sie die Massenerhaltung als physikalische Randbedingung in ein rekurrentes neuronales Netz integrieren.

- Für die Prozessoptimierung können die Ergebnisse in Bezug auf verschiedene Kriterien vorhergesagt werden. Häufig liegt dabei der Fokus auf der Temperatur [24]. Dafür wird unter anderem ein Recurrent GNN eingesetzt, das besonders Zeitverläufe berücksichtigt [24].
- Für die Qualitätskontrolle werden vor allem die Temperatur und mögliche Fehler basierend auf Kamerabildern analysiert. So kann für einen Laserprozess der Schmelzpool vorhergesagt werden. Dabei ist es sogar möglich, die unterschiedlichen Temperaturphasen der Naht zu berücksichtigen [25].
- Eine Prozess- und Bauteiloptimierung entspricht meist einer Adaption von Prozessparametern, oft mit dem Ziel der Optimierung der Prozessparameter unter festgelegten Rahmenbedingungen. Beispielsweise kann die Breite und Höhe einer Schweißnaht als Parameter von der Geschwindigkeit des Werkzeugmittelpunkt (Tool Center Point, TCP), dem Winkel des Werkzeugs, der Vorschubgeschwindigkeit des Drahts und dem Abstand zwischen TCP und Werkstück bestimmt werden [26]. Auch die Tiefe der Schweißnaht kann zusätzlich mit guten Ergebnissen präzisiert werden [27]. Es werden aber nur Parameter für den Gesamtprozess bestimmt und keine dreidimensionale Geometrie simuliert.

Insgesamt liegt der Fokus von gelernten Modellen für die additive Fertigung meist auf einzelnen Parametern. Als dreidimensionale Untersuchungen werden Abweichungen von vorhandenen Planungen oder Daten analysiert, aber keine Generierung der kompletten entstehenden Geometrie. Genau diese Lücke adressiert diese Arbeit für Verfahren mit Materialauftrag.

3 Integration der additiven Fertigung in die virtuelle Inbetriebnahme

Um Modelle für die Integration der additiven Fertigung in die VIBN zu entwerfen, müssen zunächst die Randbedingungen des Anwendungsfalls und die Anforderungen festgelegt werden.

Basierend auf den Anforderungen wird im Folgenden ein Grobkonzept mit vier Ansätzen zur Modellierung des Graphen vorgeschlagen und analysiert. Zum Abschluss wird die Umsetzbarkeit anhand erster Untersuchungen gezeigt.

3.1 Anforderungen an die Modelle

Für die VIBN sind insbesondere die Verfahren interessant, die auf dem Prinzip des Materialauftrags basieren. Dies führt zu neuen Kollisionsrisiken, die im Zusammenspiel mit anderen Abläufen berücksichtigt werden müssen. Im Gegensatz dazu sind Verfahren, die auf der Verbindung von bereits vorhandenem Material basieren, wie pulverbasiertes Schweißen, bewusst nicht Gegenstand dieser Untersuchung. Auch die Schichtlaminierung wird nicht betrachtet, da das Verfahren aufgrund der notwendigen Fixierung und Begrenzung des Arbeitsraums durch Rohwerkstoff und Überschuss meist nicht für andere Prozesse zugänglich ist. Zusätzlich soll auf Verfahren mit kontinuierlicher Werkstoffzuführung eingeschränkt werden, was den Werkstoffauftrag, oft Material Jetting genannt, ausschließt. Folglich verbleiben die Werkstoffextrusion, wie Fused Deposition Modeling, und die gerichtete Energieeinbringung, beispielsweise Wire Arc Additive Manufacturing (WAAM).

Für die VIBN im Kontext der Gesamtproduktion ist vor allem die entstehende Geometrie relevant, da diese für die Kollisionsdetektion mitberücksichtigt werden sollte. Materialdefekte und Bauteiloptimierungen können meistens separat analysiert werden. Damit Kollisionen im Kontext der Produktionsabläufe betrachtet werden können, muss der Aufbau der Werkstückgeometrie dreidimensional über der Zeit abgebildet werden. Zum Beispiel ermöglicht robotergestütztes WAAM eine hohe Gestaltungsfreiheit; es kann jedoch eine Herausforderung sein, sicherzustellen, dass der Roboterarm nicht mit dem neu entstehenden Werkstück kollidiert. Dies könnte in der VIBN abgesichert werden.

