






Abschlussbericht zum Vorhaben „Echtzeitdatenerfassung und Parameterkorrektur mittels einer mit Simulationsdaten angelegten KI (SimKI)“

1 Allgemeines

Das Ziel des Projekts „SimKI“ ist es, die Bauteilqualität bzw. Produktivität der KMU zu steigern, indem sowohl die Prozessparameter als auch Produktinformationen erfasst und in ein cloudbasiertes Datensystem transferiert werden. Dort werden diese Daten über einen KI-Algorithmus korreliert und zur Modifikation der Anlagensteuerung genutzt. Der Innovationsgrad basiert auf der Problemlösung, dass bislang ein hoher Versuchsaufwand und der Zugang zu großen Datenressourcen für das Anlernen einer KI notwendig waren. In „SimKI“ wird der Algorithmus über Richtig- bzw. Falschaussagen aus einer zu Projektbeginn erstellten Simulation trainiert.

1.1 Konsortialpartner

Tabelle 1: Auflistung der Konsortialpartner mit Darstellung der beteiligten klein- und mittelständischen Unternehmen (KMU)

Logo	Bezeichnung	Tätigkeitsfelder
Konsortialpartner (maßgeblich beteiligte Unternehmen)		
	INNEO Solutions GmbH (KMU)	Lösungsanbieter für CAD/CAM, PDM/PLM, IT- und Projektmanagement
	Gaugler & Lutz GmbH & Co. KG (KMU)	Anbieter von Spezialwerkstoffen für den Leicht- & Sandwichbau mit Kompetenz bei der Werkstoffbearbeitung
	Karl Walter Formen- und Kokillenbau GmbH & Co. KG (KMU)	Werkzeugauslegung und Formenbau insbesondere von metallischen Werkstoffen
Konsortialpartner (beteiligte wissenschaftliche Institutionen der Hochschule Aalen)		
	Fakultät Maschinenbau Prof. Sebastian Feldmann	Digitale Systemintegration im Bereich Industrie 4.0 und Entwicklung von KI-Algorithmen
	Technologie Zentrum Leichtbau Dr. Wolfgang Rimkus	Prozess- und Bauteilsimulation, Herstellung umgeformter Bauteile

1.2 Projektplan

Aufgrund der Covid-19 Pandemie kam es zu Verschiebungen im Projektplan, die sich beispielsweise in Form von Personal- und Lieferengpässen auf die Herstellung der umgeformten Bauteile, die Datenerfassung zur Digitalisierung der Anlagen oder die Bewertung der Fräsmuster auswirkten. In Folge dessen wurde der Projektplan iterativ angepasst bzw. Arbeitspakete verschoben, um den Projektfortschritt und einen erfolgreichen Abschluss sicherstellen zu können. Die folgende Abbildung 1 zeigt den Abgleich zwischen dem geplanten und tatsächlich durchgeführten Projektverlauf.

TP/AP	Kurzbeschreibung	Beteiligte Projektpartner					2020											
		Rimkus	Feldmann	Inneo	Karl Walter	G&L	1	2	3	4	5	6	7	8	9	10	11	12
TP1	Technologietransfer KI																	
	Technologietransfer KI	x	x	x	x	x												
TP2	Herstellung eines smarten Presswerkzeugs																	
AP2.1	Konstruktion und Auslegung des Werkzeugs	x			x													
AP2.2	Methodenplanung für die Herstellung				x													
AP2.3	Produktion des Werkzeugs und Montage der Sensoriken				x													
TP3	Digitalisierung der Maschinen und Bauteile																	
AP3.1	Maschine/Bauteil/Prozess in virtuelle Umgebung	x		x	x	x												
AP3.2	Erstellung einer parametrisierten Simulation	x																
TP4	Datengenerierung und -darstellung																	
AP4.1	Maschinen- und Bauteildaten auslesen (Ist-Zustand)			x	x	x												
AP4.2	Maschinen- und Bauteile mit smarten Sensoren bestücken	x	x	x		x												
AP4.3	Aufbau einer Qualitätssicherung (GOM, Linescanner)			x	x	x												
AP4.4	Schnittstellenerstellung Cloud - Maschinen/Bauteil		x	x	x	x												
AP4.5	Aufbereitung und Darstellung der Daten (Dashboard)			x														
TP5	Datenverarbeitung und -analyse																	
AP5.1	Anlernen der KI mittels Simulationsdaten	x	x	x														
AP5.2	Prozess anhand ermittelter Daten nachrechnen	x		x														
AP5.3	Korrektur der Prozessparameter			x	x	x												
TP6	Demonstratorherstellung																	
	Bauteilerstellung mit digitalisierter Wertschöpfungskette	x	x	x	x	x												

