

Progress Report KIKA-IPK (ProLern) und ProKI: KI Assistenzsysteme zur Inprozesskontrolle bei WAAM und DoD Prozessen

T. Westphal und J. Krüger, IWF, TU Berlin

Abstract

Within the framework of the projects, KIKA-IPK and ProKI Berlin, that are funded by the Bundesministerium für Bildung und Forschung, significant advances have been achieved in integrating artificial intelligence into manufacturing processes. These projects aimed to enhance the performance and functionality of production machinery by leveraging AI technologies. In the KIKA-IPK project, AI-assisted systems were developed for real-time process control in different manufacturing scenarios, including Wire Arc Additive Manufacturing (WAAM) and Drop on Demand (DoD) for personalized medication production. ProKI Berlin focused on raising awareness and supporting small and medium-sized enterprises in adopting AI solutions across various production processes, while focusing on the milling process. The projects yielded innovative methods that not only demonstrate considerable economic and scientific potential but also contribute to building digital competencies. Moreover, the integration of these practical applications into the curriculum at TU Berlin has fostered a seamless transfer of knowledge between research, industry, and education. These outcomes lay the groundwork for further research, development, and industrial implementation of AI-based methods in manufacturing.

Keywords: KI, Fertigung, Inprozesskontrolle

1 Einleitung

Das *Bundesministerium für Bildung und Forschung (BMBF)* fördert mit dem Programm „Innovationen für die Produktion, Dienstleistung und Arbeit von morgen“ kooperative, vorwettbewerbliche Forschungsvorhaben zur Stärkung des verarbeitenden Gewerbes in Deutschland. Das Programm adressiert dabei die Entwicklung neuer Technologien, Dienstleistungen und Arbeitsmodelle, um Wertschöpfung und Arbeitsplätze in Deutschland zu erhalten und auszubauen. [1]

Im Rahmen dieses Programms soll durch die Fördermaßnahme „Lernende Produktionstechnik – Einsatz Künstlicher Intelligenz (KI) in der Produktion (ProLern)“ die Leistungsfähigkeit und Funktionalität von Maschinen und Ausrüstungen der Fertigungstechnik durch den verstärkten Einsatz von KI erhöht werden. [2]

Das Programm „Zukunft der Wertschöpfung – Forschung zu Produktion, Dienstleistung und Arbeit“ des *BMBF* fördert Forschungsprojekte, die neue Konzepte, Produkte und Verfahren entwickeln, um nachhaltige und zukunftsfähige Produkte, hochwertige Produktion, kundennahe Dienstleistungen und qualitativ hochwertige Arbeit zu sichern. [3]

Das Demonstrations- und Transfernetzwerk KI in der Produktion (*ProKI-Netz*) ist Teil dieses übergeordneten Programms und fördert Projekte mit dem Ziel, das umfangreiche Potenzial der KI im Produktionseinsatz sichtbar zu machen und zu erschließen. [4]

1.1 ProLern: KIKA-IPK

Mit der Fördermaßnahme *ProLern* werden insgesamt 14 Projekte gefördert, die eine Vielzahl von Produktionsverfahren betrachten. Dazu zählen: Laserauftragsschweißen, -bearbeitung, -schneiden, Lackieren, Fügen, Trennen, Umformen und Zerspanen. [5], [6]

Forschungsschwerpunkte liegen insbesondere bei KI-Anwendungen, maschinellem Lernen (engl. Machine Learning, ML), Deep-Learning (DL), erklärbarer KI, Assistenzsystemen, Sensorik, Daten, Anomalieerkennung, vorausschauender Wartung, Integration von Expertenwissen und Mitarbeiterpartizipation. Die Forschungs- und Entwicklungsergebnisse sollen unter anderem zur Überwachung, Optimierung, Verbesserung, Effizienzsteigerung und Qualitätssicherung von Produktionsprozessen, zur Lebensdauersteigerung und Ausfallreduzierung von Maschinen und zur Steigerung der Effektivität sowie der Akzeptanz und des Vertrauens in den Einsatz von KI beitragen. [6]

Das Projekt „KI-kognitionsunterstützendes Assistenzsystem zur Inprozesskontrolle in der Fertigung“ (*KIKA-IPK*) zielt darauf ab, die Vorteile menschlicher und künstlicher Intelligenz in der additiven Fertigung zu kombinieren, um Werkerinnen und Werker bei der Qualitätskontrolle und Prozesssteuerung zu unterstützen. Dafür werden Bild-, Prozess- und Sensordatenströme in Echtzeit analysiert. Die Entwicklungen werden an zwei Szenarien getestet: dem Druck von großvolumigen metallischen Bauteilen, im Lichtbogenauftragschweißen (engl. Wire Arc Additive Manufacturing, WAAM) der Firma *GEFERTEC GmbH* und der personalisierten Medikamentenherstellung, bei der Wirkstofftropfen auf Anforderung (engl. Drop on Demand, DoD) auf Dünnfilm (engl. Oral Dispersible Film) im Drucker der Firma *DiHeSys Digital Health Systems GmbH* mit berührungsloser Nanoliter-Dispensierung der Firma *Hamilton Freiburg GmbH* aufgetragen werden. Die Demonstratoren werden, wie im unteren Teil von Abbildung 1 auch als KI-Maschinen bezeichnet. [7]

Durch die Erweiterung ihrer Industrie 4.0-Plattform um eine KI-Cloud-Framework-Komponente, zur standardisierten Integration und Verwaltung von KI-Diensten Dritter, mit intuitiver Benutzeroberfläche zur Unterstützung von Produktionsmitarbeitern, wird von der *PSI Metals GmbH* die Basis für die Bereitstellung externer KI-Dienstleistungen geschaffen. Die *Gestalt Robotics GmbH* entwickelt im Projekt KI-gestützte Automatisierungsdienste im Bereich des additiven Auftragsschweißens durch Optimierung von Bildverarbeitungssystemen, während die *Relimetrics GmbH* *KIKA-IPK* durch optische Inspektionssysteme für das DoD-Verfahren mit KI-Dienst zur Tropfencharakterisierung unterstützt. Das Fachgebiet *Industrielle Automatisierungstechnik (IAT)* am *Institut für Werkzeugmaschinen und Fabrikbetrieb* der *Fakultät V - Verkehrs- und Maschinensysteme* der *Technischen Universität Berlin (TUB)* trägt durch die Erforschung neuer maschineller Lernverfahren zur Extraktion von Prozesseigenschaften und optischer Qualitätsmerkmale und die Zustandserkennung und Qualitätsbewertung von Fertigungsprozessen zum Projekt bei und nutzt die Ergebnisse zur Weiterentwicklung der Lehre auf Basis praxisnaher Anwendungsfälle von KI. In Abbildung 1 ist die Verbindung der KI-Entwickler mit den KI-Maschinen über die KI-Cloud dargestellt. [8]