Neben der dreidimensionalen Geometrie des Werkstücks muss auch die Geometrie der Umgebung in der Modellierung für den additiven Fertigungsverfahren mitberücksichtigt werden. Die entstehende Geometrie ist vom Untergrund abhängig, der nicht immer eine Ebene ist. Je nach Verfahren kann, nachdem eine erste Schicht aufgebracht wurde, diese für die nächste Schicht zur Umgebung umgewandelt werden. Diese Vereinfachung ist nur zulässig, falls die zweite Schicht des Materialauftrags die Geometrie der ersten Schicht nicht wesentlich verändert.

Zudem müssen Modelle die Anforderungen für VIBN-Modelle erfüllen, die im Stand der Forschung und Technik beschrieben wurden. Das bedeutet, die Modelle benötigen Schnittstellen zur Steuerung, müssen schnell genug berechenbar, genau genug und robust sein.

3.2 Modellierungsansätze bezogen auf die Geometriesimulation für die additive Fertigung

Die gegensätzlichen Anforderungen von Genauigkeit und geringer Rechenzeit stellen eine Herausforderung für die Modellierung in der VIBN dar. Dies spricht gegen die Verwendung konventioneller Modelle und motivierte die Anwendung von gelernten Modellen. Da GNNs bereits erfolgreich zur Simulation physikalischen Verhaltens eingesetzt werden und mit der Architektur von Sanchez-Gonzalez *et al.* [1] ein verallgemeinerter Simulator vorhanden ist, soll dieser Ansatz weiterverfolgt werden.

Die Weiterentwicklungen der GNNs vernachlässigen teilweise die Nachbarschaftsbeziehungen, die der physikalischen Interaktion entsprechen (Attention-based GNNs) oder stellen zeitliche Abhängigkeiten her (Recurrent GNNs), die bei einer reinen Betrachtung ohne Geometrie nicht benötigt werden. Die folgenden Schritte hängen nur von wenigen vorherigen Schritten ab, die in der Architektur von Sanchez-Gonzalez als Knoteninformation mitgegeben werden, und nicht von einer längeren Sequenz. Die größere Modellkomplexität und der größere Rechenaufwand bieten tendenziell wenig große Vorteile. Zur Anpassung der Architektur auf die Anwendung der additiven Fertigung werden die folgenden Punkte vorgeschlagen:

- Die Knoten des Materials und die Knoten der Starrkörper in der Umgebung bekommen verschiedene Knotentypen, so dass die Positionen der Starrkörper vorgegeben und die Positionen des Materials über ihre Geschwindigkeit gelernt werden können. Der Untergrund wird sich dabei häufig nicht verändern, es wäre jedoch möglich, dessen Positionen manuell anzupassen.
- Je nachdem mit welchem Tool die Daten für Training und Validierung generiert werden, liegen die Geometrien bereits als Point Cloud oder noch als Netze beziehungsweise Volumenmodelle vor. Daraus müssen in der Datenvorverarbeitung Positionen für die Knoten generiert werden. Möglicherweise wird außerdem ein Downsampling benötigt, um die Anzahl der Partikel zu verringern.
- Als allgemeines Attribut kann je nach Fertigungsverfahren beispielsweise die Zuführgeschwindigkeit des Materials angegeben werden.
- Wenn die Trainingsdaten nicht mit einer Simulation generiert werden, die auf Partikeln basiert, sondern die Partikel beispielsweise aus Netzen für jeden Zeitschritt generiert werden, ist es herausfordernd, Trajektorien je Partikel zu erstellen. Stattdessen kann für die Verlustfunktion die Wasserstein-Metrik [28] verwendet werden, die den minimalen Unterschied zwischen zwei Verteilungen bestimmt, um das Material in den Ground-Truth-Daten mit dem prädictierten Material zu vergleichen.
- Die TCP-Position und Geschwindigkeit werden als Eingang gegeben, um die Interaktion mit der Steuerung zu ermöglichen. In die Gegenrichtung findet keine direkte Kommunikation statt.

