


Themen-Schmöcker

Künstliche Intelligenz



Liebe Leserin,
lieber Leser,

Künstliche Intelligenz ist das Schlagwort der Stunde - niemand, der sich mit Digitalisierung beschäftigt, kommt in der nächsten Zeit an dem Thema vorbei. Das Wissenschaftsjahr 2019 steht in ihrem Zeichen und auch die Bundesregierung hat jüngst eine Strategie zur KI verabschiedet, um die Entwicklung und Anwendung in Deutschland zu fördern.

In zwei kurzweiligen Artikeln möchten wir Ihnen konkrete Anknüpfungspunkte für Industrie und Forschung geben. Ob maschinelles Lernen oder intelligentes Datenmanagement - hinter KI stecken faszinierende Technologien, die großen Nutzen stiften können - von der Entwicklung zum fertigen Produkt und darüber hinaus!

Viel Spaß beim Schmökern wünscht

Das Fraunhofer IEM

#Produktionszustand

Sebastian von Enzberg

Auch produzierende Unternehmen horten wahre Datenschätze. Die Chancen, die sich durch Datenerfassung, -auswertung und -nutzung ergeben, sind enorm.

Erschienen in: NEXT industry (2/2018)

Seite **4**

Engineering Intelligence

*Lukas Bretz, Marc Foullois, Michael Hillebrand
und Ruslan Bernijazov*

KI-Kompetenz wird für Entwicklerinnen und Entwickler immer wichtiger. Engineering Intelligence bringt die Produktentwicklung auf eine neue Stufe der Leistungsfähigkeit.

*Erschienen in: Produktentwicklung Wissen Kompakt /
IT&Production (2018 / 19)*

Seite **10**

Autonome Systeme in der Produktion

*Prof. Roman Dumitrescu,
Dr. Thorsten Westermann, Tommy Falkowski*

Die Konzipierung dieser hochkomplexen Systeme erfordert leistungsfähige Entwicklungsansätze und -methoden, die disziplinübergreifend angewendet werden.


Erschienen in: Industrie 4.0 und Management (34 / 2018)

Seite **14**

#PRODUKTIONS- ZUSTAND

Big Data – das sind Google und Facebook. Ja, aber: Auch produzierende Unternehmen horten wahre Datenschatze. Wo soziale Netzwerke die Likes ihrer Benutzer auswerten, können Fabrikleiter Erkenntnisse aus den Echtzeit-Infos der Fertigungssensoren ziehen. Während Facebook das Benutzerverhalten für zielgerichtete Werbung analysiert, können Unternehmen wichtige Informationen zur Wartung erlernen. Die Chancen, die sich durch Datenerfassung, -auswertung und -nutzung ergeben, sind enorm.

Text: Sebastian von Enzberg; Illustration: Next Industry



E

Ein Blick in heutige Produktionsanlagen: Pro Sekunde entstehen hier Tausende von Informationen. Sensoren messen Geschwindigkeit und Qualität der Fertigung, Steuerungen horten wichtiges Wissen über den Zustand von Maschinen und Anlagen. Ursprünglich haben Unternehmen diese Informationsquellen gezielt für die Automatisierung ihrer Fertigung eingerichtet. Durch die Vernetzung von Maschinen und das Internet der Dinge

Roland Berger errechnet eine Gesamtsumme von 1,25 Billionen Euro, die in der europäischen Industrie durch die Digitalisierung zusätzlich gehoben werden kann.

werden hier inzwischen Datenmengen generiert, die das Volumen jeder anderen Branche übersteigen. Durch intelligente Datenauswertung können Daten in Erkenntnisse überführt werden, die Entscheidungen unterstützen oder sogar Grundlage für automatisierte Handlungen und Optimierungen sein können. Was

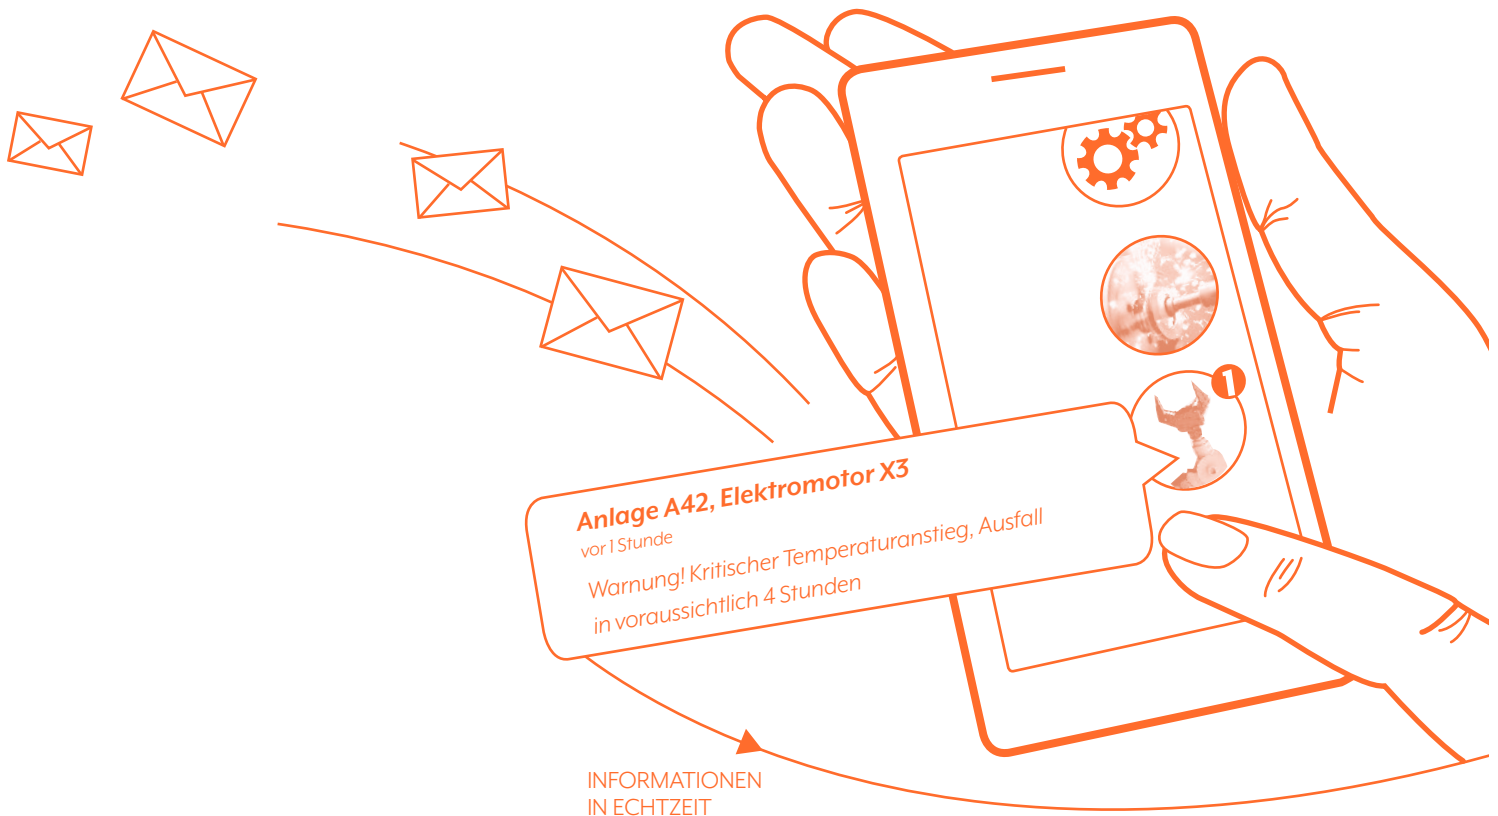
sind die größten Einflussfaktoren auf die Produktivität meiner Fabrik? Wie kann ich Maschinenausfälle vermeiden? Wie kann ich die Qualität meiner Produkte erhöhen? Wie kann ich Energie einsparen? Frost & Sullivan leiten von Big Data Analytics enorme Optimierungspotenziale ab: eine Steigerung der Produktionseffizienz von zehn Prozent, eine Reduktion der Betriebskosten um fast 20 Prozent und eine Reduktion der Instandhaltungskosten um 50 Prozent. Roland Berger

benennt dies mit einer Gesamtsumme von 1,25 Billionen Euro bis 2025, die in Europa durch Digitalisierung in der Industrie zusätzlich gehoben werden können.

Das Bewusstsein vom Wert der Daten wächst also zunehmend. In der IT-Branche ist dies eine Selbstverständlichkeit. Technologieunternehmen wie Google oder Facebook fußen ihr gesamtes Geschäftsmodell auf der intelligenten Datenauswertung und erzeugen jährliche Gewinne von mehreren Milliarden US-Dollar. Big-Data-Methoden sind hier schon lange etabliert, Rechenleistung und Speicher sind erschwinglich, die Fortschritte im maschinellen Lernen sind enorm und Frameworks zur Nutzung dieser Verfahren frei verfügbar. Doch der Einsatz von Big-Data-Methoden ist im Maschinen- und Anlagenbau, insbesondere bei kleinen und mittleren Unternehmen nach wie vor verhalten. Laut einer McKinsey-Studie von 2016 verstehen nur 15 Prozent der Betriebe in der industriellen Fertigung Daten als Teil der Wertschöpfung. In 50 Prozent der Unternehmen bleiben Daten für die Entscheidungsfindung gänzlich ungenutzt.

