

Detektion von Anomalien zur Qualitätssicherung basierend auf Sequence-to-Sequence LSTM Netzen

Anomaly detection for quality control based on sequence-to-sequence LSTM networks

Benjamin Lindemann, Nasser Jazdi und Michael Weyrich

Abstract

Unvorhersehbare Prozessereignisse und Anomalien sind Treiber erhöhter Ineffizienzen in Form von schwankender Produktqualität. In diesem Beitrag wird ein datengetriebener Ansatz zur Qualitätsoptimierung vorgestellt, auf dessen Basis Anomalien charakterisiert werden, die zur Entwurfszeit des Systems nicht bekannt waren. Es wird eine Netzarchitektur in Form eines Sequence-to-Sequence Netzes mit Long Short-Term Memory (LSTM) Zellen vorgestellt. Dadurch kann vorhergesagt werden, welche Anpassung am Stellgrößenverhalten vorgenommen werden muss, um erwartete Anomalien zu kompensieren. Dadurch wird das Qualitätsergebnis langfristig in der Toleranz gehalten. Der Ansatz wird prototypisch anhand von zwei Prozessketten der diskreten Fertigung umgesetzt und evaluiert.

Unforeseeable process events and anomalies are drivers of increased inefficiencies in terms of fluctuating product quality. This paper presents a data-driven approach for quality optimization that is used to characterize anomalies being unknown at the time the system was designed. A network architecture based on a sequence-to-sequence network with Long Short-Term Memory (LSTM) cells is presented. Thus, it can be predicted which adaptation of the actuating variables has to be carried out in order to compensate expected anomalies. This keeps the quality result within tolerance. The approach is prototypically implemented and evaluated on the basis of two process chains of discrete manufacturing.

Schlagwörter: *Künstliche Intelligenz, LSTM Netze, Anomalie-Detektion, Qualitätssicherung, Cyber-Physische Produktionssysteme*

Keywords: *Artificial intelligence, LSTM networks, anomaly detection, quality control, cyber-physical production systems*

1. Einleitung

Prozessanomalien in Form von unbekanntem nichtlinearen Effekten sind ursächlich für Qualitätsschwankungen und Ausschussteile in der diskreten Fertigung. Das Prozessverhalten ist hochgradig nichtlinear und kann u.a. aufgrund seiner zeitlichen und örtlichen Verteilung nicht in einem analytischen Modell gefasst werden. Aus diesem Grund wird ein datengetriebenes Verfahren entwickelt, um Anomalien in Form von Modellunsicherheiten und unbekanntem Nichtlinearitäten zu kompensieren. Die Kompensation wird durch ein Neuronales Netz realisiert. Auf die entwickelte Architektur des Neuronalen Netzes wird im Detail eingegangen. Es generiert ein Signal zur Anpassung der Stellgrößen, sodass diese so geändert werden, dass der Einfluss der Anomalien auf das Qualitätsergebnis des Prozesses ausgeglichen wird und die Qualität länger in der Toleranz gehalten werden kann.

In Kapitel 2 wird der Stand der Technik und Forschung beschrieben. Dabei werden vor allem bereits bestehende Ansätze hinsichtlich des Einsatzes Neuronaler Netze reflektiert. In Kapitel 3 wird eine formale Beschreibung der Prozesskette als Ganzes sowie der Prozesse im Einzelnen vorgenommen. Dazu wird die nichtlineare Systembeschreibung um Interdependenzen entlang der Prozesskette erweitert. Kapitel 4 widmet sich dem Konzept zur Prädiktion und Kompensation dynamischer Anomalien. Dabei wird zunächst der grundlegende Ansatz erläutert, bevor die dafür entwickelte Netzarchitektur vorgestellt wird. Diese wird dann zur Erzeugung der Kompensation in den geschlossenen Regelkreis zur Qualitätssicherung integriert. In Kapitel 5 wird auf die Prozessketten zur Evaluierung eingegangen, bevor dann die empirischen Ergebnisse präsentiert werden. In Kapitel 6 erfolgen eine Zusammenfassung und ein Ausblick.

2. Stand der Technik und Forschung

Neuronale Netze in der Qualitätssicherung

Neuronale Netze wurden bereits in diversen Strukturen in Regelungen und zur Sicherung der Qualität in industriellen Fertigungsprozessen eingesetzt [1][2][3]. Die auf radialen Basisfunktionen basierenden General

Regression Neural Networks (GRNN) haben sich als äußerst geeignet für die Abbildung statischer, nichtlinearer Zusammenhänge erwiesen. Die Approximation von zeitinvarianten oder periodischen Nichtlinearitäten kann wesentlich zu einer verbesserten Unterdrückung von nichtlinearen Störungen beitragen. Das periodische Einwirken einer Unrundheit im Antriebssystem in [4] sei als Beispiel angeführt. Ein Vorteil von GRNN ist deren Approximationsgüte, die es erlaubt, die Netze strukturell einfach zu halten und mit lediglich einer verdeckten Schicht zu betreiben. Dadurch lässt sich die Stabilität des Lernvorganges nach Lyapunov bei einschichtigen Netzen verhältnismäßig aufwandsarm nachweisen [5]. Ein wesentlicher Nachteil ist hingegen der Umstand, dass GRNN keine zeitvarianten Zusammenhänge im Sinne nicht-periodischer Zusammenhänge abbilden können.

Rekurrente Neuronale Netze (RNN) sind hingegen in der Lage, zeitvariante Zusammenhänge zu erlernen. Die Struktur der Rekurrenzen repräsentiert in gewisser Weise die Funktionalität des Gedächtnisverhaltens und hat Einfluss darauf, welche vergangenen Informationen in welchem Ausmaß für die aktuelle Ausgabe von Bedeutung sind. In [6] und [3] wurde jeweils ein RNN zum Erlernen des Modells der Regelstrecke in Form eines Neuronalen Beobachters eingesetzt. Es handelt sich dabei um ein Beispiel aus der Flugregelung und dessen Adaption auf die Regelung eines Fertigungsprozesses. RNN haben somit den Vorteil komplexe, zeitvariante Zusammenhänge erlernen zu können. Sie können wie in [8] dargelegt bspw. zum direkten Erlernen und Lösen von zeitvarianten, nichtlinearen Differentialgleichungen eingesetzt werden. Nachteilig wirkt sich bei den genannten Beispielen das als Vanishing-Gradient-Effekt bekannte Gewichtungsproblem zeitlich weit zurückliegender Informationen aus. Dadurch wird ein Vergessen von Zusammenhängen, die für das Reagieren auf Störungen relevant sind, möglich.