Ein Vorteil der Architektur mit GNNs ist, dass diese auf unterschiedlich große Graphen generalisierbar ist. Bei den bisherigen Anforderungen als gelernter Simulator bleiben die Graphen jedoch in einem Simulationsschritt gleich groß. Das bedeutet, dass eine Herausforderung zur Abbildung mit GNNs die Akkumulation des Materials zum Aufbau des Werkstücks ist, die sich nicht nur durch eine reine Verschiebung der Knoten abbilden lässt.

Hier sollen vier Ansätze vorgestellt werden (Bild 4), wie die Akkumulation des Materials abgebildet werden könnte.

3.2.1 Materialakkumulation als wachsender Graph

Der direkteste Ansatz die zunehmende Menge an Material abzubilden, wäre die Vergrößerung des Graphens. Der gelernte Simulator müsste in einem Simulationsschritt dann nicht nur die Parameter der Knoten verändern, sondern auch neue Knoten mit neuen Parametern und neuen Kanten hinzufügen (Bild 4a). Es existieren Ansätze mit generativen Graphmodellen in anderem Kontext wie der Chemie, bei denen Graphen komplett neu generiert werden [29, 30]. Diese werden aber meist nicht basierend auf äußeren Begebenheiten entworfen, sondern generieren verschiedene mögliche Graphen als Geometrievorschläge in der Konstruktion oder als mögliche Molekülstrukturen. Dabei werden häufig Autoencoder eingesetzt. Darauf basierend wurden auch Ansätze entworfen, bei denen Graphen über die Zeit aufgebaut werden [31]. Auch hier liegt der Fokus allerdings nicht auf dem Prozess, sondern auf den entstehenden Strukturen. Dynamic GNNs ermöglichen große Veränderungen der Graphenstruktur, sind jedoch weniger für die lokal begrenzte Erweiterung wie hier benötigt gedacht [32]. Im Kontext gelernter Simulatoren sind den Autoren keine GNN-Architekturen bekannt, in denen bei Graphen die Anzahl der Knoten ausgehend von den Umgebungsbedingungen kontinuierlich verändert wird. Entsprechend müsste für diesen Ansatz eine neue ML-Architektur entworfen werden.

3.2.2 Materialakkumulation als Änderung des Knotentyps

Wenn keine dynamisch wachsenden Graphen entworfen werden sollen, könnte ein neuer Knotentyp eingeführt werden, der die freie Umgebung abbildet. Wenn Material hinzugefügt wird, müsste das GNN lernen, dass sich der Knotentyp entsprechend ändert. In Bild 4b ist dies mit dem Wechsel vom Knotentyp Umgebung zum Knotentyp Material dargestellt. Dies entspricht nicht mehr einem klassischen GNN-Ansatz, sondern beinhaltet bereits Elemente eines Dynamic GNNs, allerdings in sehr kleinem Maßstab, daher könnte eine Kombination beider Ansätze entwickelt werden. In diesem Fall wären von Beginn an alle Knoten indiziert, anfangs als freie Umgebung und als Starrkörper. Je nach Szene führt dies zu einer großen Menge an Knoten, die in jedem Schritt simuliert werden müssten. Jeweils zwischen den Partikeln der freien Umgebung und den Partikeln der Starrkörper müssten keine Kanten aufgebaut werden und deren Positionen müssten nicht automatisch angepasst werden, um den Rechenaufwand zu verringern. Trotzdem müsste mit sehr großen Graphen gerechnet werden, was die Rechenzeit und die benötigte Speicherkapazität negativ beeinflusst. Bisher werden die Knotentypen statisch vorgegeben und verändern sich nicht, das heißt der gelernte Wechsel der Knotentypen müsste neu in die ML-Architektur integriert werden.

3.2.3 Materialakkumulation als kontinuierliche Materialzuführung

Wenn die Funktionsweise des gelernten Simulators nah am realen Prozess sein soll, könnte bereits das Material in der Zuführung indiziert werden. Die Knoten in Bild 4c bewegen sich an die passende Position. Auch hier verändert sich die Anzahl der




Bild 4 Konzepte zur Materialakkumulation: a) Wachsender Graph, b) Änderung des Knotentyps, c) kontinuierliche Materialzuführung, d) separate Geometrien. Grafik: ISW, Universität Stuttgart