DER GANZHEITLICHE BLICK

Woran scheitert Big Data also in der industriellen Produktion? Und welche Hindernisse gibt es besonders im Mittelstand? Um diese Fragen zu beantworten, müssen wir über die reine Algorithmik hinausschauen. Industrial Data Science bietet hier eine ganzheitliche Perspektive an. Der Ansatz betrachtet neben den Verfahren zur Datenauswertung auch Datenquellen, Dateninfrastruktur und die darauf aufbauenden Anwendungsfälle. Dieser umfassende Blick ist insbesondere für



kleine und mittlere Unternehmen oft eine Herausforderung, denen es an Budget und Personal fehlt, um beispielsweise eine umfassende, sichere IT-Infrastruktur oder Fachwissen zur Anbindung von Daten aus der Maschinensteuerung aufzubauen. Aber: Es lohnt sich!

Betrachtet man die aktuell typische Dateninfrastruktur in produzierenden Unternehmen, so laufen die Datenquellen in zentralen IT-Systemen zusammen. ERP-Systeme (Enterprise Resource Planning) sind häufig die zentrale Speicher- und Verarbeitungsinstanz für Unternehmensdaten. Sie ermöglichen die Produktionsplanung und -steuerung inklusive aller zugehöriger Ressourcen wie Material, Personal oder Betriebsmittel. Für die tiefere Sammlung und Verarbeitung von Maschinen- und Betriebsdaten kommen meist MES-Systeme (Manufacturing Execution System) ins Spiel. Sie übernehmen die Überwachung und Steuerung einzelner Fertigungsprozesse. ERP und MES sind somit in den meisten Fällen die zentralen Datenspeicher in einem Fertigungsbetrieb. Daneben gibt es eine Vielzahl weiterer, spezialisierter IT-Systeme wie zum Beispiel für die Verwaltung von Kundendaten (CRM-Systeme), von Produktdaten (PLM-Systeme) oder für die Auswertung betrieblicher Daten (Business-Intelligence-Systeme). Diese erfüllen einzelne Teilfunktionen – und stellen gleichzeitig nicht vernetzte Datensilos dar.

Zusammengefasst: Die typische IT-Infrastruktur in der Industrie ist nicht für Big-Data-Auswertungen ausgelegt. Eine Reihe von Initiativen wie Big Data Europe oder Fiware beginnen zwar Lösungen zu erarbeiten, die eine zentrale Speicherung und Verarbeitung bieten. Bis zur breiten Akzeptanz und Verfügbarkeit ist es jedoch noch ein weiter Weg. Aspekte der Datensicherheit oder Zugriffsrechte auf Datenquellen werden von vielen Unternehmen skeptisch beäugt.

Eine weitere Hürde: Typische Anwendungsfälle für die Datenauswertung sind im industriellen Umfeld sehr heterogen – es mangelt also an eingängigen Best Practices. Szenarien finden sich in den verschiedensten Funktionsbereichen, wie Entwicklung, Fertigung, Marketing oder Vertrieb. Aber auch innerhalb der Bereiche gibt es eine Vielzahl von Use Cases. So können in der Fertigung der Zustand einzelner Maschinen beobachtet (Condition Monitoring) oder Ausfälle vor-

hergesagt werden (Predictive Maintenance). Gleichzeitig ist es auch möglich, den Fertigungsprozess zu überwachen (Process Monitoring) oder zu optimieren (Process Optimization). Die verschiedenen Anwendungsfälle

erfordern eine jeweils unterschiedliche Herangehensweise bei der Datenauswertung, die nicht nur von Branche zu Branche unterschiedlich ist, sondern auch immer von Produkt und Maschine abhängt. Für einzelne Anwendungsfälle (z. B. Predictive

Maintenance) gibt es schon Softwarelösungen, diese sind aber entweder auf einzelne Hersteller oder bestimmte Szenarien beschränkt oder erfordern eine hohe Anpassung der Algorithmen.

Die typische IT-Infrastruktur in der Industrie ist nicht für Big-Data-Auswertungen angelegt.

BIG DATA IN DER FERTIGUNG

Unternehmen müssen folglich ihre Big-Data-Strategie individuell entwickeln. Dies widerspricht zunächst der Vorstellung einer automatisierten Datenauswertung, wie wir sie durch maschinelle Lernverfahren wie zum Beispiel künstliche neuronale Netze erwarten: Können intelligente Algorithmen nicht selbstständig Lösungen finden, wenn wir sie bloß mit ausreichend Daten füttern?

Die Antwort auf diese Frage erhalten wir, wenn wir uns Fertigungsdaten genauer ansehen. Für die Charakterisierung haben sich die „fünf Vs“ etabliert (siehe auch S. 14). Der Fertigungsprozess sollte möglichst beherrschbar sein und konstant und gleichbleibend verlaufen. Für maschinelle Lernverfahren ist dies aber ungünstig, denn gerade anhand schwankender Daten können Zusammenhänge erlernt werden. Soll beispielsweise künftig ein Maschinenausfall automatisch erkannt werden, so muss dieser in den Lerndaten ersichtlich sein – und darf nicht durch eine Instandhaltungsmaßnahme verhindert werden. Sonst können im Wesent-

FEHLER-
PROTOKOLL

ZENTRALE
PRODUKTIONS-
INTELLIGENZ

DAS POTENZIAL



Quelle: Frost & Sullivan

**LAUT MCKINSEY (2016)
VERSTEHEN NUR 15 % DER
BETRIEBE IN DER INDUSTRIEL-
LEN FERTIGUNG DATEN ALS
TEIL DER WERTSCHÖPFUNG.**

*Danke für die
schnelle Info.
Wartungsdienst
unterwegs,
Produktion wird
in 1 Stunde ange-
halten.*

lichen nur Normalzustände „auswendig gelernt“ werden (sogenanntes „overfitting“) und keine echten Zusammenhänge.

Weiterhin ist die Datenqualität (Validity) oft nicht ausreichend. Das betrifft insbesondere Annotationen, die durch den Menschen gemacht wurden – diese sind entweder unpräzise oder unstrukturiert. So werden zum Beispiel Wartungsvorfälle selten auf die Sekunde genau dokumentiert, Ausfallursachen oft als variierender Freitext festgehalten oder eine Sichtprüfung stark subjektiv bewertet. Gerade dies sind aber meist die wertvollen Zielgrößen, anhand derer eine möglichst präzise Vorhersage, eine genaue Diagnose oder eine objektivierte Einschätzung erlernt werden soll. Insgesamt schränkt dies die Robustheit datengetriebener Verfahren ein, denn diese steht und fällt mit den genannten Eigenschaften der verfügbaren Datenquellen.

Zuletzt wird Big Data durch den unternehmerischen Wert (Value) charakterisiert. Dieser kann jedoch erst nach erfolgreicher Umsetzung ermittelt werden. Der Lackdrahtspezialist Schwering und Hasse und Jowat SE, Hersteller von Klebstofflösungen, standen vor eben skizzierten Herausforderungen. Mit Ansätzen des Industrial Data Science gelang es, je einen eigenen Weg zu finden, um Big Data sinnvoll zu nutzen.

AUS DER PRAXIS

Die Firma Schwering und Hasse stellt Lackdrähte für die elektrotechnische Industrie her. Diese kommen zum Beispiel in Elektromotoren oder Transformatoren zum Einsatz. Die Herstellung von Lackdrähten ist ein kontinuierlicher Fertigungsprozess, bei dem ein Rohdraht auf einen geforderten Querschnitt gebracht wird und durch Aufbringung eines Lacks elektrisch isoliert wird. Der Draht wird mit hohen Geschwindigkeiten und kontinuierlich – auf Rollen von mehreren Kilometern Länge – verarbeitet. Während der Verarbeitung können nur wenige Qualitätsmerkmale online überwacht werden, weshalb Qualitätskontrollen offline notwendig sind. Das unternehmenseigene Labor untersucht Stichproben zerstörend auf verschiedenste mechanische, elektrische und Materialeigenschaften hin.

Die Entnahme erfordert eine Unterbrechung des Prozesses, was das Erreichen einer möglichst hohen Basislänge verhindert. Andererseits muss die Qualitätsprüfung häufig genug stattfinden, da im Fehlerfall sämtliche gefertigten Drähte zwischen zwei Qualitätsprüfungen aufwendig untersucht werden müssen.