Long Short-Term Memory und Netzarchitekturen

In [9] wurde mit der Einführung der LSTM Zelle eine definierte Gedächtnisstruktur für RNN geschaffen, um den Vanishing-Gradient-Effekt zu verhindern. Eine LSTM Zelle zeichnet sich durch multiple Ein- und Ausgänge und Verknüpfungen innerhalb des Neurons aus (den Gates). Neben dem konventionellen Eingang, der Rückkopplung und dem Ausgang, verfügt die LSTM Zelle über einen weiteren Ein- sowie Ausgang, über die sie eine Zustandstransformation auf Basis der an den bereits bestehenden Schnittstellen anliegenden Signale durchführt. Dadurch wird ein konkreter Zellenzustand definiert und mit jedem Lernschritt propagiert. Für eine mathematische Beschreibung wird auf die Fachliteratur verwiesen [9]. Der wesentliche Vorteil von LSTM besteht darin, dass zeitvariante Informationen verarbeitet und negative Gedächtniseffekte vermieden werden können.

Rekurrente Netze können, ob mit LSTM Zellen oder ohne, in verschiedenen Architekturen zur Vorhersage genutzt werden. Diese unterscheiden sich in der Struktur ihrer Ein- und Ausgaben. So kann ein einzelner Eingabevektor in eine Ausgabebequenz (one-to-many) sowie eine Eingabebequenz in einen einzelnen Ausgabevektor (many-to-one) überführt werden. Eine Eingabebequenz kann darüber hinaus während des Einlesens ohne Zeitverzug (many-to-many) sowie mit einem definierten Zeitverzug nach dem Einlesen in Encoder-Decoder-Architektur (sequence-to-sequence) in eine Ausgabebequenz übersetzt werden. Dies ist in Bild 1 visualisiert [10]. Übertragen auf Prozessparameter, könnte bspw. der aktuelle Pumpenzustand einer Presse eingelesen und daraufhin eine Vorhersage des Verlaufs getroffen werden. Beispiele für den Einsatz von LSTM Netzen zur Identifikation dynamischer Anomalien im Kontext diskreter Fertigungsprozesse liefern [11], [12] sowie [13]. Die Prävention von Anomalien ist Gegenstand der aktuellen Forschung.

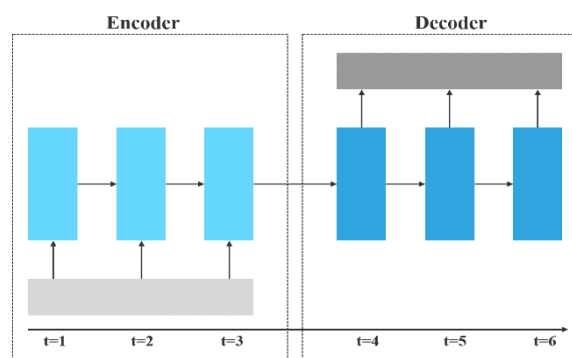


Bild 1: RNN in Sequence-to-Sequence Architektur.

3. Formale Beschreibung der Prozesskette

Im Folgenden wird eine allgemeine formale Beschreibung der Prozesskette sowie der einzelnen Prozessschritte vorgenommen, wie sie dieser Arbeit zugrunde liegen. In der tatsächlichen Anwendung entsprechen diese fertigungstechnischen Prozessen zur Erzeugung von Stahl- und Aluminiumbauteilen. Die Gesamtheit der Prozesskette setzt sich aus einer Abfolge von Einzelprozessen zusammen, die sequentiell zur Herstellung des Endproduktes durchgeführt werden müssen. Die einzelnen Prozessschritte sind über die Produkteigenschaften verknüpft. Dies ergibt sich durch die stetige Weiterverarbeitung bis zum Endprodukt. Die Prozesskette wird in Anlehnung an [14] als azyklischer, gerichteter Graph aufgefasst. Die Prozesskette lässt sich damit wie folgt darstellen: $\Psi(n) = \{P, \Pi(n)\}$, mit P als Menge der Prozesse und $\Pi(n)$ als Menge der Transportwege zwischen

den Prozessen. Der zu einem diskreten Zeitpunkt n die Prozesskette abbildende Graph $\Psi(n)$ liefert durch die Konstellation der Kanten $\Pi(n)$ die einzelnen Prozesse, an denen Stellsignale $\underline{u}(n)$ aufzuschalten sind. Das realisierte System arbeitet mit einer entsprechenden bauteilbezogenen Taktung. Bei den Knoten kann es sich einerseits um analytisch beschreibbare Prozesse deren Physikern bezüglich definierter Qualitätsmetriken bekannt sind sowie andererseits um numerisch abzubildende Prozesse bei denen die physikalischen Zusammenhänge im Hinblick auf Qualitätsschwankungen nicht vollständig bekannt sind handeln. Bei unbekannter Struktur des Systems kann eine nichtlineare Systembeschreibung des Mehrgrößensystems wie folgt vorgenommen werden:

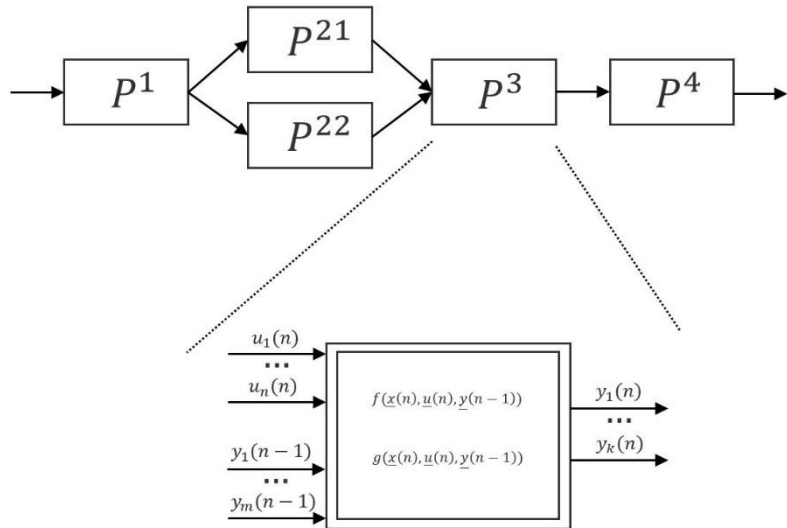


Bild 2: Gerichteter Graph zur Verknüpfung multipler Prozessschritte und Nichtlineare Systembeschreibung der Einzelprozesse.