Abbildung 1: Abgleich des Projektverlaufs. Grün: nach Projektplan bearbeitete Arbeitspakete, Orange: verlagerte Arbeitspakete, Grau schraffiert: nicht bearbeitete Arbeitspakete

Der im Projektantrag beschriebene Meilenstein (AP 3.1) wurde auf den Kalendermonat 5 verschoben, da aufgrund der pandemiebedingten Restriktionen die Datenerhebung des Presswerkzeugs oder der Fräsmaschine verzögert wurde und keine Überführung in eine virtuelle Umgebung stattfinden konnte. Die Arbeitspakete der projektbeteiligten Unternehmen (z.B. AP 4.1 oder AP 4.2) wurden verlängert, um die situationsbedingt erhöhten Lieferzeiten und Personalmangel zu berücksichtigen. Im Gegenzug wurden projektkritische Arbeitspakete wie z.B. die Erstellung einer Schnittstelle zur Cloud oder das Anlernen des KI-Algorithmus (AP 5.1) vorgezogen bzw. entsprechend länger gestaltet. Bei letzterem wurde auf Basis fiktiver Testdaten vorgelagert ein Modell erstellt, welches ab Kalendermonat 9 mit Realdaten finalisiert und angelernt werden konnte. Die in AP 5.3 dargestellte Parameterrückkopplung zur Steuerungsmodifikation der Anlagen konnte innerhalb des zeitlichen Rahmens nicht vollständig abgeschlossen werden – die Daten wurden jedoch für entsprechende Arbeitsschritte vorbereitet.

2 Projektergebnisse

Für eine große Breitenwirkung der Projektergebnisse, werden in „SimKI“ verschiedene Situationen untersucht: eine Maschine bzw. Werkzeug a) mit und b) ohne vorhandenem Digitalisierungsgrad. Im Fall a) wird das Fräs-Bearbeitungszentrum von Gaugler & Lutz als Modellanlage genutzt, welches bereits mit Sensorik bestückt ist. Im Fall b) wird das Presswerkzeug von Karl Walter und die Presse der Hochschule Aalen betrachtet, die bislang keinerlei Datenerfassung ermöglichen.

2.1 Anlage ohne vorhandene digitale Schnittstelle (Umformprozess)

Zur Herstellung von Demonstratorbauteilen und zur Datengenerierung wurde ein smartes Umformwerkzeug entwickelt. Dieses beinhaltet eine Vielzahl von Sensoren, deren Daten über ein Echtzeit-Datenerfassungssystem auf die IoT-Plattform übertragen werden. Das Umformwerkzeug, das in Abb. 2 dargestellt ist, besteht aus einem Vier-Zonen-Stempel, einer Vier-Zonen-Matrize und einem Ein-Zonen-Platinenhalter. Diese Zonen können separat beheizt bzw. temperiert werden, um bewusst einen Bauteilverzug erzeugen zu können. Die daraus entstehenden Gut- bzw. Schlecht-Bauteile spielen eine entscheidende Rolle bei der Bewertung durch die KI im Demonstrationsprozess. Zusätzlich ist das Werkzeug mit einem pneumatischen Kurzhubzylinder zur Härtemessung des Bauteils und einem Thermoelement ausgestattet, welches die Platinentemperatur während der Umformung überwacht. Das Beschleunigungs- und Geschwindigkeitsprofil, das für das Lastkollektiv in der Simulation wesentlich ist, wird durch einen Distanzsensor gemessen. Dieser Sensor wird auch für die Berechnung der Hubzahl und Zykluszeit verwendet. Zur weiteren Prozessüberwachung wurde eine Kamera installiert, die sowohl Auffälligkeiten als auch die Einlegeposition der Platine überprüft.