CHANGE-MANAGEMENT

Unternehmensweite Datenstrategie

Der Aufbau einer unternehmensweiten Datenstrategie kann nur unter Einbeziehung aller betroffenen Abteilungen gelingen. Grob vereinfacht erfolgt dieser in vier Schritten:

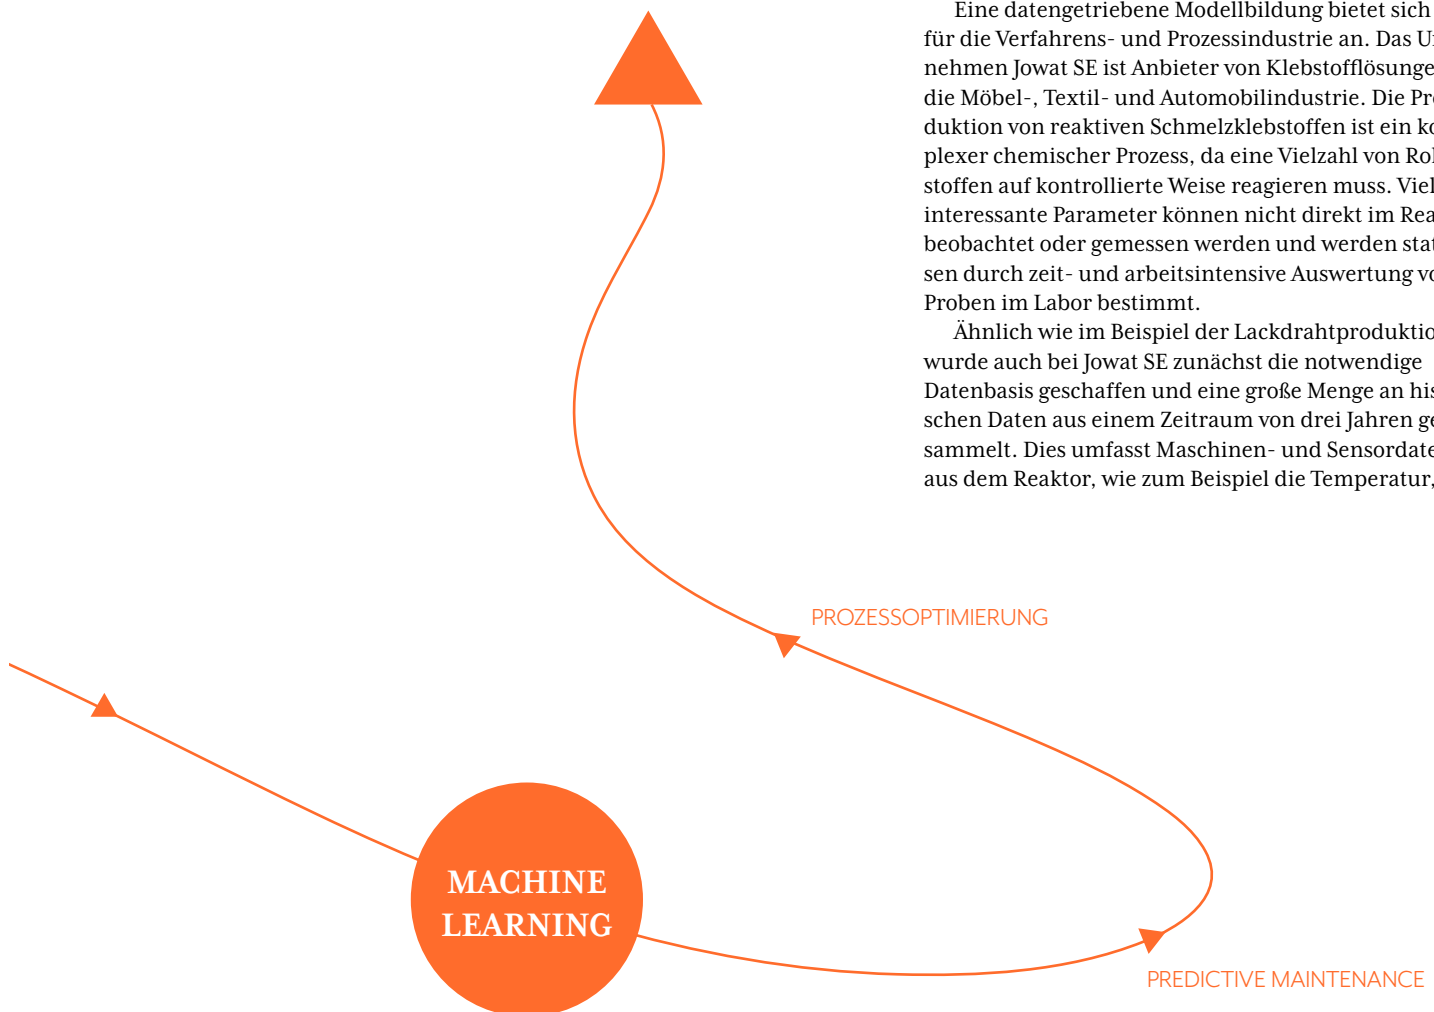
- Datenakquise- und Retrofitstrategie (Datenquellen identifizieren und nutzbar machen)
- Data Governance & Infrastrukturstrategie (sichere Datenverarbeitung)
- Analyticsstrategie (geeignete KI-Verfahren finden und testen)
- Anwendungsstrategie (Erkenntnisse umsetzen)

Die Basislänge wird üblicherweise als Erfahrungswert eingestellt und bei Bedarf angepasst. In einem Transferprojekt wurde die datengetriebene Optimierung der Basislänge untersucht. Das Ziel: Die Häufigkeit von Qualitätsprüfungen sollte abhängig vom gefertigten Produkt und auf Grundlage aktueller Produktionsdaten individuell und bestenfalls dynamisch angepasst werden.

Dazu sammelte Schwering und Hasse historische Daten aus über zwei Jahren Produktion und von hundert verschiedenen Produkten, bereitete sie auf und analysierte sie. Daraus entstand ein datenbasiertes Kostenmodell, um den hypothetischen Ausschuss bei verschiedenen Produktions- und Prüfparametern zu simulieren. So konnte der Lackdrahtspezialist die Auswirkung verschiedener Prüfzyklen bewerten und eine optimale Prüfhäufigkeit berechnen. Ergebnis des Big-Data-Projekts ist die optimale Nutzung der Kapazitäten seiner Prüflabore sowie die Minimierung von Ausschuss und Nachprüfungen. Mit der ermittelten Strategie kann Schwering und Hasse seinen Ausschuss um bis zu 14 Prozent reduzieren.

Eine datengetriebene Modellbildung bietet sich auch für die Verfahrens- und Prozessindustrie an. Das Unternehmen Jowat SE ist Anbieter von Klebstofflösungen für die Möbel-, Textil- und Automobilindustrie. Die Produktion von reaktiven Schmelzklebstoffen ist ein komplexer chemischer Prozess, da eine Vielzahl von Rohstoffen auf kontrollierte Weise reagieren muss. Viele interessante Parameter können nicht direkt im Reaktor beobachtet oder gemessen werden und werden stattdessen durch zeit- und arbeitsintensive Auswertung von Proben im Labor bestimmt.

Ähnlich wie im Beispiel der Lackdrahtproduktion wurde auch bei Jowat SE zunächst die notwendige Datenbasis geschaffen und eine große Menge an historischen Daten aus einem Zeitraum von drei Jahren gesammelt. Dies umfasst Maschinen- und Sensordaten aus dem Reaktor, wie zum Beispiel die Temperatur,



Produktinformationen, beispielsweise Produktnummern und Rezeptparameter, sowie zugehörige Ergebnisse aus Labormessungen. Eine Herausforderung ist dabei das Erstellen einer sauberen Datenbasis, also die fehlerfreie Kombination der verschiedenen Datenquellen. Als Zielgröße wurde im Gespräch mit Prozessexperten die Viskosität ermittelt. Diese Größe ist entscheidend für die Eigenschaften des Klebstoffs, während des Herstellungsprozesses allerdings nur durch Laborproben messbar.

Für den Auswertalgorithmus kamen künstliche neuronale Netze zum Einsatz. Diese können Zusammenhänge aus vorgegebenen Trainingsdaten erlernen. Tatsächlich konnte die Viskosität aus den messbaren Größen am Reaktor abgeleitet werden. Das künstliche neuronale Netz erfüllt somit die Funktion eines virtuellen Viskositätssensors. Diese virtuelle Sensorik – derzeit im Piloteinsatz – ermöglicht die Onlineüberwachung während des Herstellungsprozesses. Jowat SE kann also, bei ähnlicher Messgenauigkeit, auf die je 20-minütigen realen Labormessungen verzichten.

DATENSTRATEGIE ALS UMFASSENDES PROJEKT

Nicht jedes Unternehmen kann auf eine konsistente historische Datenbasis von mehreren Jahren zurückgreifen. Für eine erfolgreiche Umsetzung der Wertschöpfung aus Daten müssen die verschiedenen Ebenen – Datenquellen, Infrastruktur, Datenauswertung und Anwendungsfälle – ganzheitlich und mit einer strategischen Perspektive betrachtet werden. Jeder Aspekt muss über das gesamte Unternehmen und darüber hinaus über die Wertschöpfungskette betrachtet werden. Dies erfordert die horizontale Integration sämtlicher Funktionsbereiche, also zum Beispiel die Verbindung einzelner Datensilos zu einem Data Warehouse oder Data Lake oder den Aufbau einer gemeinsamen Dateninfrastruktur mit gemeinsamen IT-Systemen.