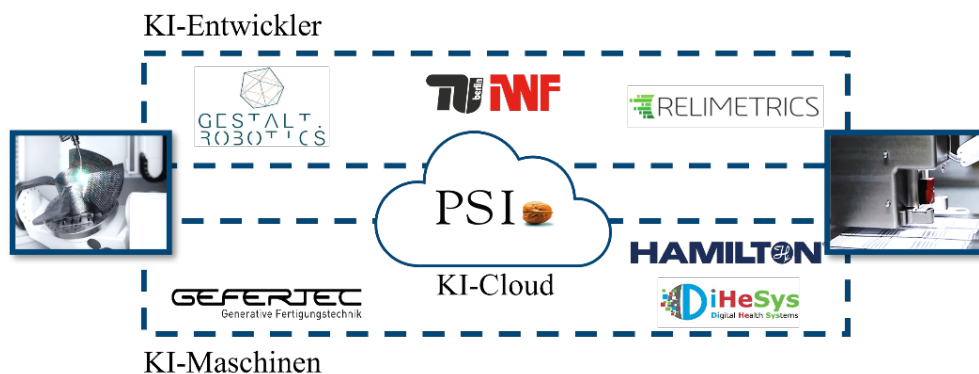


Abbildung 1: Organigramm des KIKA-IPK Projekts mit Logos der Projektpartner. (Links: Lichtbogenauftragschweißen, Rechts: Medikamentendruck)

1.2 ProKI-Netz: ProKI Berlin

Es gibt insgesamt acht *ProKI*-Standorte in Deutschland: Aachen, Berlin, Darmstadt, Dresden, Hannover, Ilmenau, Karlsruhe und Nürnberg.

Wie in Abbildung 2 gezeigt, stehen dort Produktionsverfahren wie Beschichten, Fügen, Trennen und Umformen im Fokus, mit dem Ziel die Wettbewerbsfähigkeit von kleinen und mittleren Unternehmen (KMU) in der Produktion durch den Einsatz von KI zu steigern. Durch Demonstrationsmaßnahmen, Qualifizierungsmaßnahmen und Transferprojekte werden Unternehmen auf die neuesten Trends und Mehrwerte der KI hingewiesen, Mitarbeitende für den KI-Einsatz geschult und Unternehmen bei aktuellen Herausforderungen beraten. [6]

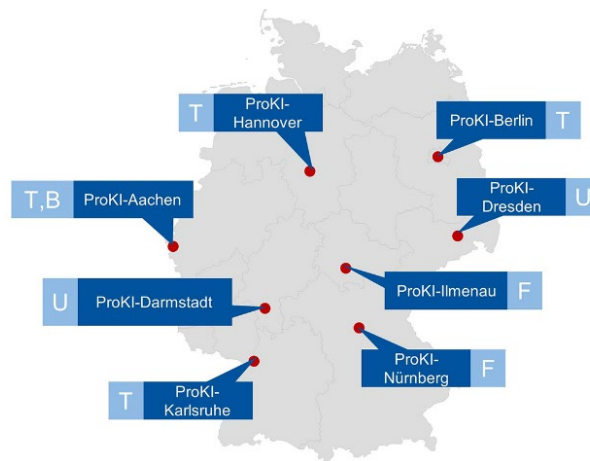


Abbildung 1: ProKI-Netz Karte. (B: Beschichten, F: Fügen, T: Trennen, U: Umformen)
©Werkzeugmaschinenlabor WZL der RWTH Aachen

Forschungsseitig erprobte KI-Anwendungen sollen so in reale Produktionsumfelder überführt werden. Dafür entwickelt jeder Standort Konzepte zur Einführung von KI-Applikationen und bietet verschiedene Maßnahmen für Unternehmensvertreter an, um KI in den jeweiligen Fertigungsverfahren erfahrbar zu machen und produktionsbegleitende Anwendungen zu implementieren. [9]

ProKI Berlin vereint die fünf Fachbereiche: Werkzeugmaschinen und Fertigungstechnik, Datenbank- und Informationsmanagement, Mensch-Maschine-Systeme sowie industrielle Automatisierung. Durch Forschungs- und Praxiserfahrung über diese Disziplinen hinweg entstehen ganzheitliche Lösungen für den Einsatz künstlicher Intelligenz. [10]

Im produktionstechnischen Zentrum der *TUB* werden mehrere Demonstratoren gezeigt. Es handelt sich dabei um Fräs-, Dreh- und Senkmaschinen, die mit KI zur Prozessüberwachung, Prozessanalyse, vorausschauender Wartung und Prozessoptimierung nachgerüstet werden. Gezeigt werden unter anderem die Werkzeugverschleißerkennung bei der Zerspanung von carbonfaserverstärktem Kunststoff mittels Echtzeitanalyse des emittierten Körperschalls, die Prozessregelung mit Werkzeugverschleißkompensation durch laserbasiertes Abtasten und Analysieren der Bauteiloberfläche beim Drehen, die Erkennung von Fertigungsfehlern in der Ultrapräzisionsfertigung bei der Herstellung von Noppenelementen mit Spanbeurteilung durch maschinelles Sehen, die Prozessoptimierung bei der Funkenerosion durch ein KI-Assistenzsystem, die Prozessregelung und -optimierung mit thermischer und statischer Kompensation innerhalb des Maschinengestells einer modularen Bearbeitungsmaschine und die Inprozesskontrolle von Rattern beim, durch das *IAT* betreuten, Fräsdemonstrator anhand von Sensor- und Prozessdaten. [10]