Knoten über die Zeit nicht. Die Positionen der Knoten, die noch nicht verarbeitet wurden, müssen von außen vorgegeben werden. Bei diesem Ansatz kann die Position des TCPs nicht nur in den globalen Attributen vorgegeben werden, sondern das unverarbeitete Material muss entsprechend äußerer Vorgaben bewegt werden. Das unverarbeitete Material könnte dabei entweder realitätsnah entlang einer Linie angeordnet werden oder gesammelt in einem festen Bereich. Dementsprechend müssen die Daten für Training und Validierung angepasst oder erweitert werden. Eine

weitere Herausforderung ist, dass der Simulator speziell das Verhalten des verarbeiteten Materials lernen muss. Dies könnte ähnlich wie bei den Starrkörpern realisiert werden, dass die prädiagnostizierten Positionen des unverarbeiteten Materials nicht weiterverarbeitet werden und auch nicht in der Verlustfunktion berücksichtigt werden. Um dies zu ermöglichen, muss bekannt sein, welche Knoten zum unverarbeiteten Material gehören, möglicherweise indem der TCP als räumliche Grenze verwendet wird.

Tabelle Vergleich der Ansätze zur Materialakkumulation.

	Wachsender Graph	Änderung des Knotentyps	Kontinuierliche Materialzuführung	Separate Geometrien
ML-Darstellung für Material	Wachsender Graph	Zusätzlicher Knotentyp	Verarbeitetes Material und Material in der Zuführung	Bewegung basierend auf vorhandenen Ansätzen
Veränderung der Simulator-Architektur	Neu, Graphenaufbau lernen	Anpassung mit Lernen des Knotentyps	Große Ähnlichkeit	Große Ähnlichkeit
Integration in die VIBN	Gut möglich	Gut möglich, da ein Knotentyp ignoriert werden kann	Unterscheidung zwischen verarbeitetem Material und Material in der Zuführung notwendig	Aufwendig, da vergangene Zeitschritte separat betrachtet werden müssen
Größe der Graphen	Durch Rechenleistung beschränkt	Zu Beginn durch Anzahl der gesamten Knoten definiert → durch Rechenleistung beschränkt	Zu Beginn durch Anzahl der Knoten im Material definiert → durch Rechenleistung beschränkt	Unbeschränkt, insgesamt am kleinsten

3.2.4 Materialakkumulation als separate Geometrien je Zeitschritt

Der letzte Ansatz beruht auf der Idee, dass jeweils nur das verarbeitete Material aus einem Zeitschritt gelernt wird [33]. Der Simulator lernt, wie sich das Material für den jeweils neuesten Schritt vorwärtsbewegt, während das Material aus dem vorherigen Schritt zu Starrkörper wird. In Bild 4d werden die Knoten des Typs Material zu Knoten des Typs Starrkörper und neue Knoten des Typs Material werden ergänzt. Der Starrkörper wächst, allerdings nicht innerhalb eines Simulationsschritts, sondern in der Initialisierung des nächsten Zeitschritts. Die Daten müssen entsprechend aufbereitet werden, sodass die Differenzen zwischen den Zeitschritten bekannt sind. Der Ansatz geht implizit davon aus, dass sich die Geometrie des bereits verarbeiteten Materials nicht mehr verändert.

3.2.5 Analyse der Ansätze zur Materialakkumulation

Jeder der vier Ansätze hat unterschiedliche Vor- und Nachteile, ein Überblick ist in der **Tabelle** dargestellt.

Die Architektur des Simulators kann bei der kontinuierlichen Materialzuführung und bei der Verwendung von separaten Geometrien je Zeitschritt in großen Teilen übernommen werden, was den Aufwand verringert und zugleich eine hohe Stabilität erwarten lässt. Dafür ist vor allem beim letzteren Ansatz die Integration in die VIBN aufwendig, da Simulationsschritte nicht einzeln betrachtet werden können, sondern Informationen aus den vorherigen Schritten notwendig sind, um die additiv gefertigte Geometrie komplett abzubilden.