Gleichzeitig müssen die einzelnen Ebenen ganzheitlich gedacht werden. Dies erfordert auch die interdisziplinäre Zusammenarbeit einzelner Experten: Prozesssex-

perten oder Automatisierungstechniker mit dem Wissen über Datenquellen, IT-Experten mit dem Wissen über den Aufbau und die Möglichkeiten der IT-Infrastruktur, Data Scientists und Softwareentwickler für die Entwicklung von Algorithmen sowie Management und Geschäftsführung, die über die Umsetzung verschiedener Anwendungsfälle entscheiden. Um diese ganzheitliche Integration – entlang der Wertschöpfungskette und entlang der Ebenen – nachhaltig zu ermöglichen, ist eine unternehmensweite Datenstrategie erforderlich.

Mit der Querschnittsdisziplin Industrial Data Science erforschen wir diese interdisziplinären Aspekte und verbinden Big-Data-Methoden aus der Informatik mit maschinellen Lernverfahren und den spezifischen Problemstellungen aus dem industriellen Kontext. Daraus ergeben sich spezifische Vorgehensmodelle und einfach anwendbare Lösungsmuster, die den Entwicklungsprozess von Big-Data-Anwendungen systematisieren und somit die Umsetzung stark vereinfachen.

Für Unternehmen bedeutet Industrial Data Science das nötige Rüstzeug, um Aufwand, Nutzen und somit die Wirtschaftlichkeit von Big Data besser einschätzen und zielgerichtet in die Umsetzung gehen zu können. So können zukünftig auch Maschinen und Anlagen ihren Prozesszustand selbstständig twittern und ihren Gesundheitsstatus teilen. ◀



Hier gelangen Sie zu themenrelevanten Empfehlungen des Autors.



Bild: Fraunhofer

Sebastian von Enzberg, Fraunhofer IEM

Sein Fachgebiet als Gruppenleiter Mechatronik ist die Anwendung von maschinellem Lernen und KI im Maschinen- und Anlagenbau, insbesondere in der industriellen Fertigung. Sein Fokus liegt auf der Auswertung maschinennaher Daten für die Maschinen- und Prozessoptimierung, Smart Maintenance und Smart Quality.

MEHR DAZU

...finden Sie unter:

www.iem.fraunhofer.de

oder besuchen Sie unseren Next-Industry-ExpertTalk am 6. September 2018 in Hamburg: www.big-data-ni.de

Engineering Intelligence

KI-Kompetenz wird für Entwickler immer wichtiger

Der Einsatz von Künstlicher Intelligenz hat sich als globaler Trend etabliert. Ob Internetsuche, Online-Shopping, Sprachassistent oder die Erkennung von Verkehrsschildern im Auto: Längst sind KI-Anwendungen in vielen Bereichen unseres Privatlebens selbstverständlich. Schon in wenigen Jahren könnten KI-Technologien auch die Produkte und Services deutscher Unternehmen prägen. Neben der Produktentwicklung wird KI auch eine wichtige Rolle bei der Optimierung interner Prozesse einnehmen. Engineering Intelligence bringt die Produktentwicklung auf eine neue Stufe der Leistungsfähigkeit.

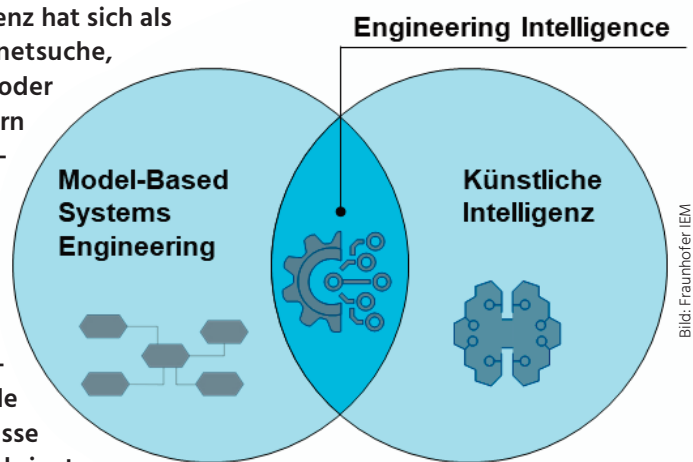


Bild 1 | Engineering Intelligence als Schnittmenge von MBSE und Künstlicher Intelligenz.

Die Analysten des amerikanischen Beratungsunternehmens International Data Corporation (IDC) gehen davon aus, dass sich die Menge der weltweiten Daten alle zwei bis drei Jahre verdoppelt. Während 2015 noch 70 Prozent aller Daten von Privatpersonen generiert wurden, werden 2025 über 60 Prozent der Daten von Unternehmen erzeugt. Die manuelle Analyse dieser Daten ist aufwendig, fehleranfällig und wird in Zukunft noch kritischer werden. Aus diesem Grund wird die Automatisierung dieser Arbeiten notwendig. Digitale Assistenzsysteme verarbeiten diese Datenmengen und die Abhängigkeiten zwischen diesen Daten automatisiert. Auch für Entwicklungsprojekte bieten sich hier neue Möglichkeiten, indem Assistenzsysteme allen Projektbeteiligten gezielt die wichtigsten Erkenntnisse für ihre Arbeit liefern. Besonders Künstliche Intelligenz verspricht hier hohen Nutzen. Künstliche Intelligenz ist ein Sammelbegriff für verschiedene Techniken, die es Computersystemen ermöglichen sollen, selbständig Probleme zu lösen. Dazu können KI-Systeme

z.B. den Inhalt von Daten verstehen und selbständig daraus lernen. Gerade Mitarbeiter in der Entwicklung ließen sich so unterstützen, um mehr Zeit für ihre Kern- und Kreativaufgaben zu haben. Im Unternehmen selbst stiege so die Produktivität. Um dorthin zu gelangen, müssen Planung und Bereitstellung von KI-Applikationen zur Kernkompetenz in der Engineering-IT werden.

Engineering Intelligence

Daten z.B. zum Nutzungsverhalten, zu den Servicefällen, Diagnosedaten oder auch zur Betriebsumgebung werden entlang des Produktlebenszyklus gesammelt, analysiert und aus diesen Informationen und Wissen extrahiert. Dieses Wissen wird in der Produktentstehung genutzt, um die nächste Generation, eine neue Marktleistung nutzungs- und kundenspezifisch anzubieten oder Geschäftsmodelle zu verändern. Charakteristisch ist die ganzheitliche, kontinuierliche Entwicklung dieser Marktleistung, für

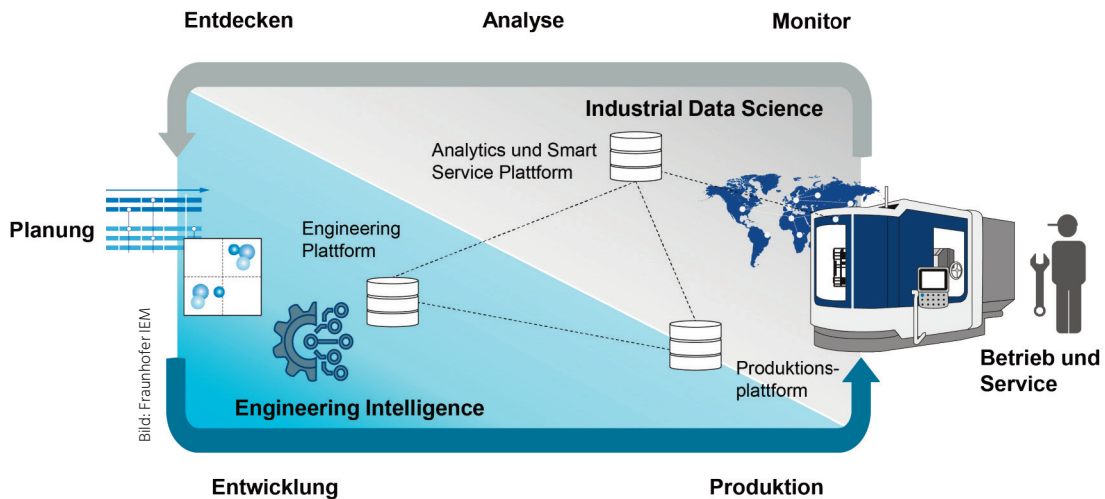


Bild 2 | Engineering Intelligence im Wechselspiel mit Industrial Data Science.

die sich der disziplinübergreifende Ansatz des Systems Engineering mithilfe formaler Modelle anbietet. Doch wie lassen sich diese Daten sinnvoll im Systems Engineering einsetzen und das extrahierte Wissen zweckorientiert nutzen? Ein vielversprechender Ansatz liegt in der Schnittstelle von Model-Based Systems Engineering (MBSE) und Künstlicher Intelligenz. Dieses Feld wird beim Fraunhofer IEM als Engineering Intelligence bezeichnet (vgl. Bild 1). Damit ergänzt Engineering Intelligence das Feld Industrial Data Science (vgl. Bild 2, dessen Fokus auf der Anwendung statistischer und maschineller Lernverfahren zur Modellbildung und Wissensextraktion im industriellen Kontext liegt und damit insbesondere die Phasen Produktion, Betrieb und Service adressiert. Engineering Intelligence nutzt dieses Wissen und kombiniert es mit den Produktdaten. Es unterstützt bei der Identifikation und der Modellierung von Systemanforderungen, Architekturen, Design sowie bei der Verifikation und Validierung. Beginnend in der Konzeptphase über die gesamten Entwicklungsphasen bis hin zu den späteren Lebenszyklusphasen.