Abbildung 2: Aufbau des smarten Umformwerkzeugs einschließlich der Sensoren

Die von der Maschine und dem Werkzeug gelieferten Sensordaten werden in Echtzeit erfasst und mittels Edge Micro-Server (EMS) und Simulink Real-Time an die ThingWorx-Plattform übertragen. Der Hauptvorteil dieses Aufbaus liegt in der Möglichkeit, gängige Maschinenschnittstellen wie z.B. Analogeingang, Digital IO, CAN, CAN-Open, EtherCAT, Ethernet, RS485 oder I2C implementieren zu können. Darüber hinaus können Prozessdaten vorverarbeitet und zwischengespeichert werden, bevor sie an den IoT-Server gesendet werden. Der Edge Micro-Server dient als Sicherheitsinstanz, um unbefugte Zugriffe zu verhindern. Außerdem kann er als Low-Cost-Gerät direkt an Maschinen der Produktionsanlage angeschlossen werden oder über eine TCP/IP-Verbindung Daten empfangen. Die gestreamten Prozessdaten werden mit einem Zeitstempel versehen und über eine verschlüsselte WebSocket-Verbindung an die IoT-Plattform gesendet. Die durchschnittliche Latenzzeit beträgt 20 bis 80 Millisekunden pro Datenpaket. Auf Basis der übermittelten Daten bietet der trainierte KI-Algorithmus die Möglichkeit, eine Echtzeitauswertung der Bilddaten zu generieren, um Defekte wie Falten- und Rissbildung zu identifizieren. Die Defekte werden in Form einer Heatmap (siehe Abb. 3) dargestellt. Zusätzlich gibt ein sich aktualisierendes Dashboard dem Bediener einen Überblick über Parameter wie z.B. Zykluszeit oder Temperaturen.




Abbildung 3: Umgeformtes Bauteil; a) ohne Defekte, b)/c) Rissbildung, d)Faltenbildung, e) Heatmap-Darstellung Falten, f) Heatmap-Darstellung Riss

Um eine möglichst große Anzahl bzw. Vielfalt an Simulationsbildern zu erzeugen, wurde mit dem Programm „LS-OPT“ eine DoE-Studie erstellt, die auf einer parametrisierten Umformsimulation basiert. Für jede Simulation werden die variierten Prozessparameter (z.B. Platinenposition), das Ergebnisbild und die Bewertung des Umformteils als Datensatz gespeichert. Dabei ist zu beachten, dass die Ansicht, in der die Simulationsbilder erstellt werden, der späteren Realität entspricht. Die Ergebnisse der DoE-Studie bilden die Grundlage für das Training der KI.

Dieser Ansatz hat einerseits den Vorteil, eine große Anzahl von Parametern in der Simulation schnell verändern und mittels DoE Wechselwirkungen erkennen zu können. Andererseits wird der Aufwand erheblich reduziert, die KI zu trainieren. Zur Verifizierung bzw. Vergleich wurden drei Lernstrategien untersucht: a) Training der KI nur über reale Versuchsbilder, b) nur über Simulationsdaten oder c) eine hybride Variante bestehend aus 80 % Simulationsbildern und 20 % Versuchsbildern. Für das Referenztraining und die Ergebnisauswertung wurde ein gängiges „deep neural Network“ (DNN) auf Basis der SqueezeNet-Architektur verwendet. Das DNN besteht aus 69 Schichten inklusive 9 "Fire"-Modulen, die mehrere Filter verwenden. Die Simulationsbilder wurden in eine Graustufendarstellung umgewandelt und gefiltert, um eine hohe Übereinstimmung mit den Aufnahmen realer Bauteile zu erreichen. Die Ergebnisse wurden in gute und defekte Teile aufgeteilt, die in den Trainingsordnern gemischt wurden. Das Training wurde auf einer Workstation mit einem Intel Xenon Quad-Core E5-2690 Prozessor durchgeführt.