2 KI in der Produktion

Im Artikel „Artificial Intelligence in manufacturing: State of the art, perspectives, and future directions“ beschreiben Gao et al. signifikante Fortschritte bei Anwendungen von KI in der Fertigung und zeigen vielfältige Möglichkeiten zur Prozessoptimierung, Qualitätskontrolle und der vorausschauenden Wartung auf. Als beispielhafte Anwendungen werden unter anderem die Prozessmodellierung durch künstliche, neuronale Netzwerke beim Spritzgießen, die Vorhersage der Materialabtragsrate beim Polieren durch Deep-Belief-Netzwerke, die Oberflächendefekterkennung in der additiven Fertigung mit Hilfe von Convolutional-Neural-Networks (CNN), die Werkzeugverschleißvorhersage beim Fräsen durch Gated-Recurrent-Units, die Optimierung von Prozessparametern beim Tiefziehen durch Reinforcement-Learning und die Temperaturvorhersage in der additiven Fertigung durch Physics-Informed-ML genannt. [11]

Die Integration von KI in Fertigungsprozesse ermöglicht eine Steigerung von Effizienz, Qualität und Flexibilität und ist dadurch von großem wirtschaftlichem Interesse. Jedoch sehen sich insbesondere KMU bei der Einführung von KI mit erheblichen Hindernissen konfrontiert. Eine der größten Herausforderungen ist der Mangel an Wissen und Fähigkeiten in diesem Bereich, um KI-Technologien effektiv zu entwickeln und umzusetzen, sowie teilweise hohe Implementierungskosten. Dazu kommen oft Bedenken hinsichtlich Datensicherheit, Datenschutz und eines kulturellen Wandels innerhalb der Unternehmen, zum Beispiel aus Angst vor Arbeitsplatzverlust. [12], [13]

Mit dem gezielten Aufbau digitaler Kompetenzen – etwa mittels Schulungen und Ausbildungen zu KI und deren Anwendungen – können KMU befähigt werden, die Einführung von KI in ihren Prozessen zu beschleunigen. Durch Förderprogramme können Implementierungskosten verringert und dadurch der Zugang zu KI-Technologien für KMU erleichtert werden. Zuletzt können Investitionen in Cybersicherheitsmaßnahmen und den Datenschutz, sowie die Förderung einer positiven Unternehmenskultur gegenüber KI dazu beitragen die Vorteile von KI in Fertigungsprozessen bei KMUs zu erschließen. [12], [13]

2.1 WAAM

ML und DL werden zur Überwachung des WAAM-Prozesses bei der Defekterkennung, Parameteroptimierung und Qualitätssicherung genutzt. WAAM-Prozesskontrolle lässt sich mit Daten aus Kameras, Spannungs- und Schallsensoren durch KI erheblich verbessern und in Echtzeit abbilden. Mit bildbasierten KI-Systemen können die geschweißten Schichten in Echtzeit analysiert werden, um Oberflächenanomalien wie mangelhafte Anbindung der Schichten und Hohlräume zu identifizieren [14]. Die Höhe und Breite des Auftrags können mit Random-Forest-Modellen sehr genau vorhergesagt werden, aus den Geometriedaten lassen sich mit diesen Modellen auch die Stromstärke und Fahrgeschwindigkeit ableiten, um so die Prozessparameter für geometrische Genauigkeit zu optimieren [15]. Defekte die aus der Bildung von Schweißkugeln resultieren, können mit CNNs aus Bildern und Spannungsdaten klassifiziert werden [16]. Die Schallemissionen beim WAAM können genutzt werden, um den Prozesszustand in Echtzeit zu kontrollieren, zu bewerten und so Defekte vorherzusagen [17].

2.2 DoD

Eine genaue Messung kleiner Flüssigkeitsvolumina ist für Anwendungen des DoD-Verfahrens im pharmazeutischen Bereich, der kombinatorischen Chemie und in industriellen Prozessen, bei denen genaue Dosierungen von Reagenzien, Schmiermitteln oder Kühlmitteln erforderlich sind, von besonderer Bedeutung [18]. Bei bestimmten Anwendungen ist es zudem essentiell, dass diese

Methoden berührungslos erfolgen, um Verunreinigungen und Flüssigkeitsverlust zu vermeiden [19]. Geeignete Methoden ermöglichen eine Echtzeit-Prozesskontrolle, um Stabilität und Reproduzierbarkeit zu gewährleisten [18]. Es gibt verschiedene Ansätze das Volumen von Tropfen im Nanoliterbereich kontaktlos zu messen. Wenn ein Tropfen ein elektrisches Feld zwischen Kondensatorelektroden durchläuft, kann durch die Messung der Kapazitätsänderung auf das Tropfenvolumen geschlossen werden [18], [20]. Tropfen können im freien Fall vor einer lichtemittierenden Diode mit einem Phototransistor optische abgetastet werden, um das Volumen zu bestimmen [21]. Alternativ kann durch Messung des Luftrückflusses in den Dispenserbehälter mit einem Durchflusssensor das Volumen des ausgestoßenen Tropfens abgeleitet werden [22]. Als nicht kontaktfreie Vergleichsmethode dient im Regelfall ein gravimetrisches Verfahren, das als Standardmethode angesehen wird, dafür wird aus der Messung der Tropfenmasse das Tropfenvolumen hergeleitet [23].