Besondere Systemanforderungen

IT-Systeme für das Engineering Intelligence besitzen spezifische Fähigkeiten. Zum einen müssen die Systeme unstrukturierte Daten wie etwa Bilder oder Sprache verstehen. Dabei interpretieren sie die Daten, erfassen die zugrunde-

liegenden Konzepte und Muster, bilden Hypothesen und leiten Lösungsalternativen ab. Mit jedem Datenpunkt, jeder Interaktion und jedem Ergebnis lernen diese Systeme. Anhand von Regeln, Erfahrungswissen oder Zielen können die Systeme situationspezifisch Handlungspläne generieren, entscheiden und ausführen. Mithilfe der Fähigkeit zu sehen, zu sprechen und zu hören, interagieren sie mit Menschen und kommunizieren mit technischen Systemen. IT-Systeme mit diesen intelligenten Fähigkeiten besitzen vielfältige Anwendungspotentiale, die am Institut vier Anwendungsfelder gegliedert werden. Ziel dieser Systemauslegung ist die durchgehende Assistenz für den Entwickler, das Entwicklungsteam und den gesamten Entwicklungsprozess:

Persönliche Assistenz: Systeme die am Arbeitsplatz und im operativen Tagesgeschäft unterstützen. Dies sind etwa administrative und wiederholende Tätigkeiten wie Übersetzung, Digitalisierung von Workshops oder Terminkoordination.

Engineering Assistenz: Lösungen zur Unterstützung bei der Modellierung von Anforderungen, Design und Analyse. Dazu gehören etwa integrierte Funktionen zur Anforderungs- und Architekturbewertung, Wissensextraktion aus Produkt- und Nutzungsdaten mit denen weitere Anforderungen abgeleitet werden können, Priorisierung und Erstellung von Testfällen auf Basis von Service- und Fehlerfällen

oder auch die Exploration des Entwurfsraums durch evolutionäre Algorithmen.

Management Assistenz: Systeme zur Unterstützung von Management- und Entwicklungsprozessen, wie die Visualisierung von Prozessdaten, das Monitoring und die Prog-

nose der Entwicklungsproduktivität, Fallanalysen und Reasoning bis zum intelligenten Routing von Workflows.

Intelligentes Datenmanagement: Systeme die Produktdaten miteinander vernetzen und verwalten. Hierzu zählt das Verknüpfen von Anforderungen, Funktionen und logischer Architektur mit Testfällen und weiteren CAX-Daten.

Begriffsdefinitionen:

Künstliche Intelligenz:

Die Disziplin umfasst eine Reihe an Methoden, Techniken und Verfahren welche die Realisierung von intelligenten Verhalten und den zugrundeliegenden kognitiven Fähigkeiten auf Computern adressieren.

Maschinelles Lernen:

Der Bereich des maschinellen Lernens ist ein Teilbereich der künstlichen Intelligenz und beschäftigt sich mit der automatischen Erkennung von Regelmäßigkeiten in den Daten durch den Einsatz von Computeralgorithmen.

Industrial Data Science:

Anwendung von Data Science im industriellen Kontext. Data Science bezeichnet die Anwendung statistischer und maschineller Lernverfahren zur Modellbildung und Wissensextraktion aus Daten.

Evolutionäre Algorithmen:

Stochastische Heuristiken, die die Vorgänge der biologischen Evolution auf abstrakter Ebene imitieren. Kernmechanismen sind die Mutation und Rekombination sowie eine Selektion zugunsten der besten Merkmalsträger. Algorithmen werden zur Exploration und Optimierung eingesetzt.

Engineering Intelligence:

Anwendung von Methoden und Techniken der künstlichen Intelligenz im Model-Based Systems Engineering zur Unterstützung von Prozessen, Tätigkeiten und Datenmanagement. Die Systeme sind fähig zu lernen, zu interpretieren, zu interagieren und zu entscheiden.

MBSE:

Model-Based Systems Engineering (MBSE) ist die formalisierte Anwendung der Modellierung zur Unterstützung von Systemanforderungen, Design, Analyse, Verifikation und Validierung, beginnend in der Konzeptphase und über die gesamte Entwicklungsphase bis hin zu späteren Lebenszyklusphasen.

Fehlersuche im MBSE

In der komplexer werdenden Produktentwicklung wird es schwieriger, auf vorhandenes Wissen zurückzugreifen. Oft werden Entwicklungsfehler zwar dokumentiert, dann aber für zukünftige Projekte nicht weiter berücksichtigt. Die Folge sind hohe Kosten, um die Fehler nachträglich zu beheben. Im Anwendungsbeispiel aus dem Bereich Engineering Intelligence macht ein Live-Conversation-System, hier die intelligente Assistentin Lisa, den Entwickler früh auf Fehler aufmerksam, die in der Vergangenheit bereits aufgetreten sind. Bild 3 stellt einen im MBSE typischen Entwicklungsschritt im Tool iQuavis dar. Das zu entwickelnde System wird mit seinen logischen Elementen, Schnittstellen und Flüssen modelliert. Diese Abstraktion des realen Systems wird Systemmodell genannt. Hat der Entwickler einen Abschnitt abgeschlossen, so kann er nun diesen mittels Engineering-Intelligence-Systemen analysieren. Das Engineering Intelligence System Lisa, zieht sein Wissen aus historischen Daten. Hierfür wurde Lisa mit Verknüpfungen von in früheren Projekten dokumentierten Fehlern zu den verursachenden Bereichen in den Systemmodellen trainiert, sodass ein Graph entstanden ist. In der Analyse des aktuellen Systemmodells sucht Lisa den Graphen nach ähnlichen Mustern ab und macht somit in der Vergangenheit dokumentiertes Wissen für heutige und zukünftige Projekte nutzbar.

Bild 3 zeigt die Ergebnisse der Analyse an. Die Bereiche, die mit hoher Wahrscheinlichkeit zu einem bereits in früheren Projekten entdeckten Fehlern führen, werden von Lisa mit einem Warnhinweis markiert. Zusätzlich erläutert die Engineering Intelligence den möglichen Fehler in einem Chat Fenster. Der Entwickler kann so nach möglichen Lösungen oder Verweisen auf vergangene Projekte zu fragen. Hierüber kann er auch auf das frühere Projekt zugreifen, um den möglichen Fehler besser zu verstehen und zu analysieren.

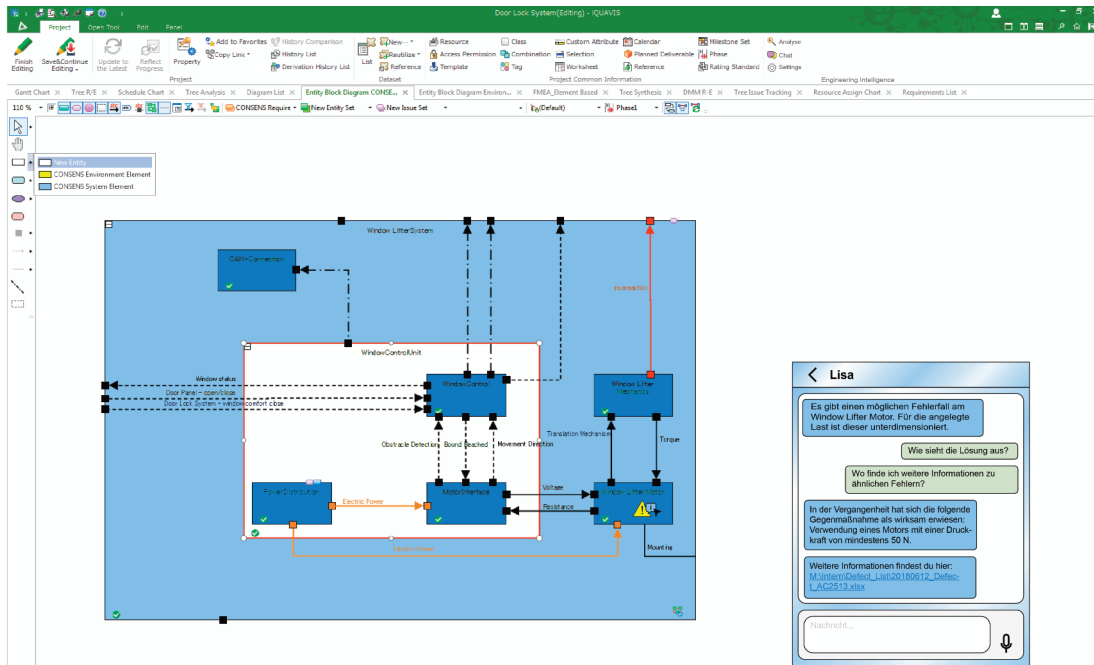


Bild: Fraunhofer IEM

Bild 3 | Mock-up der Analyse eines Systemmodells mit einem Engineering Intelligence System und einem möglichen Chat-Verlauf.