Tabelle 2: Durchschnittliche Leistung des DNN in Abhängigkeit von der Lernstrategie

DNN Art des Trainings	Simulation	Versuche	Hybrid
Anzahl der Trainingsepochen	15	15	15
Anzahl der Iterationen	105	105	105
Validierungsgenauigkeit	83.84 %	82.96 %	84.38 %
Verstrichene Trainingszeit	7 min, 44 sec	8 min, 48 sec	10 min, 1 sec

Im Gegensatz zum konventionellen Training mit gescannten Bauteilen (82,96 % Genauigkeit) zeigen die Testergebnisse eine vergleichbare Validierungsgenauigkeit bei alleiniger Verwendung von Simulationsdaten (83,84 %) bzw. eines hybriden Datensatzes (84,38 %). Daher lässt sich sagen, dass der untersuchte Ansatz ein enormes Potenzial zur Verbesserung von Qualität und Einlaufprozessen in komplexen Umformprozessen aufweist. Darüber hinaus konnte gezeigt werden, dass moderne KI-Algorithmen auch in kleinen und mittleren Unternehmen sinnvoll und mit vertretbarem Aufwand eingesetzt werden können.

2.2 Anlage mit vorhandener digitaler Schnittstelle (Fräsprozess)

Der zweite Anwendungsfall ist aus drei Bausteinen aufgebaut: der Fräsmaschine mit vorhandener Sensorik, dem Edge Device und einer IoT-Plattform (siehe Anwendungsfall 1). Bei der verwendeten Fräsmaschine handelt es sich um eine 5-Achs-CNC-Holzfräse vom Typ VISION I der Reichenbacher Hamuel GmbH. Die Aufgabe des Edge Device (Industrierechner mit zwei Ethernet-Schnittstellen) ist die Erfassung der Ist-Prozessparameter und Sensordaten sowie die Überbrückung der Kommunikationslücke zwischen der Fräsmaschine und IoT-Plattform. Die Steuerung erfolgt über eine spezifische Schnittstelle, das s.g. S7-Protokoll (RFC 1006). Dieses Protokoll greift auf einen benutzerdefinierten Datenbaustein auf der SPS-Seite zu und wird von einem Treiber der auf dem Edge-Gerät installierten Software „PTC Kepware“ unterstützt. Die Übertragung vom Edge-Gerät zur Cloud-IoT-Plattform erfolgt über eine WebSocket-Verbindung. Die Aufgabe der dritten Komponente (der IoT-Plattform) ist es, Daten zu speichern, Merkmalsanalysen durchzuführen und die Trainingsgrundlage für maschinelles Lernen zu schaffen. Hierfür wurde eine On-Premises-Installation von PTC ThingWorx 8.5 in Kombination mit einer PostgreSQL-Datenbank verwendet.

Die Parameter, die während eines Fräsprozesses gesteuert werden können, sind die Schnittbreite, die Schnitttiefe, der Vorschub und die Schnittgeschwindigkeit. In den durchgeführten Versuchsreihen wurde die Vorschubgeschwindigkeit schrittweise von 30 000 mm/min bis zu 60 000 mm/min variiert, während die Spindeldrehzahl konstant auf 20000 U/min (maximal mögliche Drehzahl der Werkzeugmaschine) eingestellt wurde. Auch die Schnittbreite und -tiefe blieben während der Versuchsreihe konstant.




Abbildung 4: Aufbau der Fräs-Versuchsreihe

Die Fräsorientierung wurde definiert, um zwischen Gleich- und Gegenlaufräsen zu unterscheiden. Zur Evaluierung des Ansatzes wurde die Testreihe mit einem bei dem Konsortialpartner häufig eingesetzten Material, dem Polymerschaum AIREX T90 der Firma 3A Composites Holding AG, durchgeführt. Als Versuchsergebnis wurde die Rauheitsverteilung auf der Oberfläche ausgewertet, die durch unvollständige Schnitte, elastische Verformungen oder mehrfache Schnitte von ungelösten Spänen hervorgerufen wird.

Die Qualität der Oberfläche wurde manuell bewertet und mit der beobachteten Position des Fräasers abgeglichen. Die daraus resultierenden Daten lassen sich mittels der Schwankungen des Oberflächenparameters R_q beschreiben. Hohe Schwankungen in diesem Bereich bzw. schlechtere Oberflächen werden mit einem kleineren Qualitäts-Score bewertet, kleine Schwankungen bzw. gute Oberflächen mit einem größeren Wert. Der Wertebereich liegt zwischen 0 und 10. Zwei beispielhafte Scores sind in Abb. 5 dargestellt.