Auch bei der kontinuierlichen Materialzuführung ist eine Nachverarbeitung nötig, da zwischen dem bereits verarbeiteten Material und dem Material, das noch zugeführt wird, unterschieden werden muss. Letzteres wird in der VIBN nicht dargestellt beziehungsweise nicht analog zur Darstellung in diesem ML-Ansatz. Da die gelernten Simulatoren insbesondere aufgrund des Rechenaufwands eingesetzt werden sollen, ist dieser eine wichtige Anforderung. Abgesehen von der Gesamtarchitektur ist die Größe der verarbeiteten Graphen ein wichtiger Einflussfaktor auf den Rechenaufwand eines GNNs. Bei wachsenden Graphen nimmt der Rechenaufwand zu und ist nicht mehr konstant. Sowohl bei der Verwendung von drei Knotentypen als auch bei der kontinu-

ierlichen Materialzuführung werden alle Knoten zu Beginn initialisiert. Dies ist vor allem durch den Rechenaufwand beschränkt und begrenzt so die mögliche Größe der resultierenden Geometrie. Darüber hinaus ist es nachteilig, dass bei größeren Graphen mehr Trainingsdaten und -zeit benötigt werden. Die kleinsten Graphen entstehen bei der Verwendung von separaten Geometrien je Zeitschritt.

3.3 Erste Voruntersuchungen

Zur Überprüfung der Ansätze wurden erste Untersuchungen mit den separaten Geometrien je Zeitschritt durchgeführt [33], da hier auf der vorhandenen GNN-Architektur von *Sanchez-Gonzalez et al.* aufgebaut werden kann. Zudem werden die kleinsten Graphen benötigt, was sowohl für die Rechenzeit als auch für den Trainingsaufwand vorteilhaft ist. Zur Erzeugung von Trainings- und Validierungsdaten wurde „ModuleWorks“ [34] genutzt und einfache Schweißnähte entsprechend eines WAAM-Prozesses simuliert. Es wurden kürzere Rechenzeiten (ungefähr konstant bei circa 0,23 s/Zeitschritt im Vergleich zu kontinuierlich wachsend von 0,5 s/Zeitschritt) erzielt, wobei die Geometrien jedoch von den Ground-Truth-Daten abweichen (Wasserstein-Metrik der gesamten Punktwolke zwischen 20 und 35 mm). **Bild 5** zeigt beispielhaft die Ergebnisse für eine Schweißnaht mit einer Länge von 5 cm, die mit einer variierenden Werkzeuggeschwindigkeit zwischen 360 und 400 mm/min in einem Winkel von 10° aufgebracht wurde.

Trainiert wurde mit einem Datensatz von circa 2300 Zeitschritten (je 100 ms) mit Zufallsrauschen im Maßstab $0,4 \cdot 10^{-4}$ und 8000 Partikeln (downgesampelt aus Punktwolken) für 40 Epochen. In Encoder, Prozessor und Decoder wurden je ein Multi-Layer-Perceptron mit 2 Hidden-Layern mit je 64 Neuronen eingesetzt und in der Verlustfunktion ein Adam Optimizer basierend auf der Architektur in [1].

3.4 Fazit

Die Ergebnisse der ersten Voruntersuchungen zeigen, dass das Grundprinzip des Auftragsschweißens mit GNNs simuliert werden kann und dabei deutlich kürzere Rechenzeiten als in ModuleWorks erzielt werden können. Allerdings werden nicht die genau-




Bild 5 Simulierte Schweißnaht mit separaten Geometrien je Zeitschritt, links: Ground Truth, rechts: Prädiktion mit Graph Neural Network (GNN). Grafik: ISW, Universität Stuttgart

en Geometrien der Ground-Truth-Daten in den einzelnen Zeitschritten erreicht.

Eine Herausforderung des GNN-Ansatzes ist die Notwendigkeit von Datensätzen für das Training, deren Größe und die Variabilität der Daten. Dafür wird neben der Erstellung der Daten eine Vorverarbeitung nötig, beispielsweise mittels Downsampling. Die größte Herausforderung ist die Abbildung der Akkumulation des Materials. Um damit umzugehen, wurden vier Ideen vorgestellt, die unterschiedliche Vor- und Nachteile haben. Je nach Ansatz ist teils eine Nachverarbeitung der Ergebnisse notwendig, bevor diese in der VIBN verwendet werden können, teils ist die Integration in die VIBN aufwendig, teils entsteht mit wachsender Materialmenge ein zunehmender Rechenaufwand.