des Systems kann eine nichtlineare Systembeschreibung des Mehrgrößensystems wie folgt vorgenommen werden:

$$\underline{x}(n+1) = f(\underline{x}(n), \underline{u}(n), \underline{y}(n-1)) + v_x(n)$$

$$\underline{y}(n) = g(\underline{x}(n), \underline{u}(n), \underline{y}(n-1)) + v_y(n)$$

Die Darstellung wurde durch den Ausgang des vorherigen Prozessschritts $\underline{y}(n-1)$ um die Verknüpfung der Prozesse über die Produkteigenschaften erweitert. Bezüglich der Funktionen f und g ist Systemwissen lediglich in Form numerischer Simulationen vorhanden, die nicht zur Quantifizierung der Funktionen im Sinne einer analytischen Systembeschreibung herangezogen werden können. Aus diesem Grund muss bei unbekannter Struktur des Systems eine datengetriebene Approximation dieser Funktionen erfolgen. Die Größen $v_x(n)$ und $v_y(n)$ stellen die Abweichungen von Modellausgabe und tatsächlichem Prozessverhalten dar. In Bild 2 ist exemplarisch ein Graph für eine 4-schrittige Prozesskette mit den beschriebenen Eigenschaften sowie ein Übertragungsglied mit nichtlinearem Übertragungsverhalten dargestellt.

Unbekannte Systemstruktur – Beispiel Umformen

Mittels einer numerischen Simulation werden Daten generiert und darauf aufbauend das initiale Prozessmodell erzeugt. Dieses Vorgehen verbindet Kenntnisse der Anwendung mit passenden Modellformalismen und kommt bei unbekannter Systemstruktur zur Anwendung. Dies gilt insbesondere für geometrische Qualitätsaspekte bei umformtechnischen Fertigungsprozessen. Das Materialverhalten ist hier durch seine räumliche und zeitliche Verteilung sehr komplex und kann daher nicht zum Entwurf eines Reglers verwendet werden. Die initiale Identifikation des Einflusses der einzelnen Stellgrößen auf die zu regelnden Qualitätsparameter wird durch eine systematische Variation der Stellgrößen in der Simulation erreicht. Das Ergebnis wird in einem E/A-Modell gekapselt, bei dem es sich bspw. um ein Regressionsmodell oder eine Netzstruktur handeln kann [15]. Auf Basis dieses initialen Modells kann ein Regler entworfen werden.




Bild 3: Numerische Simulation des Prozesses zur initialen Modellbildung.

Dadurch können die Stellgrößen für jedes zu fertigende Bauteil eingestellt werden, wobei Vereinfachungen in der Simulation, Modellfehler sowie a priori unbekannte Nichtlinearitäten eine zuverlässige Beeinflussung des Prozesses zum optimalen Arbeitspunkt erschweren bzw. verhindern [16]. Ziel des Konzeptes ist es daher, durch eine Kompensation dieser Einflüsse eine verbesserte Regelgüte und eine höhere Qualität des Produkts zu erzielen. In Bild 3 ist das beschriebene Vorgehen zur initialen Modellbildung für einen Umformprozess illustriert.

4. Prädiktion und Kompensation dynamischer Anomalien

Beschreibung des Ansatzes

Der im Folgenden erläuterte Ansatz hat die Prävention von Anomalien zur Reduktion von Qualitätsschwankungen zum Ziel. Dazu soll eine Modifikation der Stellgrößen durch ein Kompensationssignal vorgenommen werden, dass adaptiv während des Betriebs durch ein Neuronales Netz generiert wird. Bild 4 illustriert diese Idee. Es wird wie in Abschnitt 3 beschrieben davon ausgegangen, dass ein initiales Prozessmodell generiert wurde und damit zum Entwurf eines initialen Reglers zur Verfügung steht. Darüber hinaus wird vorausgesetzt, dass dieser initiale Regler bereits entworfen wurde und der geschlossene Regelkreis aus Regelstreckenmodell und Regler stabil ist. Sie konvergieren in ihrem Übertragungsverhalten: $\lim_{t \rightarrow \infty} e(t) = 0$. Die stabile Einstellung des Prozessmodells durch den Regler wird in der Illustration durch die jeweils schwarzen Koordinatenpunkte repräsentiert. Ein Problem fertigungstechnischer Prozesse hinsichtlich der Modellbildung ist der Umstand, dass das Prozessverhalten örtlich und zeitlich variiert sowie hochgradig nichtlinear ist. Ein auf Basis numerischer Simulationen gewonnenes Modell kapselt nicht alle Zusammenhänge adäquat und weist daher Abweichungen zum realen Prozessverhalten auf. Diese durch Modellunsicherheiten bzw. unbekannte Nichtlinearitäten entstehende Diskrepanz aus erwartetem Ausgang y_1 und tatsächlichem Ausgang y_2 wird zur Anpassung der Stellgröße genutzt. Die Stellgröße wird zu u_2 angepasst, sodass auch der reale Prozess den erwarteten Ausgang liefert. Um Anpassungen dieser Art für jedes Bauteil realisieren zu können, wird die gemessene Abweichung e wie in Bild 5 zur Generierung des Lernsignals für ein Neuronales Netz genutzt. Dieses Netz wird darauf trainiert, der Stellgröße das Kompensationssignal q^n aufzuschalten. In diesem Fall wird nicht das tatsächliche Prozessverhalten oder dessen Abweichung zum Modell erlernt, sondern die Kompensation, die aufgebracht werden muss, um eine Abweichung zu vermeiden. Der ursprünglich entworfene Regler kann dadurch unverändert bleiben. Das dargestellte Regelkreisschema orientiert sich an [17] und wurde auf die beschriebene Prozesskette übertragen. Die initial entworfene Regelung wird entsprechend durch die in der Abbildung grün dargestellten Glieder erweitert. Zu verdeutlichen ist an dieser Stelle, dass alle Stellgrößen bauteilbezogen, d.h. mit jedem am Prozess ankommenden Bauteil und damit in diskreter Zeit neu eingestellt werden. Eine Online-Regelung der