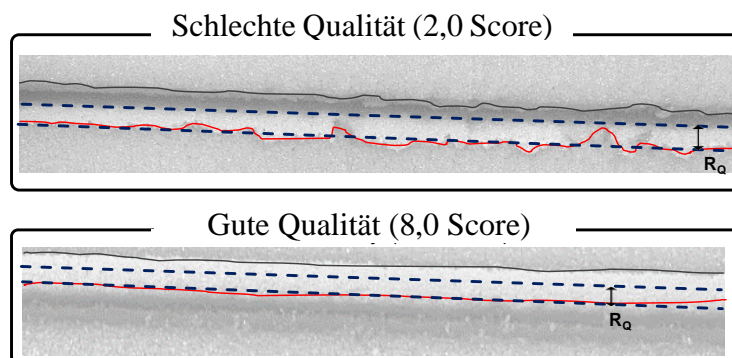


Abbildung 5: Bewertung der resultierenden Fräsqualität

Rohdaten wie u.a. der Zeitstempel, die XYZ-Position, die Spindelgeschwindigkeit oder der Vorschub wurden über 10 Durchläufe der in Abb. 4 dargestellten Testgeometrie aufgenommen bzw. hieraus berechnet. Auf dieser Datenbasis wurden insgesamt sechs verschiedene Machine Learning-Ansätze evaluiert - drei ANN-Konfigurationen (Artificial Neural Network), ein Entscheidungsbaummodell, ein Random-Forest-Modell und ein Ensemble-Learning-Modell. Die drei unterschiedlichen ANN's haben zwar die Gemeinsamkeit, dass ein dreischichtiger Ansatz mit 300 Neuronen verwendet wurde, die Aktivierungsfunktion unterscheidet sich jedoch voneinander. Das erste ANN-Modell verwendet eine sigmoide Aktivierungsfunktion, das zweite Modell eine rectified linear unit (ReLU) und das dritte Modell verwendet den hyperbolischen Tangens (Tanh) als Aktivierungsfunktion. Das Entscheidungsbaummodell wurde mit den Standardeinstellungen und einer maximalen Tiefe von 12 konfiguriert. Ensemble-Learning kombiniert mehrere Ansätze in einem einzigen Modell, indem ANN (sigmoid), Entscheidungsbaum, Gradientenverstärkung und lineare Regression kombiniert werden. Dieser Ansatz wählt die beste Technik während des Trainings als „Elite-Lernenden“ aus, bewertet diese Technik dann separat und gibt den Durchschnitt ihrer Ergebnisse aus.

Die Modelle wurden durch eine zufällig gewählte Auftrennung in Trainings- und Validierungsdaten bewertet, d.h. 80 % der Daten wurden für das Training der verschiedenen Ansätze und die restlichen 20 % für deren Validierung verwendet. Als Bewertungskriterien wurden die Wurzel der mittleren Fehlerquadratsumme (Root-Mean-Square-Error, RMSE) und das Bestimmtheitsmaß (R^2) gewählt. In der nachfolgenden Tabelle 3 sind diese Bewertungskriterien und die optimalen (d.h. Qualitäts-Score größer als 8) Parameterbereiche für jedes Modell aufgeführt.

Tabelle 3: Modellevaluation und Darstellung der optimalen Parameterbereiche

Machine Learning Ansatz	RMSE	R^2	Vorschub [mm/min]	Schnittgeschwindigkeit [mm/min]
ANN - Sigmoid	1,5750	0,3776	0-25000	500- 1500
ANN - ReLu	1,5571	0,2816	9000	1200
ANN – Tanh	1,5879	0,1087	7000-11000	1000-1300
Decision Tree	1,6225	0,0887	10000-20000	900-1100
Random Forest	1,3457	0,1888	8000-20000	300-1500
Ensemble	1,5548	0,2050	10000-20000	400-1500

Die optimalen Parameter bezüglich der Qualität des Fräsergebnisses wurden bei einem Vorschub von 9000 mm/min und einer Schnittgeschwindigkeit von 1200 mm/min identifiziert. Der für diese Testreihe am besten geeignete Machine-Learning-Modelltyp war der ANN-Ansatz, da alle zugehörigen Modelle zu kleinen, optimierten Parameterbereichen führten. Die genauesten Ergebnisse wurden von einem ANN-Modell mit einer ReLu-Aktivierungsfunktion vorhergesagt, weshalb dieses für den in der Studie verwendeten Datensatz als bevorzugter Modelltyp zu verwenden ist.