Wenn ein gelerntes GNN-Modell ein bestimmtes Szenario abbilden kann, ist damit nicht direkt gegeben, dass auch andere Szenario abgebildet werden können. Die Verallgemeinerbarkeit der Modelle muss separat betrachtet, in den Trainingsdaten berücksichtigt, trainiert und eventuell in der Architektur angepasst werden.

4 Zusammenfassung und Ausblick auf zukünftige Forschung

Mit der additiven Fertigung nimmt die Bedeutung eines flexiblen Verfahrens in der Produktionstechnik zu, das große Potenziale hinsichtlich Individualisierung und Ressourceneffizienz

bietet. Die Integration additiver Verfahren in industrielle Produktionssysteme erfordert umfassende Tests und Analysen im Kontext der Gesamtproduktion. Vor allem muss bei der Inbetriebnahme eine kontinuierliche Kollisionsüberwachung mit dem schichtweise entstehenden Bauteil berücksichtigt werden. Dafür hat sich die Methode der virtuellen Inbetriebnahme etabliert, bei der additive Fertigungsprozesse bisher kaum simuliert werden. Konventionelle Modelle sind dafür aufgrund ihres hohen Rechenaufwands und des abweichenden Fokus nicht geeignet. Stattdessen bieten datengetriebene Ersatzmodelle, die Verfahren des ML nutzen, eine erfolgversprechende Alternative. Besonders GNNs haben sich als vielversprechende Simulatoren für physikalisches Verhalten erwiesen.

In dieser Arbeit wurde ein Konzept entworfen, wie die Geometrien von additive Fertigungsverfahren mit Materialauftrag mithilfe von GNNs prädiziert werden könnten. Dabei wurden unterschiedliche Varianten zur Berücksichtigung der zunehmenden Materialmenge während des Fertigungsprozesses vorgestellt. Die Voruntersuchung legt nahe, dass dieser Ansatz die Approximation von Prozessen wie WAAM in der virtuellen Inbetriebnahme mit hoher Präzision und Rechengeschwindigkeit ermöglicht.

Aufbauend auf dem vorgestellten Konzept und der Voruntersuchung sollen künftig umfangreichere Untersuchungen mit mehr Daten und Parametervariationen durchgeführt werden. Dazu soll auf der einen Seite eine größere Datenbasis mit Szenarienvariationen erstellt werden, bei denen in einem weiteren Schritt auch

größere Szenen mit Schichtauftrag untersucht werden. Auf der anderen Seite sollen die Parameter im Trainingsprozess in einer Hyperparameterstudie systematisch analysiert werden, wobei auch die Fehlerakkumulation und die Rollout-Stabilität berücksichtigt werden sollten.

Die vier vorgestellten Ansätze zur Modellierung der Materialakkumulation sollen weiterverfolgt und ausführlich miteinander verglichen werden. Insbesondere die Stabilität der verschiedenen Ansätze ist ein wichtiger Aspekt. Des Weiteren kann untersucht werden, ob ein Long-Horizon-Training oder zusätzliche physikalische Einschränkungen in der Verlustfunktion die Stabilität erhöhen. Wenn ein geeignetes Modell erzielt wurde, soll dieses in den Prozess der virtuellen Inbetriebnahme integriert und im Zusammenspiel mit Produktionssystemen simuliert werden.

FÖRDERHINWEIS

Diese Arbeit wurde gefördert vom Landesministerium für Wissenschaft, Forschung und Kunst Baden-Württemberg im Rahmen der Nachhaltigkeitsförderung der Projekte der Exzellenzinitiative II.

DANKSAGUNG

Die Autoren danken Marius Baur für die Vorarbeiten und Diskussionen.