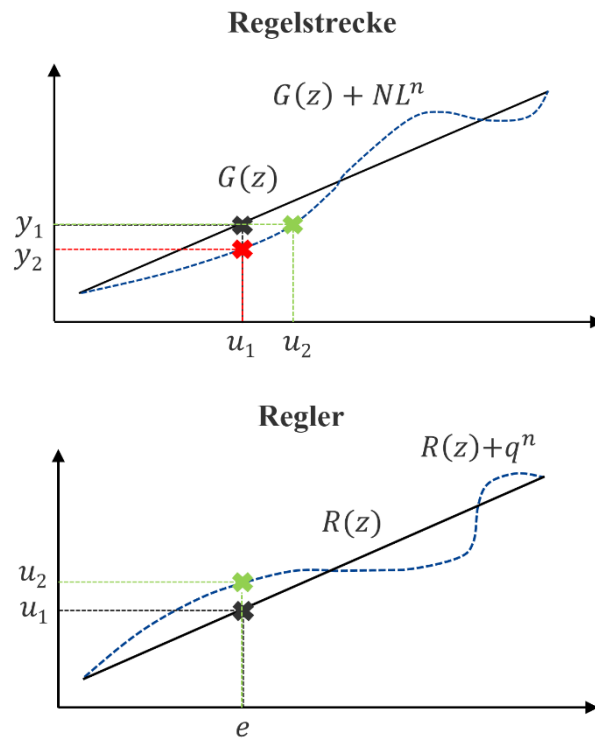


Bild 4: Vereinfachte Darstellung des grundlegenden Ansatzes zur Kompensation von Anomalien.

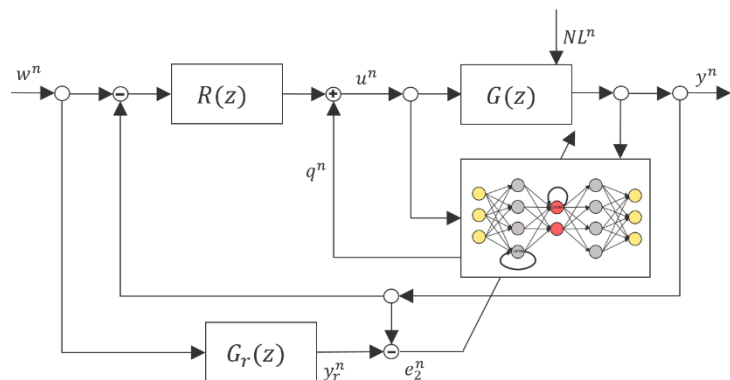


Bild 5: Regelkreisschema mit Neuronalem Netz zur Kompensation.

Qualität während des Prozesses ist nicht vorgesehen. Durch dieses bauteilbezogene Eingreifen sollen bisher unbekannte, die Produktqualität beeinflussende Effekte erlernt und kompensiert.

Entwickelte Netzarchitektur - Prädiktion

Im Folgenden wird die zur Prädiktion und Kompensation entwickelte Neuronale Netzstruktur beschrieben. Zur Erzeugung der Netzeingänge wird eine Diskrete-Wavelet-Transformation (DWT) über die Verläufe der Prozessparameter gebildet, sodass die Daten in einen niederdimensionalen Unterraum projiziert werden. Dies geschieht mit einer definierten Fenstergröße, um eine maximale Reduktion der Datenmenge unter minimalem Informationsverlust zu realisieren. Das Fenster umfasst drei Prozesszyklen, sodass auf abrupte Änderungen von Bauteil zu Bauteil geeignet reagiert werden kann. Die hochfrequenten Koeffizienten der DWT werden verworfen, um eine Rauschunterdrückung zu erreichen. Durch diese Abstraktion der Informationen in den Wavelets erhöht sich die Übertragbarkeit des Ansatzes, da die Netzarchitektur mit abstrakten Features trainiert wird. Zur Dimensionsreduktion wird ein Autoencoder genutzt, der die Koeffizienten der DWT als Eingänge m erhält. Der Autoencoder reduziert diese auf die Anzahl an Neuronen seiner verdeckten Schicht n und versucht diese anschließend möglichst exakt zu rekonstruieren. Dabei gilt: $f: R^m \rightarrow R^n$ mit $m > n$.

Die auf die Neuronen der verdeckten Schicht reduzierten Features werden zur weiteren Verarbeitung im Sequence-to-Sequence Netz genutzt, das zur Vorhersage eingesetzt wird. Das Netz ist in einen den Eingang verarbeitenden Encoder- und einen den Ausgang erzeugenden Decoder-Teil gegliedert und in Bild 6 dargestellt. Dazu werden zwei Netze mit inverser Struktur aufgebaut, um die Gewichte getrennt voneinander trainieren zu können. Der Encoder-Teil verarbeitet die Eingangsdaten und extrahiert abnormales Prozessverhalten. Um sich das abnormale Verhalten „merken“ zu können, wird über das Netz iteriert, bis die Eingangssequenz vollständig im Encoder-Teil verarbeitet wurde. Die Größe des Netzes ist auf die Größe der Eingabesequenz abgestimmt, um ein möglichst gutes Gedächtnisverhalten zu realisieren.




Bild 6: Sequence-to-Sequence Netz zur Prädiktion mit reduzierten Features als Ein- und Ausgänge.

Die Eingangssequenz wird dann in den Decoder-Teil kopiert. Dieser generiert auf Basis des bezüglich der Anomalien erzeugten Gedächtnisverhaltens ein neues Signal zur Vorhersage des erwarteten Ausgangs. Dies ist in der Abbildung anhand eines einfachen Beispiels aus Frage und zu erwartender Antwort dargestellt. Zusätzlich ist an Ein- und Ausgang die Vorhersage von Anomalien am Beispiel realer Zeitreihen aus Abschnitt 5 zu sehen. Die Grundlage des Netzes sind LSTM Zellen, die in der Abbildung grau angedeutet und in Bild 7 a) in ihrem Aufbau detailliert dargestellt sind. Sie erzeugen aus den Eingängen einen Zustand, der mit jedem Zeitschritt propagiert wird. Die Vorhersage geschieht über ein definiertes Zeitintervall wie bspw. einen Tag oder eine Stunde. Deshalb müssen die Zieldaten den entsprechenden zeitlichen Abstand zu den Eingangsdaten besitzen. Durch wiederholtes

Ausführen des Sequence-to-Sequence Netzes kann über größere Zeithorizonte vorhergesagt werden. Es werden die Dimensionsreduktion auf der einen sowie die Unterbindung des Vanishing-Gradient-Effektes auf der anderen Seite in einem Netz zusammengeführt.