Aufgrund des zeitlichen beschränkten Projektrahmens war es nicht möglich, die real aufgenommenen Versuchsdaten bzw. Rauheitswerte mit denen aus Simulationsbildern zu vergleichen. In Kombination mit den in Kapitel 2.1 beschriebenen konnte dennoch eine Methodik aufgezeigt werden, die einerseits die Wahl des Trainingmodells und andererseits die für das Training notwendige Datenbasis erheblich vereinfacht und somit auch für KMUs zugänglich bzw. wirtschaftlich sinnvoll macht.

3 Verbreitung der Projektergebnisse

Um das Projekt „SimKI“ und dessen Projektergebnisse weitreichend sichtbar zu machen, wurden die Verbreitungsaktivitäten anhand dreier Zielgruppen strukturiert: potentielle Kunden bzw. Endnutzer, Wissenschaft und zukünftige Akteure. Für jede Zielgruppe bedarf es einer adäquaten Aufbereitung und Detaillierung der Resultate, weshalb diese im Folgenden separat aufgelistet werden.

Tabelle 4: Auflistung der Verbreitungsaktivitäten im Projekt „SimKI“

Zielgruppe	Titel	Art der Veröffentlichung	Veröffentlicht durch/in
Wissenschaft	Machine Learning of Parameters for Structural PET Foam Milling	Conference Paper (peer reviewed)	54th CIRP Conference on Manufacturing Systems
Wissenschaft	Real-time data acquisition and forming process control using AI trained with simulation datasets	Conference Paper (peer reviewed)	54th CIRP Conference on Manufacturing Systems
Kunde/Endnutzer	Mit ThingWorx, Simulation und KI - Maschineneinfahrzeiten reduzieren	Online Artikel	INNEO
Kunde/Endnutzer	Maschineneinfahrzeiten reduzieren mit ThingWorx, Simulation und KI	Online Artikel	BigData-Insider
Kunde/Endnutzer	Maschineneinfahrzeiten reduzieren mit ThingWorx, Simulation und KI	Online Artikel	Industry of Things
Kunde/Endnutzer	Inneo, Gaugler & Lutz, PTC: KI + IoT = reduzierte Einfahrzeit	Online Artikel	EngineeringSpot
Kunde/Endnutzer	SimKI macht kleine Unternehmen wettbewerbsfähig	Artikel	Limes 2/2020
Kunde/Endnutzer	Künstliche Intelligenz: wie der Mittelstand profitiert	Online Artikel	Konstruktion & Entwicklung
Kunde/Endnutzer	Schneller, besser, billiger: KI-Simulationen sparen Zulieferern viel Zeit und Material beim Einfahren von Maschinen	Online Artikel	Wirtschaft digital Ba-Wü

Zukünftige Akteure	Digitalisierung eines manuellen Umformprozesses zur Integration in IoT Anwendungen	Abschlussarbeit	HS Aalen (S. Bohn)
Zukünftige Akteure	Simulation eines digitalen Zwillings anhand eines Umformprozesses	Abschlussarbeit	HS Aalen (P. Blum)
Zukünftige Akteure	Prozesssimulation eines smarten Umformwerkzeugs zur Kommunikation mit einem machine learning System	Abschlussarbeit	HS Aalen (N. Eberhardt)
Zukünftige Akteure	Entwicklung eines Digitalen Zwillings eines Bearbeitungszentrums	Abschlussarbeit	HS Aalen (A. Gül)
Zukünftige Akteure	Entwicklung eines Lösungsansatzes zur Ermittlung von Bearbeitungsparametern neuartiger Werkstoffe mithilfe einer IoT - Plattform	Abschlussarbeit	INNEO (M. Haas)
Zukünftige Akteure	Aufbau einer Messzelle zur Echtzeit-Qualitätsüberwachung mit einem kollaborativen Roboter	Abschlussarbeit	HS Aalen (T. Huu Tho)
Zukünftige Akteure	Aufbau einer intelligenten Messzelle zur Echtzeit-Qualitätssicherung	Abschlussarbeit	HS Aalen (R. Esslinger)
Zukünftige Akteure	Applikation einer KI-basierten Echtzeitanalyse von Umformbauteilen unter Verwendung eines perzeptionsbasierten Verfahrens	Abschlussarbeit	HS Aalen (F. Rettenmaier)
Zukünftige Akteure	Implementierung einer KI-Basierten Qualitätssicherung in eine industrielle Produktionsumgebung	Abschlussarbeit	INNEO (L. Rief)