Intelligenz bedarfsgerecht

Um KI-basierte Assistenzsysteme erfolgreich in Entwicklungsabteilungen zu etablieren, sollten Unternehmen zunächst eine Basis schaffen. Die disziplinübergreifenden Ansätze des Systems Engineering und das modellbasierte MBSE schaffen geeignete Strukturen für ein ganzheitliches aber formalisiertes Engineering. Auch ein Blick für das wirklich Notwendige hilft weiter, denn nicht jedes Assistenzsystem schafft Unternehmen einen Mehrwert. Im Sinne der Bedarfsorientierung sollten Unternehmen zunächst eine umfassende und detaillierte Einführungsstrategie erarbeiten. Diese definiert zum einen die spezifischen Anwendungsbereiche von KI, bewertet sie hinsichtlich ihrer Wirt-

schaftlichkeit und identifiziert notwendige Technologien zur Realisierung der Assistenzsysteme. Zum anderen wird ein schrittweises Vorgehen zur Umsetzung, Erprobung und Einführung der ausgewählten Assistenzsysteme festgelegt. Dabei müssen insbesondere domänen- und unternehmensspezifische Anforderungen und Charakteristika, wie die Datenabhängigkeiten und Anforderungen an die Transparenz der durch die KI getroffenen Entscheidungen, berücksichtigt werden. Die Entwicklung einer solchen Strategie erfordert neben einem Verständnis für die Produktentwicklung auch Expertise in den Bereichen Künstliche Intelligenz und insbesondere Engineering Intelligence. ■

www.iem.fraunhofer.de

Autoren

Lukas Bretz, Marc Foullois, Michael Hillebrand und Ruslan Bernijazov arbeiten als wissenschaftliche Mitarbeiter am Fraunhofer-Institut für Entwurfstechnik Mechatronik IEM.

Autonome Systeme in der Produktion

Planungssystematik für die Entwicklung autonomer Systeme

Roman Dumitrescu, Thorsten Westermann, Tommy Falkowski,
Fraunhofer-Institut für Entwurfstechnik Mechatronik IEM, Paderborn

Autonome Systeme werden perspektivisch alle Lebensbereiche durchdringen und haben das Potenzial, einen gesellschaftlichen Wandel auszulösen. Die Konzipierung dieser hochkomplexen Systeme erfordert leistungsfähige Entwicklungsansätze und -methoden, die disziplinübergreifend angewendet werden. Stellvertretend für die vielschichtigen Anwendungsbereiche von autonomen Systemen steht die industrielle Produktion, in der im Kontext von Industrie 4.0 bereits eine technologieinduzierte Transformation eingeleitet wurde.

Im Bereich Mobilität sind in den vergangenen Jahren enorme Innovationssprünge zu verzeichnen. Die Leistungsfähigkeit von Assistenzsystemen, besonders im Automobilssektor, wird immer mehr zu einem zentralen Verkaufsargument und erfährt eine zunehmende mediale Aufmerksamkeit sowohl im wissenschaftlichen als auch im nichtwissenschaftlichen Bereich. Die Umsetzung von autonomen Fahrzeugen erfordert die Weiterentwicklung und Integration modernster Technologien, die bspw. eine Situationserkennung und Entscheidungsfindung ermöglichen. Experteneinschätzungen über die Umsetzbarkeit solcher autonomen Systeme in der nahen Zukunft divergieren stark und werden durch gesellschaftliche bzw. ethische Fragestellungen begleitet [1]. Neben dem autonomen Fahren existieren weitere Anwendungsbereiche für autonome Systeme, die einen ebenso großen gesellschaftlichen Wandel auslösen können, allen voran die industrielle Produktion. Als Motor für den Wohlstand in Deutschland ist es von enormer Wichtigkeit, die Einsatz- und Nutzenpotenziale autonomer Systeme für die industrielle Produktion zu erkennen und die Umsetzung entsprechender Systeme systematisch zu planen. Die Entwickler solcher Systeme stehen dabei vor der Herausforderung, die steigende Komplexität im Entwicklungsprozess zu beherrschen.

Autonome Systeme für die Produktion

Der digitale Wandel im Maschinen- und Anlagenbau ist durch einen zunehmenden Einsatz von Informations- und Kommunikationstechnik geprägt. Es entstehen neue Möglichkeiten zum einen für die Verbesserungen einzelner Maschinen und Anlagen, zum anderen für die Leistungssteigerung kompletter Wertschöpfungsprozesse.

Die Vernetzung der technischen Systeme sowie die Verschmelzung von virtueller und physikalischer Welt werden dabei im Kontext der industriellen Produktion unter dem Begriff CyberPhysical Systems (CPS) zusammengefasst. CPS sind offene, vernetzte Systeme, die mittels Sensorik Daten über den Zustand der physikalischen Welt erfassen, diese interpretieren und für digitale Dienste verfügbar machen. Über Aktoren können die Systeme direkt auf Prozesse in der physikalischen Welt einwirken und damit das Verhalten von Komponenten, Anlagen und Diensten steuern [2]. Durch den zunehmenden Einsatz von CPS in der industriellen Produktion vollzieht sich derzeit ein tiefgreifender Wandel. Der Begriff Industrie 4.0 steht für diesen Wandel und bezeichnet eine neue Stufe der Organisation und Steuerung komplexer Wertschöpfungsnetzwerke [3]. CPS sind dabei die wesentlichen Wegbereiter, deren konsequente Weiterentwicklung in der Umsetzung von autonomen Systemen mündet.


Notwendig werden solche Systeme unter anderem aufgrund der zunehmenden Nachfrage nach kundenindividuellen Produkten bei gleichzeitig sinkenden Fertigungskosten, welche sich nur mithilfe einer wandelbaren und flexiblen Fertigung umsetzen lassen. Das Ziel sind intelligente und vernetzte Fabriken, die in dynamischen Wertschöpfungsketten agieren und sich laufend selbst optimieren und so trotz individualisierter Produktion eine Senkung der Kosten ermöglichen. Solche intelligenten Fabriken werden auf den Einsatz autonomer Systeme und deren enger Verzahnung angewiesen sein.

Autonomous Systems in Production – Toward a Planning and Development Methodology


The performance of assistance systems, especially in the automotive sector, has become an unique selling point. The trend toward Autonomous driving represents the expected impact of innovation resulting from the exploitation of the latest technologies. Besides autonomous driving, other areas of application for autonomous systems could trigger social change – the prime example being industrial production. The following article presents a planning approach tailored to the complex engineering task of planning and designing autonomous systems for industrial applications.

Keywords:

Autonomous systems, systems engineering, cyberphysical systems, industrial internet of things



Prof. Dr.-Ing. Roman Dumitrescu ist Direktor am Fraunhoferinstitut für Entwurfstechnik Mechatronik IEM in Paderborn, wo er den Fachbereich Produktentstehung leitet und ist Geschäftsführer Strategie, FuE des Spitzenclusters it's OWL.



Dr.-Ing. Thorsten Westermann leitet eine Forschungsgruppe zum Thema Produkt-Service-Systeme im Bereich Produktentstehung des Fraunhofer-Instituts für Entwurfstechnik Mechatronik IEM in Paderborn.



M. Sc. Tommy Falkowski arbeitet als wissenschaftlicher Mitarbeiter am Fraunhoferinstitut für Entwurfstechnik Mechatronik IEM in Paderborn und ist Referent für Strategie, Forschung und Entwicklung beim Spitzencluster it's OWL.

roman.dumitrescu@iem.
fraunhofer.de
www.iem.fraunhofer.de

Ein prominentes Beispiel sind fahrerlose Transportsysteme, die eine bedarfsgerechte und effiziente Bereitstellung von Waren ermöglichen. Durch die Integration von maschinellen Lernverfahren und Ansätzen wie der Schwarmintelligenz werden diese Systeme zukünftig auch ohne zentrale Leitstellen auskommen und ihre Aufgaben vollständig autonom und dezentral abwickeln können. Durch eine dynamische Vernetzung der einzelnen Teilsysteme (Maschinen und Anlagen, Transport- und Wartungssysteme, Auftragsabwicklungssysteme etc.) ohne die Notwendigkeit von menschlichem Eingreifen, wird der Weg zu einer vollständig autonomen und standortübergreifenden industriellen Fertigung im Sinne der intelligenten Fabrik geebnet.