Die verwendeten LSTM Zellen zeichnen sich durch eine inverse Verbindung zwischen dem Add- und Forget-Gate aus, um dem unerlässlichen Hinzufügen weiterer Informationen entgegenzuwirken. Der Umstand ist am menschlichen Vorbild orientiert und soll die Begrenztheit des menschlichen Gedächtnisses nachbilden sowie ein reines Auswendiglernen verhindern. Dies ermöglicht es, typische zeitliche Signalmuster zu erlernen und Abweichungen von diesen zu erkennen. Diese Eigenschaften werden für die Abstraktion von Anomalien genutzt. Dadurch ändern sich Netzstruktur und Lerngesetz. Unter Verwendung der Hebb'schen Regel [18] ergibt sich das folgende Lerngesetz:

$$\widehat{W}(n+1) = \widehat{W}(n) + \eta e(\widehat{W}, n) \frac{\partial \hat{y}}{\partial \widehat{W}}(\widehat{W}, n)$$

wobei $\widehat{W}(n+1)$ die angepassten Netzgewichte, $e(\widehat{W}, n)$ den Ausgabefehler und $\frac{\partial \hat{y}}{\partial \widehat{W}}(\widehat{W}, n)$ die Änderung der Ausgabe zum diskreten Zeitpunkt n darstellen. Die Konvergenzgeschwindigkeit wird über die Lernrate η gesteuert. Um das Lerngesetz zu bestimmen, wird zunächst die Änderung der Zellausgänge in Abhängigkeit der Gewichte bestimmt zu:

$$\nabla W(n) = \nabla \underline{c}(n) \otimes [\underline{x}(n) \underline{h}(n-1) \underline{1}]$$

wobei der Einfluss der Zelleingänge in

$$\nabla \underline{c}(n) = \left[\nabla \underline{f}(n) \nabla \underline{i}(n) \nabla \underline{o}(n) \right]^T$$

gekapselt ist. Am Beispiel des Forget-Gates $\nabla \underline{f}(n)$ soll nun die Abhängigkeit der Gates von den Zelleingängen aufgelöst werden. Dabei ergibt sich durch die inverse Verknüpfung zwischen Add- und Forget-Gate aus der Rückpropagation entlang der LSTM Zellenstruktur folgender Einfluss der Eingänge $\underline{x}(t)$ und $\underline{h}(t-1)$:

$$\nabla \underline{f}(n) = \nabla f(n) \odot \underline{f}(n) \odot (1 - \underline{f}(n))$$

Die Änderung der Netzausgabe des gesamten Netzes, nicht nur einer wie hier beschriebenen einzelnen Zelle, ergibt sich durch Verbinden der einzelnen Netzschichten entlang der Netzstruktur:

$$\frac{\partial \hat{y}}{\partial \widehat{W}_i(n)} = \frac{\partial \hat{y}}{\partial s_i(n)} \frac{\partial s_i(n)}{\partial \widehat{W}_i(n)}$$

Der Summenausgang der Schicht i wird dabei mit $s_i(n)$ bezeichnet. Dadurch kann $\frac{\partial \hat{y}}{\partial \widehat{W}}(\widehat{W}, n)$ für das gesamte Netz bestimmt werden. Das Netz wird mit historischen Daten, die bereits aufgetretene Anomalien enthalten, vortrainiert und getestet. Durch das Vortraining reagiert das Netz in der Anfangsphase des Einsatzes robuster. Im Online-Betrieb findet der weitere Lernvorgang statt. Bei Anomalien ist durch das Sequence-to-Sequence Netz eine Zustandsvorhersage möglich. Eine Vorhersage über einen definierten Zeithorizont ist notwendig, um Qualitätsschwankungen durch eine Anpassung der Stellgrößen zu unterbinden und verschleißende Komponenten trotz evtl. eingeschränkter Funktion länger nutzen zu können.

Um die Vorhersage hinsichtlich des Aspektes zu bewerten, ob es sich dabei um abnormales Prozessverhalten handelt oder nicht, wird diese einem separaten Netz zugeführt. Das dazu verwendete LSTM Netz in Autoencoder-Struktur ist in Bild 7 b) dargestellt. Das Netz wird ausschließlich mit Normal-Daten trainiert. Mit Normal-Daten sind diejenigen Prozessdaten gemeint, die während eines Anlagenbetriebs ohne das Vorhandensein qualitätsrelevanter Einschränkungen aufgenommen wurden. Das Lernsignal wird mittels Rückpropagation des Fehlers durch das LSTM Netz erzeugt. Ausgang des LSTM Netzes sind die betrachteten Qualitätsparameter, deren Abweichungen zu den Sollwerten reduziert werden sollen und für das Training dieser Komponente verwendet werden. Ausgang des Autoencoders sind hingegen die gemessenen Prozessparameter die dem Autoencoder auch in dessen Eingängen zugeführt werden. Der Rekonstruktionsfehler wird hier zum Training genutzt. Er ist ein Maß für die Fähigkeit des Netzes, die Ausgänge aus den Eingängen zu rekonstruieren. Das Netz kapselt alle in den Normal-Daten vorhandenen Zusammenhänge. Die Prädiktion des Sequence-to-Sequence Netzes kann durch dieses nachgelagerte, auf Normal-Daten eintrainierte LSTM Netz beurteilt werden. Dem Netz werden dazu in der

Testphase Normal-Daten sowie Daten mit Anomalien zugeführt. Normal-Daten erzeugen eine Ausgabe, die zu einem niedrigen Rekonstruktionsfehler führt. Treten Anomalien in den Testdaten auf, entsteht ein größerer Rekonstruktionsfehler, da unbekannte Muster zu Fehlern in der Rekonstruktion führen. Der Rekonstruktionsfehler wird daher als Metrik zur Beurteilung der Prädiktion herangezogen.




Bild 7: a) LSTM Netz mit inverser Verknüpfung, b) Einbettung in die Netzarchitektur.