2.3 Fräsen

Im Fräsprozess eignen sich Größen wie Schnittkraft, Oberflächenrauheit, Werkzeugverschleiß und akustische Emissionssignale für die Überwachung durch KI. Daraus kann auf die Qualität der bearbeiteten Teile und den Zustand der Schneidwerkzeuge rückgeschlossen werden [24]. Hohe Schnittkräfte können zu schnellem Werkzeugverschleiß und schlechter Oberflächengüte führen [25]. Die Oberflächenrauheit ist ein entscheidendes Qualitätsmerkmal des Fräsprozesses während Kenntnis über den Werkzeugverschleiß die Planung eines rechtzeitigen Werkzeugtauschs ermöglicht und so Werkzeugausfälle vermieden und eine gleichbleibende Bearbeitungsqualität gewährleistet werden kann [24], [25]. Durch die Analyse akustischer Emissionssignale können Anomalien im Fräsprozess, wie zum Beispiel Werkzeugzustand, -bruch, Rattern und andere Unregelmäßigkeiten erkannt werden [25], [26], [27]. KI kann beim Fräsen dazu beitragen die Oberflächenqualität zu verbessern, den Werkzeugverschleiß und Ausfallzeiten zu reduzieren, Bearbeitungsparameter wie Vorschub und Schnitttiefe zu optimieren und so eine verbesserte Bearbeitungseffizienz und geringeren Betriebskosten ermöglichen [24], [25], [27]. Sensordaten können von künstlichen, neuronalen Netzen und Support-Vector-Regression-Modellen genutzt werden, um Oberflächenrauheit und Schnittkräfte vorherzusagen und Prozessparameter zu optimieren [24], [25]. Mit Generative-Adversarial-Networks lassen sich synthetische Trainingsdaten für die Überwachung des Werkzeugzustands generieren, die im Training von anderen KI-Modellen zur Performanceverbesserung beitragen können [28]. Aus der Analyse von akustischer Emissionen mit Hilfe logistischer oder polynomialer Regression, CNNs, Residual-Networks und DL-Modellen kann der Werkzeugzustand abgeleitet werden [25], [26].

3 Projektinhalte

In den Projekten *KIKA-IPK* und *ProKI Berlin* werden verschiedene Ansätze für KI-Anwendungen konzipiert und untersucht. Als Grundlage dafür dienen Aufzeichnungen von Sensordaten aus den Fertigungsprozessen – WAAM, Medikamentendruck und Fräsen. An exemplarischen Beispielen können Inhalte und Ergebnisse der Untersuchungen gezeigt werden. Beim WAAM werden mit einer Kamera, Bilder aus dem Prozess aufgezeichnet und mit KI analysiert, um bestimmte Prozessmerkmale zu erfassen. In Strom- und Spannungsdaten wird der Prozess mit Hilfe des Matrixprofils [29] bewertet, um Anomalien aufzudecken. Synthetische Bilder und Tiefenkarten von Tropfen des DoD-Verfahrens werden verwendet, um KI zur Bestimmung des Volumens zu trainieren. Assistenzfunktionen des *ProKI-Cockpits* ermöglichen Echtzeitfeedback zu Fertigungsprozessen, wie zum Beispiel zu Anomalien beim Fräsen.

3.1 Objekterkennung

Zu Beginn des WAAM-Prozesses bei *Gefertec* wird ein CAD-Modell erzeugt, aus dem Werkzeugpfade mithilfe von CAM-Software und ein Programm zur numerischen Steuerung des Drucks abgeleitet werden. In der Qualifizierungsphase findet ein Testdruck statt der zur Determinierung geeigneter Prozessparameter dient, die durch Röntgen- und Zugtests der Probe im Labor verifiziert werden. Während des Prozesses werden mit einer Kamera Bilder aufgezeichnet. In diesen Bildern können Schutzgasdüse, Draht, Lichtbogen, Schweißbad, Spritzer und Rauch identifiziert werden. In Abbildung 3 ist ein Bild aus dem Schweißprozess gezeigt. Die Schutzgasdüse ist im oberen Teil des Bildes erkennbar. Der Draht befindet sich im Bild unterhalb der Düse und ist in der Regel zentriert; er kann aus verschiedenen metallischen Werkstoffen bestehen und dient als abschmelzende Elektrode, die auf die Oberfläche eines Bauteils aufgetragen wird. Der Lichtbogen befindet sich in dem überbelichteten Bereich an der Drahtspitze; er ist die Wärmequelle, die den Draht zum Schmelzen bringt. Das Schweißbad ist in den Bildern visuell mit dem Lichtbogen oder dem Draht verbunden und folgt dem Draht in der Bewegungsrichtung des Geräts; es ist ein örtlich begrenzter Bereich mit geschmolzenem Material. Spritzer sind im Bild als kleine, helle Partikel sichtbar, die in der Regel einen linienförmigen Schweiß mit einem vom Lichtbogen ausgehenden Helligkeitsgradienten aufweisen, aber je nach Flugbahn ein unterschiedliches Aussehen haben können; sie bestehen aus Tropfen geschmolzenen Materials, die aus der Richtung des Lichtbogens ausgestoßen werden und sich in jede beliebige Raumrichtung bewegen und an den umgebenden Oberflächen anhaften können. Abweichungen in Größe beziehungsweise Anzahl dieser Merkmale zum Verhalten während der Qualifizierung können auf eine Prozessinstabilität hindeuten.




Abbildung 2: Bild aus dem Schweißprozess bei Gefertec

Die Erkennung von Objekten in Bildern ist eine häufige Aufgabe bei industriellen Anwendungen. Zu den populärsten KI-Modellen für diesen Zweck gehören *YOLO* (You Only Look Once) [30] und *Faster-Region-based-Convolutional-Neural-Networks* [31]. Zum überwachten Training dieser Modelle werden annotierte Bilder benötigt. Die Schweißkamera liefert 30 bis 50 Bildern pro Sekunde, was beim Drucken eines Testteils für die Qualifizierung, 100.000 bis 200.000 Bildern entspricht. In *KIKA-IPK* wird ein Konzept für das aktive Lernen eines KI-Modells eingesetzt, bei dem die Auswahl der Bilder in Abhängigkeit vom Modell selbst getroffen wird, um die Effizienz und Effektivität des Annotierens zu steigern. Ziel ist es dabei mit einer minimalen Anzahl von annotierten Bildern und folglich möglichst geringem Aufwand für das Annotieren, ein möglichst genaues Modell zu erhalten. Das Verfahren ist in Abbildung 4 illustriert. Die dafür benötigten Vorhersagen des Modells werden gleichzeitig in einer Assistenzfunktion in der Benutzeroberfläche der Annotationssoftware eingesetzt. Dadurch kann das Verfahren weiter beschleunigt werden, denn Annotationen müssen nicht immer manuell erzeugt werden, sondern können, mit steigender Zuverlässigkeit des Modells, aus den Vorhersagen übernommen werden.