Literatur

- [1] Sanchez-Gonzalez, A.; Godwin, J.; Pfaff, T. et al.: Learning to Simulate Complex Physics with Graph Networks. Proceedings of the 37th International Conference on Machine Learning, (2020), <https://doi.org/10.48550/arXiv.2002.09405>
- [2] VDI Verein Deutscher Ingenieure: VDI/VDE 3693 – Blatt 1. Virtuelle Inbetriebnahme – Modellarten und Glossar. Beuth 2025
- [3] Jaensch, F.; Herburger, K.; Bobe, E. et al.: Complex Physics with Graph Networks for Industrial Material Flow Simulation. Procedia CIRP 118 (2023), pp. 50–55
- [4] Zhang, H.; Zhao, Z.; Zhang, X. et al.: MAM-PhyGNN: A Physics-Hardcoded Graph Neural Network for Fast and Accurate Thermal Simulation in Metal Additive Manufacturing. Additive Manufacturing 122 (2026), #105208, doi.org/10.1016/j.addma.2026.105208
- [5] Scarselli, F.; Gori, M.; Tsoi, A. C. et al.: The graph neural network model. IEEE Transactions on Neural Networks 20 (2009) 1, pp. 61–80
- [6] Puntel Schmidt, P.: Methoden zur simulationsbasierten Absicherung von Steuerungscode fertigungstechnischer Anlagen. Dissertation, Helmut Schmidt Universität Universität der Bundeswehr Hamburg, 2017
- [7] Scheifele, C.: Plattform zur Echtzeit-Co-Simulation für die virtuelle Inbetriebnahme. Dissertation, Universität Stuttgart, 2019
- [8] VDMA Forum Industrie 4.0: Leitfaden Virtuelle Inbetriebnahme – Handlungsempfehlungen zum wirtschaftlichen Einstieg. Internet: vdma.eu/c/document_library/get_file?uuid=66118d8d-68fc-55-a7-a25b-a90ffe89f1f2&groupId=34570 2020. Zugriff am 23.06.2026
- [9] Röck, S.: Echtzeitsimulation von Produktionsanlagen mit realen Steuerungselementen. Dissertation, Universität Stuttgart, 2007
- [10] Hoher, S.: Ein gekoppeltes Materialflussmodell zur durchgängigen Entwicklungsunterstützung von Materialflussteuerungen. Stuttgarter Beiträge zur Produktionsforschung. Dissertation, Universität Stuttgart, 2017
- [11] Klare, S.; Shramenko, V.; Klingel, L. et al.: Towards Automotive Manufacturing Efficiency: Enhanced Virtual Commissioning Simulation for Dynamic Sheet Metal Handling Optimization. Stuttgart Conference on Automotive Production, 2025, pp. 68–75
- [12] Ioannidis, V. N.; Marques, A. G.; Giannakis, G. B.: A Recurrent Graph Neural Network for Multi-relational Data. ICASSP 2019 – 2019 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP), Brighton, United Kingdom, 2019, pp. 8157–8161
- [13] Rakshit Trivedi; Mehrdad Farajtabar; Prasenjeet Biswal et al.: Dyrep: Learning Representations over Dynamic Graphs. International Conference on Learning Representations (ICLR) (2019), doi.org/10.48550/arXiv.1803.04051
- [14] Zheng, Y.; Yi, L.; Wei, Z.: A survey of dynamic graph neural networks. Frontiers of Computer Science 19 (2025) 6, article number 196323
- [15] DIN EN ISO 17296-2: Additive Fertigung – Grundlagen – Teil 2: Überblick über Prozesskategorien und Ausgangswerkstoffe. Deutsche Fassung, Ausgabe 2016–12
- [16] Chen, Z.; Yuan, L.; Pan, Z. et al.: A comprehensive review and future perspectives of simulation approaches in wire arc additive manufacturing (WAAM). International Journal of Extreme Manufacturing 7 (2025) 2, pp. 2679–2708
- [17] Comminal, R.; Serdeczny, M. P.; Pedersen, D. B. et al.: Numerical modeling of the strand deposition flow in extrusion-based additive manufacturing. Additive Manufacturing 20 (2018), pp. 68–76
- [18] Brenken, B.; Barocio, E.; Favalloro, A. et al.: Development and validation of extrusion deposition additive manufacturing process simulations. Additive Manufacturing 25 (2019), pp. 218–226
- [19] Mayer, T.; Brändle, G.; Schönenberger, A. et al.: Simulation and validation of residual deformations in additive manufacturing of metal parts. Heliyon 6 (2020) 5, e03987
- [20] Goh, G. D.; Sing, S. L.; Yeong, W. Y.: A review on machine learning in 3D printing: applications, potential, and challenges. Artificial Intelligence Review 54 (2021) 1, pp. 63–94
- [21] Saimon, A. I.; Yangu, E.; Yue, X. et al.: Advancing additive manufacturing through deep learning: A comprehensive review of current progress and future challenges. IISE Transactions 58 (2026) 1, pp. 33–56
- [22] Chen, R.; Gan, C.; Lee, J. et al.: Virtual Foundry Graphnet for Predicting Metal Sintering Deformation. Sensors and Materials 36 (2024) 7, pp. 2835–2849
- [23] Kassab, A.; Chelbi, M.; Shirzad, S. et al.: Physics-informed hybrid deep learning-driven sintering simulation for next-generation metal additive manufacturing. Additive Manufacturing 114 (2025), Article: 105028, doi.org/10.1016/j.addma.2025.105028
- [24] M. Mozaffar; S. Liao; H. Lin et al.: Geometry-agnostic data-driven thermal modeling of additive manufacturing processes using graph neural networks. Additive Manufacturing 48 (2021), Article: 102449, <https://doi.org/10.1016/j.addma.2021.102449>
- [25] Zhu, Q.; Liu, Z.; Yan, J.: Machine learning for metal additive manufacturing: predicting temperature and melt pool fluid dynamics using physics-informed neural networks. Computational Mechanics 67 (2021) 2, pp. 619–635
- [26] Chandra, M.; Vimal, K. E. K.; Rajak, S.: A comparative study of machine learning algorithms in the prediction of bead geometry in wire-arc additive manufacturing. International Journal on Interactive Design and Manufacturing (IJDeM) 18 (2024) 9, pp. 6625–6638
- [27] Venkata Rao, K.; Parimi, S.; Suvarna Raju, L. et al.: Modelling and optimization of weld bead geometry in robotic gas metal arc-based additive manufacturing using machine learning, finite-element modelling and graph theory and matrix approach. Soft Computing 26 (2022) 7, pp. 3385–3399
- [28] Frogner, C.; Zhang, C.; Mobahi, H. et al.: Learning with a Wasserstein loss. 29th International Conference on Neural Information Processing Systems. Cambridge, MA, USA, 2015, pp. 2053–2061
- [29] Grover, A.; Zweig, A.; Ermon, S.: Graphite: Iterative Generative Modeling of Graphs. Proceedings of the 36th International Conference on Machine Learning. PMLR 97 (2019), pp. 2434–2444