Entwickelte Netzarchitektur - Kompensation

Um diese Lernarchitektur nun zur Prävention von Anomalien nutzen zu können, wird die Erzeugung des Lernsignals in der Form angepasst, dass die durch einen abnormalen Prozessverlauf entstehende Abweichung vom erwarteten Modellausgang als Eingang und das Anpassungssignal als Ausgang des Netzes verwendet werden. Dadurch kann vorhergesagt werden, welche Anpassung am Stellgrößenverhalten vorgenommen werden muss, um erwartete Anomalien zu kompensieren. Die Nutzung des vorgestellten Netzes ist gemäß dem Schema in Bild 8 vorgesehen. Es wird wie bereits in Abbildung 5 dargestellt davon ausgegangen, dass ein Prozessmodell mit Modellunsicherheiten und ein zu diesem unvollständigen Modell entworfener Regler existieren. Aus der Abweichung der Ausgänge von tatsächlicher Regelstrecke und Modell wird das Eingangssignal des Netzes erzeugt. Dies sind Qualitätsparameter wie geometrische, werkstofftechnische oder thermische Werte des diskreten Fertigungsprozesses, die gemäß der zuvor beschriebenen Vorverarbeitung auf abstrakte Features reduziert werden. Die Netzarchitektur wird nun gemäß dem zuvor erläuterten Vorgehen betrieben, mit dem Unterschied, dass ein Kompensationssignal zur Anpassung der Stellgrößen ausgegeben wird. Es werden folglich nicht die Anomalien selbst vorhergesagt, sondern der Anpassungswert, der den Stellgrößen aufgeschaltet werden muss, um eben diese zu unterdrücken bzw. auszugleichen. Das Lernsignal ergibt sich aus der Rückpropagation der Abweichung der Ausgänge von tatsächlicher Regelstrecke y_k^n und Referenzmodell der Führungsgröße $y_{r,k}^n$. Dies führt zu der Abweichung von tatsächlichem Stellgrößenverhalten und demjenigen, dass zur Kompensation der Modellunsicherheiten benötigt worden wäre. Diese rückpropagierende Abweichung wird der Netzarchitektur als Lernsignal zugeführt.

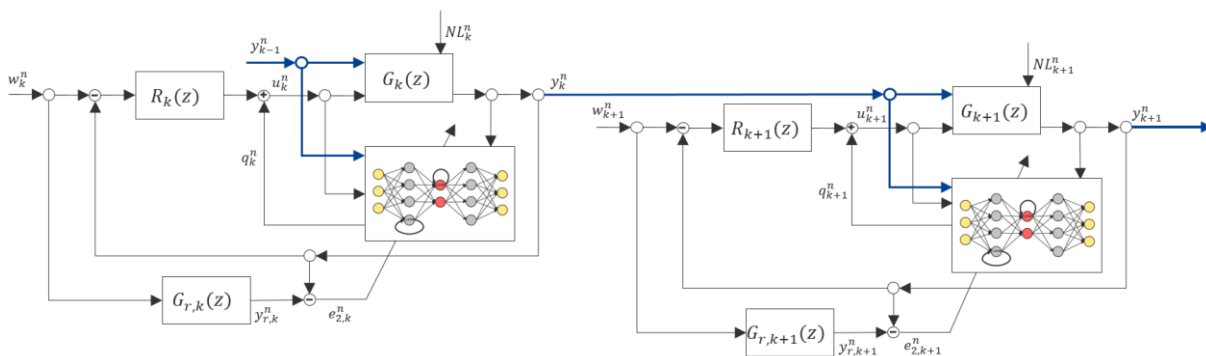


Bild 8: Kompensation dynamischer Nichtlinearitäten durch Neuronale Netzarchitektur über multiple Prozessschritte hinweg.

Aufgrund der Tatsache, dass mehrstufige Prozessketten betrachtet werden, deren Einzelprozesse über ihre Produkteigenschaften verknüpft sind, entsteht ein vermaschtes Gesamtsystem. Die Abhängigkeiten zwischen den Prozessen werden in den Produkteigenschaften gekapselt, da nur über diese eine Verbindung untereinander besteht. Für jeden Prozess k wird zum Qualitätsfehler eine Kompensation erlernt. Der Qualitätsfehler wird aus der Differenz von Prozessausgang und Ausgang der Sollwert-Referenz $G_r(z)$ ermittelt und mit e_2 beschrieben. Das Übertragungsverhalten zur Generierung des Kompensationssignals wird durch die Rückführung des Qualitätsfehlers bestimmt. Daraus ergeben sich die Änderungen an den Stellgrößen, die hätten vorgenommen werden müssen, um den rückgeführten Fehler zu vermeiden bzw. zu minimieren. Die Prädiktion zukünftig zu erwartender Qualitätsfehler führt dann zu einer Sequenz an Stellgrößenanpassungen, die zur Kompensation der zu erwartenden Qualitätsabweichungen für die nächsten Bauteile genutzt werden. Eine minimale Abweichung würde eine maximale Kompensation von Modellunsicherheiten und Nichtlinearitäten sowie eine verbesserte Einhaltung der Qualitätsanforderungen zur Folge haben. Inwiefern dies im realen Prozessumfeld möglich ist, wird in der nachfolgenden Evaluation dargelegt.

5. Evaluation anhand industrieller Prozessketten

Stuttgarter Modellfabrik

Zur Erprobung und Evaluation des Ansatzes stehen zwei Produktionsanlagen zur Verfügung. Bei der ersten handelt es sich um eine Prozesskette mit einem zweistufigen Wärmeschmiedeprozess, die am Institut für Umformtechnik (IfU) der Universität Stuttgart besteht. Die Prozesskette ist auf die Fertigung von Stahlbauteilen ausgelegt. Nach einer Eingangskontrolle der Materialeigenschaften und der Geometrie findet eine induktive Erwärmung statt. Parallel wird auf das Unter- und Obergesenk des Werkzeugs zur Einstellung eines definierten Reibungskoeffizienten ein Sprühmittel aufgebracht. Das Bauteil wird in der Presse verformt und mit einem Laserprofilometer hinsichtlich charakteristischer Qualitätsmerkmale untersucht. Nach der zweiten Iteration erfolgt abschließend die Auslagerung des Bauteils [18]. In Abbildung 9 sind Teile der Prozesskette dargestellt.




Bild 9: a) Hydraulische Presse mit Transporteinheit und induktiver Erwärmungsanlage, b) Werkzeug mit Ober- und Untergesenk, c) Bauteil nach der ersten (links) und der zweiten (rechts) Umformstufe.