Ein weiteres Anwendungsbeispiel für autonome Systeme in der Produktion sind Maschinen und Anlagen, die laufend den eigenen Zustand sowie die Umgebungsdaten erfassen und auf Basis von Datenanalyse- und maschinellen Lernverfahren die Fertigungsprozesse bedarfsgerecht rekonfigurieren und optimieren können, um so flexibel auf eingehende Aufträge zu reagieren. Ein reales Beispiel aus der industriellen Anwendung sind Industriezentrifugen, sog. Separatoren. Separatoren dienen zur mechanischen Trennung von mehreren Phasen mit unterschiedlichen Dichten im zugeführten Rohprodukt. Im Projekt „Separator i4.0“, an dem das Fraunhofer IEM als Forschungspartner beteiligt war, wurde ein solcher Separator von einem mechatronischen System zu einem intelligenten, technischen System weiterentwickelt, welches bereits Grundzüge von Autonomie umsetzt. Dieses Projekt dient im folgenden Beitrag als Anwendungsbeispiel für die Konzeption und Umsetzung autonomer Systeme in der industriellen Produktion.

Entwicklungsstufen technischer Systeme hin zu autonomen Systemen in der Produktion

Im Kontext der technischen Systeme erfordert der Begriff der Autonomie eine genauere Erläuterung. Autonome Systeme bezeichnen Systeme, die Aufgaben selbstständig und in weiten Teilen ohne menschliche Eingriffe ausführen können. Von heutigen automatisierten Systemen unterscheiden sich autonome Systeme durch ihre hohe Anpassungsfähigkeit. Hierzu zählen neben Robotern auch Fahrzeuge, Produktionsanlagen, Gebäude und Softwaresysteme. Abhängig von der Häufigkeit der notwendigen Eingriffe und Entscheidungen durch einen Menschen, kann zwischen verschiedenen Entwicklungsstufen unterschieden werden [4]. Das Spektrum reicht dabei von ferngesteuerten Systemen, bei denen der Mensch alle Entscheidungen trifft, bis hin zu vollautonomen Systemen, die auch über lange Zeiträume die selbstständige Aufgabenerfüllung und Anpassung an wechselnde Umgebungen und Situationen aufrechterhalten können [5]. Bild 1 stellt die einzelnen Entwicklungsstufen für technische Systeme hin zu autonomen Systemen dar.

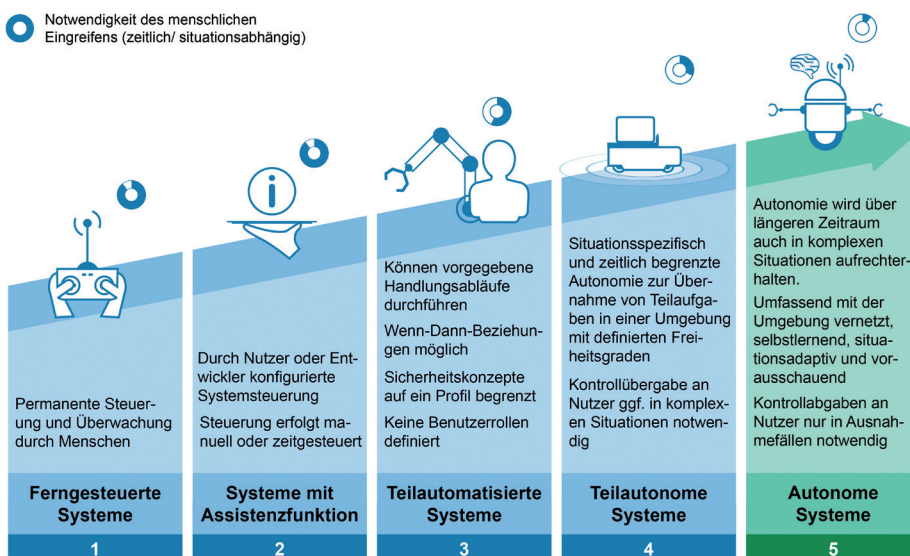
Im Kontext der industriellen Produktion sind technische Systeme, analog zu einzelnen Fahrzeugen im Straßenverkehr, immer Teil von übergeordneten Systemen. Diese übergeordneten Produktionssysteme werden im Zuge der Digitalisierung immer komplexer und die Systemgrenzen (unter einer Systemgrenze versteht man eine Abgrenzung zwischen dem System und seinem Umfeld) müssen weiter gefasst werden. Gründe sind der steigende Vernetzungsgrad, die Integration externer Datenverarbeitungssysteme und die Einbindung digitaler

Dienste. Bestand ein Produktionssystem früher nur aus den einzelnen Anlagen einer Produktionslinie und ggf. einer übergeordneten Steuerung, erweitern sich die Systemgrenzen zukünftiger flexibler Produktionsanlagen durch die Aufnahme zusätzlicher Sensorik, lokaler und externer Datenverarbeitung, angebundener Logistiksysteme sowie ggf. global verteilter Fertigungsanlagen. Die Flexibilität erfordert den Einsatz von Systemen mit höheren Entwicklungsstufen bzw. von autonomen Systemen, um eine Koordination der Systeme und einen reibungslosen Ablauf zu gewährleisten.

Bei unserem Industriebeispiel wurde ein Separator, der in die Stufe 1 eingeordnet werden konnte (vollständig manuelle Einstellung durch Bediener, keine eigen-

Bild 1: Entwicklungsstufen technischer Systeme hin zu Autonomen Systemen (in Anlehnung an [5]).

Notwendigkeit des menschlichen Eingreifens (zeitlich/ situationsabhängig)



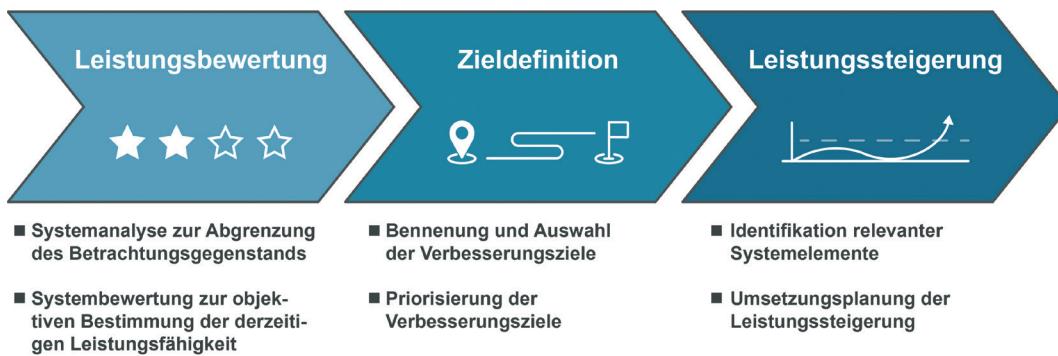


Bild 2: Vorgehen bei der systematischen Planung von autonomen Systemen.

ständige Anpassung im Betrieb) so weiterentwickelt, dass er eigenständig erkennt, wenn ein suboptimaler Betriebszustand vorliegt. Der Separator wurde hierzu mit Sensorik ausgestattet und die Messwerte durch eine selbst entwickelte Software ausgewertet. Abhängig vom erfassten Betriebszustand kann der Separator nun eigenständig die Betriebsparameter anpassen, um den optimalen Betriebspunkt einzustellen. Der so modifizierte Separator entspricht nun der Stufe 3, da er vorgegebene Handlungsabläufe selbstständig durchführen kann. Bis zu dieser Stufe ist eine Integration mit weiteren Systemen in der Prozesskette noch nicht zwingend erforderlich. Das System umfasst den mechanischen Aufbau, die Elektronikkomponenten sowie die Software (für den Fall einer lokalen Datenverarbeitung). Spätestens für einen teilautonomen Betrieb wird eine Vernetzung mit angrenzenden Systemen aus der Wertschöpfungskette erforderlich. Im Fall des Separators werden Daten über die vorgeschalteten Prozesse benötigt, um eine bedarfsgerechte und proaktive Anpassung des Betriebszustands zu ermöglichen. Wird der Separator zum Beispiel in einem Brauprozess eingesetzt, so könnte bedarfsgerecht die Leistung reduziert werden, wenn die vorgeschalteten Prozesse nicht vollständig ausgelastet sind.

Mit der Einführung teilautonomer Systeme in die Wertschöpfung nimmt die Komplexität des Gesamtsystems signifikant zu: Es reicht nun nicht mehr aus, ein einzelnes System wie den Separator im Prozess zu betrachten. Eine isolierte Umsetzung von autonomen Systemen in der Produktion wäre insofern auch nicht zielführend, da der zu erwartende Leistungszuwachs in keiner Relation zum Aufwand stünde. Erst durch eine integrierte Weiterentwicklung eines Gesamtsystems bzw. eines Systemverbundes können die Potenziale autonomer Systeme für die Produktion ausgeschöpft werden. Dies erfordert entsprechende Vorgehen und Methoden im Rahmen der Entwicklung, die eine Handhabbarkeit der hohen Komplexität ermöglichen.