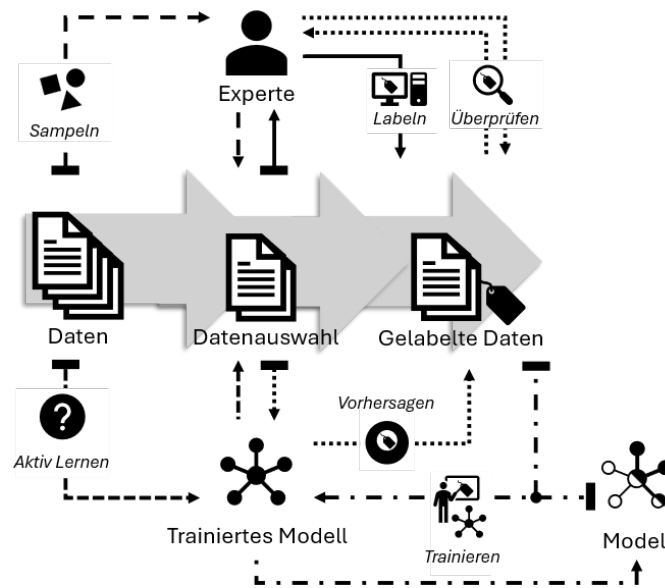


Abbildung 3: Konzept für aktives Lernen mit Annotationsassistentz

3.2 Anomalieerkennung

Strom- und Spannungsdaten liefern beim WAAM wichtige Informationen zum Prozesszustand. Strom- und Spannung folgen einem wiederkehrenden, zeitlichen Muster, das abhängig von Prozessparametern, wie zum Beispiel dem verwendeten Material, und der Prozessdauer variiert. Abbildung 5 zeigt den zeitlichen Verlauf von Strom- und Spannung bei einem Druckvorgang. Im Bereich von Sekunde 5,95 ist eine Anomalie zu sehen, die mit dem Verfahren zur Anomalieerkennung in *KIKA-IPK* identifiziert werden kann. Vom Normalverhalten abweichende Spannungsspitzen, wie bei Sekunde 6,575, lassen sich dagegen auch durch einfache Grenzwertbestimmung erkennen.




Abbildung 4: Strom- und Spannungsdaten mit Anomalie

Eine Schwierigkeit bei der Erkennung von Anomalien liegt darin, dass sie im realen Prozess nur selten auftreten. Es ist möglich Anomalien durch einen beabsichtigten Eingriff in den Prozess zu erzwingen, was wegen möglicher unerwünschter Folgen aber nur für einzelne Experimente umzusetzen ist. Das entwickelte Verfahren nutzt Daten aus der Parameterqualifizierung, die als Normalverhalten interpretiert werden, und setzt die Programmibliothek *Stumpy* [32] zur Verarbeitung ein. *Stumpy* berechnet das sogenannte Matrixprofil - ein Vektor, der die z-normalisierte euklidische Distanzen zwischen allen Teilsequenzen innerhalb einer Zeitreihe und ihren nächsten Nachbarn, den Teilsequenzen mit der kleinsten Distanz zur betrachteten Sequenz, darstellt [29].

Durch die Summation der Distanzen der Teilsequenzen zu einer festgelegten Anzahl von Nachbarn und der Akkumulation dieser Summen über eine bestimmte Fensterbreite kann ein, für das Normalverhalten repräsentativer, Abschnitt ermittelt werden. Im Druckprozess wird das Matrixprofil mit den Daten des Prozesses und diesem Normalverhalten berechnet. Die Distanzen im Matrixprofil werden als Anomaliewert interpretiert. Ist die Distanz zur ähnlichsten Sequenz im Normalabschnitt klein, ist das Prozessverhalten normal. Große Distanzen beschreiben anomales Verhalten. In Abbildung 6 sind auf der linken Seite die Distanzen des Matrixprofils zum Normalabschnitt für die in Abbildung 5 gezeigten Spannungsdaten dargestellt. Die roten Punkte zeigen die vier Segmente mit den höchsten Distanzen an. Rechts daneben ist das Segment mit der höchsten Distanz und sein nächster Nachbar aus dem Normalabschnitt abgebildet.




Abbildung 5: Anomalien in Spannungsdaten

Durch das sehr effiziente Verfahren und die Möglichkeit die Berechnung des Matrixprofils auf Grafikkarten zu parallelisieren, können auch große Mengen an Strom- und Spannungsdaten, die im Prozess mit 4 kHz bereitgestellt werden, in Echtzeit verarbeitet werden.

3.3 Tiefenschätzung

Im Medikamentendruck werden während des DoD-Verfahrens Fotografien der Einzeltropfen im freien Fall angefertigt. Diese Prozessbilder können zur Schätzung des Volumens der Nanolitertropfen genutzt werden, um die abgegebenen Wirkstoffmengen zu kontrollieren. Bei überwachten ML-Verfahren wird zum Training der Modelle Information über den tatsächlichen Sachverhalt der Zielgrößen benötigt. Im realen Prozess existiert für Nanolitertropfen im freien Fall kein kontaktloses Verfahren zur exakten Bestimmung des Volumens. 3D-Grafiksoftware, wie zum Beispiel Blender [33], ermöglicht dagegen das Volumen virtueller 3D-Objekte genau zu bestimmen und kann fotorealistische Darstellungen sowie akkurate Tiefeninformationen generieren. Monokulare Bilder können verwendet werden, um mit KI-Verfahren die passende Tiefeninformation abzuleiten. Vielversprechende Ansätze bieten dabei insbesondere vortrainierte Modelle, wie *Depth-Anything* [34], *MiDaS* [35] und *ZoeDepth* [36]. Diese Modelle können mit synthetischen Daten – Bilder und Tiefeninformation von virtuellen Tropfen – trainiert werden. Es lässt sich zeigen, dass so trainierte Modelle auch bei Bildern von Tropfen aus dem realen Prozess akkurate Tiefeninformationen erzeugen. Abbildung 7 zeigt links das Bild eines virtuellen Tropfens das optisch Tropfenbildern aus dem Prozess entspricht. Mittig ist die Visualisierung von Tiefeninformation des virtuellen Tropfens dargestellt. Die isometrische Ansicht rechts bildet eine 3D-Rekonstruktion der vom KI-Modell geschätzten Tiefeninformation ab. Diese Informationen können anschließend zur Volumeberechnung eingesetzt werden. Mit diesem Verfahren steht ein KI-basierter Ansatz zur Volumenschätzung bereit, der es ermöglicht bisherige Verfahren zu verifizieren und zu genaueren Volumenschätzungen zu gelangen.