Bei der in Tabelle 4 dargestellten Auflistung gilt, dass einzelne Verbreitungsaktivitäten wie z.B. die Präsenz bei Konferenzen für mehrere Zielgruppen geeignet sind, jedoch nur die Hauptgruppe genannt wurde. Ein besonderes Augenmerk gilt darüber hinaus der Zielgruppe „zukünftige Akteure“, da die im Projekt „SimKI“ durchgeführten Abschlussarbeiten für sowohl Erfahrung als auch Wissen bei den Studierenden sorgen, welche diese dann in ihrem zukünftigen Tätigkeitsfeld einbringen und somit die gewonnenen Projekterkenntnisse streuen bzw. diskutieren.

4 Kommerzielle Verwertung

Die Ergebnisse des Forschungsprojektes „SimKI“ zeigen zunächst, dass Werkzeugmaschinen Daten einen hohen Nutzen haben und vielseitig eingesetzt werden können – unabhängig davon, ob diese bereits vorhanden sind oder via Retrofit verfügbar gemacht werden müssen. Die Werkzeugmaschinen lassen sich mit entsprechenden Tools vernetzen und die erfassten Daten sind zuverlässig, genau bzw. mit einer hohen Abtastrate verfügbar. Ein kommerzielles Verwertungsszenario liegt beispielsweise bei KMUs, die ihre Prozessparameter nicht auswerten oder anlagenseitig erst gar nicht erfassen. Der Projektpartner INNEO Solutions kann hier bei der Sensorauswahl beraten und Software-Lösungen zur Datenerfassung, -aufbereitung, -analyse und -darstellung anbieten. Der Transfer der erzielten Ergebnisse auf weitere Anwendungen kann in verschiedene Kategorien untergliedert werden:

- Geringer Transferaufwand bei gleichem Produktionsprozess und Maschinentyp: der Transfer auf ähnlich geartete Werkzeugmaschinen mit einem vergleichbaren Prozessverhalten und Variablen, die dieses Verhalten beschreiben, ist gering. Die Logik der Achsen bleibt hierbei identisch.
- Mittlerer Transferaufwand im Falle des gleichen Produktionsprozesses mit abweichenden Maschinenkonfigurationen: der Ergebnistransfer ist durch die Anpassung der Logik, der abweichenden Variablen und der erfassten physikalischen Größen charakterisiert.
- Hoher Transferaufwand: das im Forschungsprojekt erarbeitete Vorgehen ist prinzipiell für alle CNC-Fräsprozesse und Umformoperationen geeignet. Bei abweichenden Produktionsprozessen gestaltet sich die Übertragbarkeit der Ergebnisse aufwändiger, da eine nahezu vollständig überarbeitete Logik implementiert werden muss.

Die Höhe des Transferaufwandes der Forschungsergebnisse geht einher mit dem Reifegrad des angebotenen Produktes. Im einfachsten Fall können die erarbeiteten Ergebnisse direkt als Produkt an Kunden angeboten werden. Mit zunehmendem Transferaufwand erhöht sich die kundenindividuelle Anpassung. Der Transfer weist dann weniger Produktcharakter und mehr Anteile von Consulting auf.

Die kommerzielle Verwertung des Projektes wird anwendungsseitig durch die Konsortialpartner Karl Walter sowie Gaugler & Lutz sichergestellt. Letzterer kann durch die dargestellte Methodik schnell sowie zuverlässig die optimalen Schnittparameter auch für unbekannte Werkstoffe ermitteln und so Bearbeitungszeiten verringern bzw. die Produktqualität erhöhen. Der KMU Karl Walter kann die Erkenntnisse aus der Herstellung smarter Presswerkzeuge auf weitere Produkte seines Portfolios wie z.B. Formen für Gussteile erweitern und somit kommerziell nutzbar machen.