In Abbildung 10 a) ist das Konvergenzverhalten abgebildet. Im Rahmen einer Hyperparameteroptimierung wurden Tests bezüglich verschiedener Größen des zugeführten Batchs, bzgl. der Neuronen in den verdeckten Schichten und der Lernrate durchgeführt. Hier wurden 20 Neuronen über zwei Ebenen sowie eine Lernrate von 0.01 verwendet. Abbildung 10 b) zeigt die Prädiktion von in Trainingsdaten vorhandenen Anomalien. Die Anpassung der Stellgrößen ist in Abbildung 10 c) dargestellt. Die grüne Kurve zeigt die vom initialen Regler erzeugten Stellgrößen, die roten Datenpunkte stellen die tatsächlich aufgebrauchten Stellgrößen dar. Die Differenz aus beiden Kurven entspricht der von der Netzarchitektur erzeugten Anpassung. Jeder Punkt entspricht einem diskreten und bauteilbezogenen Eingriff in den Prozess. Aufgetragen sind die Stellgrößen der Einbauräumverstellung, der Werkstückhöhe sowie der Reibzahl, bei denen eine signifikante Auswirkung auf die Qualität gefunden wurde. Die Anpassung während des realen Betriebes zeigt eine Auswirkung auf die Einbauräumverstellung sowie die

Reibzahl. Vor allem der Einbauraum wird zu größeren Werten hin angepasst, was eine Reduktion in der Gratbildung und damit eine Erhöhung der Qualität zur Folge hat.




Bild 10: a) Konvergenz des Netzes bei verschiedenen Einstellparametern, b) Prädiktion des abnormalen Prozessverhaltens in Form des Rekonstruktionsfehlers bei 150 Bauteilen, c) Anpassung der Stellgrößen zur Kompensation von Modellunsicherheiten und auftretenden Nichtlinearitäten.

Otto Fuchs KG

Die zweite Prozesskette ist eine Produktionslinie der Otto Fuchs KG, in der über verschiedene Stationen Felgen für die Automobilindustrie gefertigt werden und die die Evaluierung des Konzeptes im realen industriellen Umfeld erlaubt. Die Produktion der Felgen beginnt mit der Anlieferung, Kontrolle und Partitionierung des Rohmaterials. Transporteinheiten platzieren die Halbzeuge in Aufwärmöfen, in denen diese für die weitere Verarbeitung temperiert werden. Eine Robotereinheit kontrolliert Bauteileigenschaften sowie Temperatur und nimmt gegebenenfalls eine Aussortierung vor. Für den Fall eingehaltener Toleranzen findet in einer 40MN Presse das Schmieden statt. Danach erfolgt eine grobe Oberflächenbehandlung in Form des Bürstens und eine erneute Qualitätsmessung. Das Bauteil durchläuft in einer zweiten Iteration einen weiteren Umformschritt und eine feine Oberflächenbehandlung in Form des Strahlens. Danach wird das Bauteil entgratet, auf Maßhaltigkeit geprüft und gegebenenfalls aussortiert.

In Bild 11 ist eine Auswahl an Ergebnissen illustriert. Auf den historischen Daten der Felgenlinie konnten die Netze bezüglich der Detektion und Prädiktion von Anomalien genutzt werden. Die Evaluierung des Kompensationsverhaltens wird hier in naher Zukunft angestrebt und ist daher noch nicht abgeschlossen. Der Lernvorgang der Netzarchitektur ist in Bild 11 a) veranschaulicht. Die Einstellparameter wurden variiert, um einen möglichst stabilen Lernvorgang zu erreichen. Es werden dabei 400 Neuronen über zwei Ebenen verwendet. Die Lernrate beträgt 0.001. Über die Batches wurde insgesamt 500 Mal iteriert. Die versteckte Schicht des Autoencoders bestimmt die Größe der Ein- und Ausgänge. In diesem Fall sind dies 20 Neuronen für die abstrakten Features. Die Sequenzlänge für die Eingangs- und Zieldaten beträgt 120. Die Lernkurve konvergiert innerhalb einer Trainingszeit von 8 Stunden.




Bild 11: a) Konvergenz des Netzes bei verschiedenen Einstellparametern, b) Prädiktion des Prozessverhaltens in Form des Rekonstruktionsfehlers bei 150 Bauteilen, c) Anpassung der Stellgrößen zur Kompensation von Modellunsicherheiten und auftretenden Nichtlinearitäten.

Die Ergebnisse des LSTM Netzes zur Detektion von Anomalien sind in Abbildung 11 b) dargestellt. Die Häufigkeit des Auftretens eines bestimmten Systemzustands ist gegenüber dem Rekonstruktionsfehler aufgetragen. Es konnte eindeutig zwischen normalem Prozessverhalten (orange) und Anomalien (grün/blau) unterschieden werden. Dabei war es möglich den Verschleißvorgang (grün) bis zum Komponentenausfall (blau) mit Hilfe des Rekonstruktionsfehlers zu beschreiben. Das entworfene LSTM Netz ist damit zur Detektion von Anomalien geeignet. In Abbildung 11 c) ist der für die tatsächlichen Systemausgänge im Zeitintervall von 10 Produktionstagen berechnete Rekonstruktionsfehler (orange) sowie der Rekonstruktionsfehler, der für die im

selben Zeitintervall vorhergesagten Ausgänge (blau) berechnet wurde, dargestellt. Der Rekonstruktionsfehler ist gegenüber der Zeit aufgetragen. Wie zu sehen ist, verfolgt der vorhergesagte Verlauf dem tatsächlichen sehr gut. Die Vorhersage ist ausreichend genau um den Zustand einen Tag im Voraus zu bewerten. Theoretisch müsste der Rekonstruktionsfehler bei fortwährendem Verschleiß stetig steigen. In der Abbildung ist allerdings an den Tagen 1 und 10 ein starker Abfall bzw. Anstieg zu erkennen. Dies ist auf einen Produktwechsel in der Prozesskette zurückzuführen. Produkt B weist dabei einen geringeren Rekonstruktionsfehler auf. Der Verschleißprozess ist hier schwerer zu detektieren. Innerhalb des Abschnitts ist nichtsdestotrotz ein Anstieg des Verschleißes zu erkennen, den das Netz korrekt vorhersagt. Dieser resultiert in einem erhöhten Rekonstruktionsfehler nach dem erneuten Produktwechsel, sodass die isolierte Betrachtung der Abschnitte des Produktes A ebenfalls eine korrekte Prädiktion zeigen. Damit kann im nächsten Schritt analog zu dem bereits im Rahmen der Stuttgarter Modellfabrik realisierten Vorgehen eine Kompensation getestet und evaluiert werden.