Planung von autonomen Systemen

Der Wandel technischer Systeme erfolgt nicht adhoc und einheitlich für alle Systeme. Vielmehr werden sich die Systeme im Zuge einer schrittweisen Transformation verändern, die sukzessive entlang der zuvor beschriebenen Entwicklungsstufen verläuft (Bild 1). Dabei erschließt sich der Nutzen nicht erst mit der höchsten Entwicklungsstufe, sondern bereits entlang sämtlicher Leistungsstufen. Eine strukturierte Leistungssteigerung erfordert eine systematische Planung, die drei wesentliche Schritte umfasst: Leistungsbewertung, Zieldefinition und Leistungssteigerung (Bild 2). Dieser Planungsprozess ist essenziell, um bei jeder Entwicklungsstufe bereits die richtigen Maßnahmen für aufbauende Stufen zu treffen.

Ausgangspunkt einer systematischen Planung von autonomen Systemen ist die Leistungsbewertung, d. h. eine objektive Bemessung des Ausgangszustands. Hierzu erfolgt zunächst eine Systemanalyse, im Rahmen derer der Betrachtungsgegenstand festgelegt (z. B. Separator) und sämtliche Informationen darüber beschafft werden. Hilfreiche Informationsquellen sind u. a. Systemmodelle, Stücklisten, Zeichnungen oder Schaltpläne. Daraus lassen sich Aussagen über die bestehende Sensorik und Aktorik, die Leistungsfähigkeit der Informationsverarbeitung oder vorhandenen Kommunikations- und Mensch-Maschine-Schnittstellen treffen. Auf Basis der Informationen kann nun eine Systembewertung durchgeführt werden, in der das System in die Entwicklungsstufen eingeordnet wird. Zur Bewertung ist die Anwendung eines Reifegradmodells (z. B. [6]) empfehlenswert, die eine objektive und vergleichbare Aussage über die aktuelle Leistungsfähigkeit des betrachtenden Systems ermöglicht. Das Resultat der Leistungsbewertung für den Separator war die Leistungsstufe 1 „Ferngesteuerte Systeme“, da diese zwar umfassende Betriebsdaten erfasst, diese aber weder für Auswertungen noch für eine selbstständige Entscheidungsfindung nutzt.




Bild 3: Schrittweise Weiterentwicklung eines Separators hin zu einem autonomen System.

Nach Abschluss der Systembewertung folgt die Zieldefinition. Die anzustrebende Entwicklungsstufe ist nicht zwangsläufig die maximal mögliche. Vielmehr ist die Zielleistungsstufe an konkreten Verbesserungszielen für das System auszurichten. Verbesserungsziele beschreiben konkrete Absichten, zu welchem Zweck die Leistungssteigerung dienen soll. Beispielhafte Ziele für den Separator sind die Erhöhung der Systemverfügbarkeit, die Reduzierung von Ausschuss sowie die Verbesserung der Dienstleistungseffizienz. Aus einer Reihe möglicher Verbesserungsziele werden die wichtigsten Ziele ausgewählt und priorisiert. Anhand der festgelegten Ziele kann nun die anzustrebende Entwicklungsstufe ausgewählt werden. Für den Separator wurde die Zielleistungsstufe 3 „Teilautomatisierte Systeme“ ausgewählt, die den Separator dazu befähigen soll, vorgegebene Handlungsabläufe, wie z. B. die Einstellung des Zulaufdrucks und der Drehzahl, selbstständig vorzunehmen.

Die dritte Phase (Leistungssteigerung) hat das Ziel, die Lücke zwischen der derzeitigen Leistungsfähigkeit und dem ermittelten Zielreifeegrad zu schließen. Dazu gilt es zunächst, die Systemelemente zu identifizieren, die eine hohe Relevanz für die Erreichung der Verbesserungsziele haben. Beispielsweise waren für den Separator die Verbesserung der Informationsverarbeitung, der Sensorik und der Aktorik von besonderer Bedeutung, um die angestrebte Leistungsstufe zu erreichen. Weniger bedeutend war an dieser Stelle das Kommunikationssystem, da eine Vernetzung mit anderen Systemen entlang des Prozesses noch nicht im Fokus stand. Die einzelnen Schritte zur Verbesserung des Systems sind anschließend in eine zeitliche Reihenfolge zu bringen. Dies erfolgt in Form einer Roadmap, die neben der Reihenfolge auch die Wechselwirkungen zwischen den Systemelementen darstellt. Das Resultat aus der letzten Phase ist nun ein konkreter Plan für

die schrittweise Weiterentwicklung des Separators hin zu einem autonomen System (Bild 3).

Erfolgsfaktor Systems Engineering

Die Autonomie beeinflusst nicht nur zukünftige Systeme, sondern auch die Art und Weise, wie diese entstehen. Es verändern sich Prozesse, Methoden, Organisationsstrukturen und die Form der Zusammenarbeit, da der Entwurf autonomer Systeme das Zusammenwirken zahlreicher Fachdisziplinen voraussetzt. Die stark ausgeprägte Interdisziplinarität stellt für klassisch strukturierte Organisationen eine große Herausforderung dar. Die Umsetzung autonomer Systeme erfordert darüber hinaus, sehr vielen Entwicklungsaspekten wie Funktionalität, Verhalten, Resilienz, Security, Sustainability, Usability, Herstellbarkeit, Wartbarkeit etc. gerecht zu werden. Die Absicherung dieser Aspekte im Entwurf stellt sicher, dass die tatsächlichen Systemeigenschaften mit den geforderten Eigenschaften übereinstimmen und das System in allen Betriebssituationen in der Zielumgebung verlässlich funktioniert. Für autonome Systeme ist das eine noch ungeklärte Fragestellung, da nicht alle Situationen zur Entwicklungszeit vollständig antizipiert werden können. Die durchgehende Validierung der Systeme erhöht zusätzlich die Komplexität und schafft die Notwendigkeit der Absicherung auch über den Entstehungsprozess hinweg.

Ein Ansatz der den genannten Herausforderungen im Anspruch gerecht wird, ist das Systems Engineering. Systems Engineering hat das Ziel, Disziplinen, Entwicklungsaufgaben und vielfältige Aspekte zu integrieren und die Akteure in der Entwicklung komplexer Systeme zu orchestrieren. Es versteht sich als durchgängige, fachdisziplinübergreifende Disziplin zur Entwicklung multidisziplinärer Systeme. Systems Engineering hat seinen Ursprung in der Systemtheorie und hat sich stetig weiterentwickelt. Auslöser war stets ein Komplexitätszuwachs in der Problemstellung. Systems Engineering bildet eine fundierte Ausgangsplattform für eine zwingend erforderliche, ganzheitliche Produktentstehungsmethodik für autonome technische Systeme und kann nach Klärung aller technologischen Herausforderungen der entscheidende Erfolgsfaktor in der Entwicklung von autonomen Systemen werden.

Schlüsselwörter:

Autonome Systeme, Systems Engineering, Cyber-Physical Systems, Industrie 4.0

Literatur

- [1] Walker, J.: The Self-Driving Car Timeline – Predictions from the Top 11 Global Automakers. URL: <https://www.techemergence.com/self-driving-car-timeline-themselves-top-11-automakers/>, Abrufdatum 25.07.2018.
- [2] Broy, M.: Cyber-Physical Systems. Berlin Heidelberg 2010.
- [3] Kagermann, H.; Wahlster, W.; Helbig, J.: Umsetzungsempfehlungen für das Zukunftprojekt Industrie 4.0 – Deutschlands Zukunft als Industriestandort sichern, Forschungsunion Wirtschaft und Wissenschaft, Arbeitskreis Industrie 4.0. Ort 2013.
- [4] SAE International: https://www.sae.org/standards/content/j3016_201401/preview/, Abrufdatum 31.07.2018.
- [5] Dumitrescu, R.; Gausemeier, J.; Slusallek, P.; Cieslik, S.; Demme, G.; Falkowski, T.; Hoffmann, H.; Kadner, S.; Reinhart, F.; Westermann, T.; Winter, J.: Autonome Systeme. Studien zum deutschen Innovationssystem. Berlin 2018.
- [6] Westermann, T.: Systematik zur Reifegradmodell-basierter Planung von Cyber-Physical Systems des Maschinen- und Anlagenbaus. Dissertation. Universität Paderborn 2017.

Raum für kluge Gedanken ...

Fraunhofer-Institut für Entwurfstechnik Mechatronik IEM
Zukunftsmeile 1 | 33102 Paderborn
Tel. 05251 5465 - 107
Mail: info@iem.fraunhofer.de
www.iem.fraunhofer.de

Herausgeber

Prof. Dr.-Ing. Roman Dumitrescu

Redaktion

Kirsten Harting

Nachweise Bilder und Inhalte

- Titelmotiv: Fraunhofer IEM
- S.4-9: mit freundlicher Genehmigung von Vogel Communications Group
- S.10-13: IT&Production, mit freundlicher Genehmigung des TeDo-Verlags

Alle Rechte vorbehalten. Vervielfältigung und Verbreitung nur mit Genehmigung des Herausgebers.

Druck: November 2018