Abbildung 6: Synthetische Daten von Nanolitertropfen

3.4 Cockpit

Das *ProKI-Cockpit* ist eine integrale Plattform, die KI-Anwendungen in der Echtzeitüberwachung und Bewertung von Fertigungsprozessen bereitstellt. Es besteht aus einem Backend und einem webbasiertem Frontend, wobei letzteres sowohl als Schnittstelle zu Maschinen und Sensoren als auch zu den Bedienerinnen und Bedienern dient. Über das Frontend können Anwender und Anwenderinnen den Fertigungsprozess überwachen, Sensordaten visualisieren, Daten annotieren und ML-Modelle trainieren, testen und evaluieren. In Abbildung 8 ist die Benutzeroberfläche des *ProKI-Cockpits* gezeigt. In die Oberfläche integriert ist die Open-Source-Plattform, *Label Studio* [37], zu sehen. Durch diese Integration können Daten direkt auf der *ProKI*-Plattform annotiert werden, ohne die Anwendung verlassen zu müssen. Über das Navigationsmenü auf der linken Seite lassen sich außerdem die Benutzeroberfläche zum Zugriff auf die Datenbank, zur Datenaugmentierung, zum Training von KI-Modellen und zur Anwendung von KI-Systemen in der Produktion erreichen.

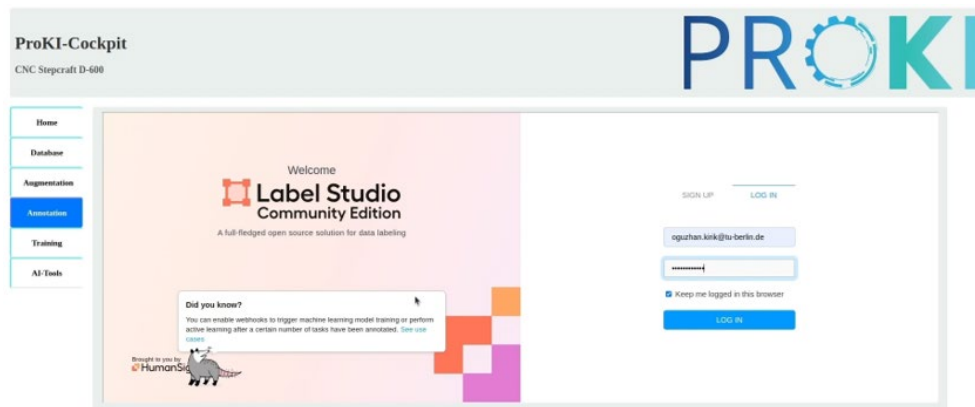


Abbildung 7: Benutzeroberfläche des ProKI-Cockpit

Ein spezifisches KI-System im *ProKI-Cockpit* dient der Erkennung von Ratterphänomenen im Fräsprozess. Rattern stellt eine selbsterregte Schwingung dar, die die Produktivität und Qualität in der Zerspanung erheblich beeinträchtigen kann. Die frühzeitige Identifikation und Vorhersage solcher Schwingungen ist daher essenziell, um Schäden an Werkstücken, Werkzeugen und Maschinen zu vermeiden. Hierbei werden Sensoren eingesetzt, die Vibrationen an der Maschine erfassen. Die Daten werden dann in Echtzeit analysiert und über geeignete Visualisierungen im *ProKI-Cockpit* kommuniziert. Eine effektive Methode zur Anomalieerkennung in Vibrationsdaten

beim Fräsen ist der Einsatz von Autoencodern. Autoencoder sind neuronale Netzwerke, die darauf trainiert werden, Daten zu komprimieren und anschließend originalgetreu zu rekonstruieren. Während des Trainings lernen Autoencoder die charakteristischen Merkmale des normalen Prozessverhaltens. Treten Anomalien auf, wie beispielsweise Rattern, weichen die rekonstruierten Daten signifikant von den tatsächlichen Sensordaten ab. Das zentrale Maß, der Rekonstruktionsfehler, ist dann besonders groß und kann verwendet werden, um auf Fehlerzustände im Prozess zu schließen. Durch die kontinuierliche Überwachung der Rekonstruktionsfehler können Anomalien in Echtzeit detektiert werden. Das *ProKI-Cockpit* kann sowohl das Training von Autoencodern, als auch die Datenanalyse mit Autoencodern und die Visualisierung der Ergebnisse abbilden.

4 Zusammenfassung und Ausblick

In den vom *BMBF* geförderten Projekten, *KIKA-IPK* und *ProKI Berlin*, konnten zahlreiche innovative Ergebnisse erzielt werden. Die entwickelten KI-Verfahren ermöglichen die Echtzeit-Analyse von Bild- und Prozessdaten und tragen zur Optimierung von Fertigungsprozessen und zur Qualitätssicherung bei. Durch Anwendung und Demonstration von KI im WAAM, im Medikamentendruck und beim Fräsen, konnte KI für diese Produktionsverfahren erschlossen, erprobt und sichtbar gemacht werden. Die Ergebnisse haben sowohl wirtschaftlich als auch wissenschaftlich ein hohes Potenzial. Die Projekte tragen zudem zur digitalen Transformation in der Industrie bei, indem sie digitale Kompetenzen fördern und traditionelle Produktionsprozesse durch intelligente, datengestützte Verfahren ergänzen. Gleichzeitig konnte durch ein breites Spektrum an Maßnahmen – etwa durch Ausstellungen, Konferenzen und Workshops – insbesondere KMU der Nutzen von KI-Anwendungen in der Produktion nahegebracht und ihre praktische Umsetzung unterstützt werden. Des Weiteren können praxisnahe KI-Anwendungen in das Lehrangebot der *TUB* integriert werden. Die Ergebnisse werden in Studierendenprojekten, Online-Kursen und neuen Lehrformaten eingesetzt und ergänzen das Lehrangebot mit aktuellen und fortschrittlichen Themen. Damit können Wissenstransfer zwischen Forschung und Praxis gesichert und Herausforderungen einer digitalisierten Produktionslandschaft mit zukunftsfähiger Ausbildung begegnet werden. Die Ergebnisse bilden die Basis, für weitergehende Entwicklung und Forschung. Prototypische Umsetzungen werden perspektivisch von Anwendungspartnern in industrielle Prozesse integriert. Der interdisziplinäre Austausch zwischen Wissenschaft, Industrie und Lehre bleibt ein zentraler Erfolgsfaktor für die nachhaltige Implementierung und Weiterentwicklung von KI-Technologien in der Fertigung.