- [30] You, J.; Ying, R.; Ren, X. et al.: GraphRNN: Generating Realistic Graphs with Deep Auto-regressive Models. Proceedings of the 35th International Conference on Machine Learning, PMLR 80, (2018) pp. 5708–5717
- [31] Liao, R.; Li, Y.; Song, Y. et al.: Efficient graph generation with graph recurrent attention networks. Proceedings of the 33rd International Conference on Neural Information Processing Systems, Vancouver, Canada. Red Hook, NY, USA, 2019, pp. 4255–4265
- [32] Kazemi, S. M.: Dynamic Graph Neural Networks. In: Wu, L.; Cui, P.; Pei, J. et al. (eds.): Graph Neural Networks: Foundations, Frontiers, and Applications. Singapore: Springer Singapore 2022, pp. 323–349
- [33] Baur, M.: Entwicklung eines Frameworks für einen erlernbaren Simulator auf Basis von Graph Neural Networks für Auftragsschweißen. Forschungsarbeit, Universität Stuttgart, 2024
- [34] ModuleWorks GmbH: Wire Arc Additive Manufacturing (WAAM). Stand: 2026. Internet: www.moduleworks.com/software-components/toolpath/additive/wire-arc-additive-manufacturing/. Zugriff am 23.06.2026

Dr.-Ing. Annika Kienzlen 
annika.kienzlen@gsame.uni-stuttgart.de

GSaME Graduate School of Excellence advanced
 Manufacturing Engineering, Universität Stuttgart
 Nobelstr. 12, 70569 Stuttgart
www.gsame.uni-stuttgart.de

Maximilian Nistler, M.Sc. 

Prof. Oliver Riedel 

Prof. Alexander Verl 

Institut für Steuerungstechnik der Werkzeugmaschinen
 und Fertigungseinrichtungen (ISW)
 Universität Stuttgart
 Seidenstr. 36, 70174 Stuttgart
www.isw.uni-stuttgart.de

LIZENZ



Dieser Fachaufsatz steht unter der Lizenz Creative Commons
 Namensnennung 4.0 International (CC BY 4.0)