6. Zusammenfassung und Ausblick

Anomalien in Form von Modellunsicherheiten und unbekanntem Nichtlinearitäten sind ursächlich für Qualitätsschwankungen in der diskreten Fertigung. Um die Ursachen für Anomalien nicht nur besser zu verstehen, sondern auch besser zu verstehen, wie diese kompensiert werden können, wurde in dieser Arbeit ein Ansatz zum präventiven Ausgleich von abnormalem Prozessverhalten vorgestellt. Dieser basiert auf der Erzeugung einer Kompensation entsprechend der inversen Dynamik der zu erwartenden Anomalie und wird durch eine Neuronale Netzarchitektur realisiert. Diese besteht aus der Komposition eines LSTM Netzes, eines Sequence-to-Sequence Netzes und einer dezidierten Dimensionsreduktion. Das Kompensationssignal wird zur Anpassung der Stellgrößen genutzt und auf diese aufgeschaltet. Der Ansatz wurde an zwei Prozessketten der Umformtechnik getestet und evaluiert. Offene Fragen ergeben sich aus dem theoretischen Nachweis der Stabilität des vorgestellten Netzes sowie im Allgemeinen dem Stabilitätsnachweis von LSTM Netzen im geschlossenen Regelkreis. Darüber hinaus können Untersuchungen zur Generalisierbarkeit und Übertragbarkeit des Ansatzes im Hinblick auf weitere Anwendungen durchgeführt werden.

7. Literatur

- [1] *K. B. Lee, S. Cheon und O. K. Chang*: A convolutional neural network for fault classification and diagnosis in semiconductor manufacturing processes. In: IEEE Transactions of Semiconductor Manufacturing (2017) vol. 30, S. 135-142.
- [2] *T. Wang, H. Gao und J. Qiu*: A Combined Adaptive Neural Network and Nonlinear Model Predictive Control for Multirate Networked Industrial Process Control. In: IEEE Transactions on Neural Networks and Learning Systems (2016) vol. 27, S. 416-425.
- [3] *B. Lindemann, C. Karadogan, N. Jazdi, M. Liewald und M. Weyrich*: Cloud-based Control Approach in Discrete Manufacturing Using a Self-Learning Architecture. In: 3rd IFAC Conference on Embedded Systems, Computational Intelligence and Telematics in Control (2018) vol. 51, Issue 10, S. 163-168.
- [4] *M. Rau*: Nichtlineare modellbasierte prädiktive Regelung auf Basis lernfähiger Zustandsraummodelle. Doktorarbeit, Technische Universität München 2003.
- [5] *D. Schröder und M. Buss*: Intelligente Verfahren – Identifikation und Regelung nichtlinearer Systeme S. 93. 2. erweiterte Auflage, Springer Verlag, Berlin 2017.
- [6] *T. Krüger, P. Schnetter, R. Placzek und P. Vörsmann*: Fault-Tolerant Nonlinear Adaptive Flight Control Using Sliding Mode Online Learning. In: Neural Networks (2012) vol. 32, S. 267–274.
- [7] *S. He, K. Reif und R. Unbehauen*: Multilayer neural networks for solving a class of partial differential equations. In: Neural Networks (2000) vol. 13, S. 385-396.
- [8] *S. Hochreiter und J. Schmidhuber*: Long Short-Term Memory. In: Neural Computation (1997) vol. 8, S. 1735-1780.
- [9] *I. Sutskever, O. Vinyals und Q. V. Le*: Sequence to Sequence Learning with Neural Networks. In: Advances in Neural Information Processing Systems (2014) S. 3104-3112.

- [10] *C. Feng, T. Li und D. Chana*: Multi-level anomaly detection in industrial control systems via package signatures and lstm networks. In: 47th Annual IEEE/IFIP International Conference on Dependable Systems and Networks (2017) S. 261-272.
- [11] *A. Taylor, S. Leblanc und N. Japkowicz*: Anomaly detection in automobile control network data with long short-term memory networks. In: IEEE International Conference on Data Science and Advanced Analytics (2016) S. 130-139.
- [12] *B. Lindemann, F. Fesenmayr, N. Jazdi und M. Weyrich*: Anomaly Detection in Discrete Manufacturing Using Self-Learning Approaches. In: 12th CIRP Conference on Intelligent Computation in Manufacturing Engineering (2018) vol. 79, S. 313-318.
- [13] *J. Tonne*: Robust model predictive control for large-scale manufacturing systems subject to uncertainties. Doktorarbeit, Universität Kassel, 2017. S. 39.
- [14] *B. Endelt und W. Volk*: Designing and iterative learning control algorithm based on process history – using limited post process geometrical information. In: International Deep Drawing Research Group annual conference (2013) S. 69-74.
- [15] *P. Groche et. al.*: Incremental Bulk Metal Forming. In: CIRP Annals - Manufacturing Technology 56 (2) (2007) S. 635-656.
- [16] *G. L. Plett*: Adaptive inverse control of linear and nonlinear systems using dynamical neural networks. In: IEEE Transactions on Neural Networks (2003) vol. 14, S. 360-376.
- [17] *M. Liewald, C. Karadogan, B. Lindemann, N. Jazdi und M. Weyrich*: On the tracking of individual workpieces in hot forging plants. In: CIRP Journal of Manufacturing Science and Technology (2018) vol. 22, S. 116–120.
- [18] *D. O. Hebb*: The Organization of Behavior – a neuropsychological theory. In: Wiley (1949), New York.

Kurzbiographie:



Benjamin Lindemann, M.Sc. ist wissenschaftlicher Mitarbeiter am Institut für Automatisierungstechnik und Softwaresysteme (IAS) der Universität Stuttgart. Hauptarbeitsgebiete: Rekurrente Neuronale Netze zur Qualitätssicherung in der Automatisierungstechnik.

Adresse: Institut für Automatisierungstechnik und Softwaresysteme, Universität Stuttgart, 70569 Stuttgart, Tel.: +49 (0711) 685 67321, Fax: +49 (0711) 685 67302, E-Mail: benjamin.lindemann@ias.uni-stuttgart.de



Dr.-Ing. Nasser Jazdi ist akademischer Oberrat am IAS der Universität Stuttgart. Hauptarbeitsgebiete: Dynamische Berechnung der Zuverlässigkeit automatisierter Systeme, Intelligenz in der Automatisierungstechnik.



Prof. Dr.-Ing. Dr. h. c. Michael Weyrich ist Institutsleiter des IAS der Universität Stuttgart. Hauptarbeitsgebiete: Intelligenz in der Automatisierungstechnik, Autonome Systeme, Absicherung von Automatisierungstechnik, Cyber-Physische Produktionssysteme.