5 Förderhinweis

Die Projekte *KIKA-IPK* und *ProKI Berlin* werden in den Fördermaßnahmen „Demonstrations- und Transfernetzwerk KI in der Produktion (ProKI-Netz)“ und „Lernende Produktionstechnik – Einsatz Künstlicher Intelligenz (KI) in der Produktion (ProLern)“ durch das *Bundesministerium für Bildung und Forschung (BMBF)* im Programm „Zukunft der Wertschöpfung – Forschung zu Produktion, Dienstleistung und Arbeit“ gefördert und vom *Projektträger Karlsruhe (PTKA)* betreut. Die Verantwortung für den Inhalt dieser Veröffentlichung liegt bei den Autorinnen und Autoren.

Literaturverzeichnis

- [1] “Bekanntmachung - BMBF - ProLern,” Bundesministerium für Bildung und Forschung - BMBF. Accessed: Feb. 13, 2025. [Online]. Available: https://www.bmbf.de/SharedDocs/Bekanntmachungen/DE/2019/10/2665_bekanntmachung.html

- [2] “Künstliche Intelligenz - BMBF,” Bundesministerium für Bildung und Forschung - BMBF. Accessed: Feb. 13, 2025. [Online]. Available: https://www.bmbf.de/DE/Forschung/Zukunftstechnologien/KuenstlicheIntelligenz/kuenstlich-eintelligenz_node.html
- [3] “Forschungsprogramm „Zukunft der Wertschöpfung“ des BMBF,” Zukunft der Wertschöpfung. Accessed: Feb. 13, 2025. [Online]. Available: <https://www.zukunft-der-wertschoepfung.de/>
- [4] “Bekanntmachung - BMBF - ProKI-Netz,” Bundesministerium für Bildung und Forschung - BMBF. Accessed: Feb. 13, 2025. [Online]. Available: <https://www.bmbf.de/SharedDocs/Bekanntmachungen/DE/2022/01/2022-01-18-Bekanntmachung-ProKI-Netz.html>
- [5] “Projekte Archive - ProLern,” Zukunft der Wertschöpfung. Accessed: Feb. 14, 2025. [Online]. Available: <https://www.zukunft-der-wertschoepfung.de/projekte/?filter-funding-measure=3396>
- [6] Lukas Gründel, Nils Thielen, Dennis Stoppel, and Oliver Petrovic, *Projektatlas „Künstliche Intelligenz in der Produktion“*. Accessed: Feb. 13, 2025. [Online]. Available: <https://www.zukunft-der-wertschoepfung.de/mediathek/projektatlas-kuenstliche-intelligenz-in-der-produktion/>
- [7] Dr.-Ing. Soner Emec, “Das Beste aus beiden Welten,” no. FUTUR 2 / 2022 Mensch und Maschine, [Online]. Available: https://www.ipk.fraunhofer.de/content/dam/ipk/IPK_Hauptseite/dokumente/futur/ausgaben/ipk-futur-2022-2-de.pdf
- [8] “KIKA-IPK - TU Berlin.” Accessed: Feb. 14, 2025. [Online]. Available: <https://www.tu.berlin/iat/forschung/projekte/kika-ipk>
- [9] “Projekte Archive - ProKI,” Zukunft der Wertschöpfung. Accessed: Feb. 14, 2025. [Online]. Available: <https://www.zukunft-der-wertschoepfung.de/projekte/?filter-funding-measure=3552>
- [10] “ProKI-Berlin – Digitalisierung und KI in der Produktion.” Accessed: Feb. 15, 2025. [Online]. Available: <https://proki-berlin.de/>
- [11] R. X. Gao, J. Krüger, M. Merklein, H.-C. Möhring, and J. Váncza, “Artificial Intelligence in manufacturing: State of the art, perspectives, and future directions,” *CIRP Ann.*, vol. 73, no. 2, pp. 723–749, Jan. 2024, doi: 10.1016/j.cirp.2024.04.101.
- [12] S. Kinkel, M. Baumgartner, and E. Cherubini, “Prerequisites for the adoption of AI technologies in manufacturing – Evidence from a worldwide sample of manufacturing companies,” *Technovation*, vol. 110, p. 102375, Feb. 2022, doi: 10.1016/j.technovation.2021.102375.
- [13] M. G. O. Cevallos, G. A. L. Jaramillo, J. L. B. Vélez, M. I. U. Zambrano, L. D. Z. Montesdeoca, and M. A. B. Palomeque, “Implementation of Artificial Intelligence in Quality Management in SMEs: Benefits and Challenges,” *Evol. Stud. IMAGINATIVE Cult.*, pp. 1489–1500, Oct. 2024, doi: 10.70082/esiculture.vi.1590.

- [14] Y. Li *et al.*, “Towards intelligent monitoring system in wire arc additive manufacturing: a surface anomaly detector on a small dataset,” *Int. J. Adv. Manuf. Technol.*, vol. 120, no. 7, pp. 5225–5242, Jun. 2022, doi: 10.1007/s00170-022-09076-5.
- [15] R. Sharma, A. Raj Paul, M. Mukherjee, S. Ram Krishna Vadali, R. Kumar Singh, and A. Kumar Sharma, “Forecasting of process parameters using machine learning techniques for wire arc additive manufacturing process,” *Mater. Today Proc.*, vol. 80, pp. 248–253, Jan. 2023, doi: 10.1016/j.matpr.2022.12.081.
- [16] S.-J. Shin, S.-H. Hong, S. Jadhav, and D. B. Kim, “Detecting balling defects using multisource transfer learning in wire arc additive manufacturing,” *J. Comput. Des. Eng.*, vol. 10, no. 4, pp. 1423–1442, Aug. 2023, doi: 10.1093/jcde/qwad067.
- [17] H. Li, F. Gao, J. Jiao, Z. Liu, D. Ji, and J. Lin, “Acoustic Emission-Based Cross-Domain Process Health Monitoring for Additive Manufacturing,” *IEEE Trans. Instrum. Meas.*, vol. 72, pp. 1–8, 2023, doi: 10.1109/TIM.2023.3320740.
- [18] A. Ernst, L. Ju, B. Vondenbusch, R. Zengerle, and P. Koltay, “Noncontact Determination of Velocity and Volume of Nanoliter Droplets on the Fly,” *IEEE Sens. J.*, vol. 11, no. 8, pp. 1736–1742, Aug. 2011, doi: 10.1109/JSEN.2010.2095837.
- [19] A. Ernst, W. Streule, N. Schmitt, R. Zengerle, and P. Koltay, “A capacitive sensor for non-contact nanoliter droplet detection,” *Sens. Actuators Phys.*, vol. 153, no. 1, pp. 57–63, Jun. 2009, doi: 10.1016/j.sna.2009.04.023.
- [20] A. Ernst, W. Streule, R. Zengerle, and P. Koltay, “Quantitative volume determination of dispensed nanoliter droplets on the fly,” in *TRANSDUCERS 2009 - 2009 International Solid-State Sensors, Actuators and Microsystems Conference*, Jun. 2009, pp. 1750–1753. doi: 10.1109/SENSOR.2009.5285741.
- [21] J. Tröndle, A. Ernst, W. Streule, R. Zengerle, and P. Koltay, “Non-contact optical sensor to detect free flying droplets in the nanolitre range,” *Sens. Actuators Phys.*, vol. 158, no. 2, pp. 254–262, Mar. 2010, doi: 10.1016/j.sna.2010.01.023.
- [22] D. Liang, T. G. Muniyogeshbabu, L. Tanguy, A. Ernst, R. Zengerle, and P. Koltay, “ONLINE LIQUID CALIBRATION TECHNOLOGIES,” 2012.
- [23] D. Liang, L. Tanguy, A. Ernst, R. Zengerle, and P. Koltay, “NOVEL GRAVIMETIC CALIBRATION METHOD FOR NANO LITER LIQUID HANDLING DEVICES,” 2012.
- [24] M. S. El-Asfoury, M. Baraya, E. El Shrief, K. Abdelgawad, M. Sultan, and A. Abass, “AI-Based Prediction of Ultrasonic Vibration-Assisted Milling Performance,” *Sensors*, vol. 24, no. 17, p. 5509, Aug. 2024, doi: 10.3390/s24175509.
- [25] M. Ahmed *et al.*, “Tool Health Monitoring of a Milling Process Using Acoustic Emissions and a ResNet Deep Learning Model,” *Sensors*, vol. 23, no. 6, p. 3084, Mar. 2023, doi: 10.3390/s23063084.
- [26] A. Sio-Sever, J. M. Lopez, C. Asensio-Rivera, A. Vizan-Idoipe, and G. De Arcas, “Improved Estimation of End-Milling Parameters from Acoustic Emission Signals Using a Microphone Array Assisted by AI Modelling,” *Sensors*, vol. 22, no. 10, p. 3807, May 2022, doi: 10.3390/s22103807.

- [27] I. Inasaki, “Application of acoustic emission sensor for monitoring machining processes,” *Ultrasonics*, vol. 36, no. 1–5, pp. 273–281, Feb. 1998, doi: 10.1016/S0041-624X(97)00052-8.
- [28] “Sample Augmentation for Intelligent Milling Tool Wear Condition Monitoring Using Numerical Simulation and Generative Adversarial Network | IEEE Journals & Magazine | IEEE Xplore.” Accessed: Feb. 20, 2025. [Online]. Available: <https://ieeexplore.ieee.org/document/9424633>
- [29] C.-C. M. Yeh *et al.*, “Matrix Profile I: All Pairs Similarity Joins for Time Series: A Unifying View That Includes Motifs, Discords and Shapelets,” in *2016 IEEE 16th International Conference on Data Mining (ICDM)*, Dec. 2016, pp. 1317–1322. doi: 10.1109/ICDM.2016.0179.
- [30] G. Jocher, J. Qiu, and A. Chaurasia, *Ultralytics YOLO*. (Jan. 2023). Python. Accessed: Jan. 26, 2025. [Online]. Available: <https://github.com/ultralytics/ultralytics>
- [31] S. Ren, K. He, R. Girshick, and J. Sun, “Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks,” Jan. 06, 2016, *arXiv*: arXiv:1506.01497. doi: 10.48550/arXiv.1506.01497.
- [32] S. M. Law, “STUMPY: A Powerful and Scalable Python Library for Time Series Data Mining,” *J. Open Source Softw.*, vol. 4, no. 39, p. 1504, Jul. 2019, doi: 10.21105/joss.01504.
- [33] B. Foundation, “blender.org - Home of the Blender project - Free and Open 3D Creation Software,” [blender.org](https://www.blender.org/). Accessed: Feb. 25, 2025. [Online]. Available: <https://www.blender.org/>
- [34] L. Yang, B. Kang, Z. Huang, X. Xu, J. Feng, and H. Zhao, “Depth Anything: Unleashing the Power of Large-Scale Unlabeled Data,” Apr. 07, 2024, *arXiv*: arXiv:2401.10891. doi: 10.48550/arXiv.2401.10891.
- [35] R. Ranftl, K. Lasinger, D. Hafner, K. Schindler, and V. Koltun, “Towards Robust Monocular Depth Estimation: Mixing Datasets for Zero-shot Cross-dataset Transfer,” Aug. 25, 2020, *arXiv*: arXiv:1907.01341. doi: 10.48550/arXiv.1907.01341.
- [36] S. F. Bhat, R. Birkl, D. Wofk, P. Wonka, and M. Müller, “ZoeDepth: Zero-shot Transfer by Combining Relative and Metric Depth,” Feb. 23, 2023, *arXiv*: arXiv:2302.12288. doi: 10.48550/arXiv.2302.12288.
- [37] “Open Source Data Labeling,” Label Studio. Accessed: Feb. 25, 2025. [Online]. Available: <https://labelstud.io/>