
Produktions- und Verfügbarkeits- optimierung mit Smart Data Ansätzen

Herausgegeben von
Univ.-Prof. Dr.-Ing. Birgit Vogel-Heuser

Automation Symposium 2018

„Produktions- und Verfügbarkeitsoptimierung mit Smart Data Ansätzen“

27. September 2018

Lehrstuhl für Automatisierung und Informationssysteme,
Fakultät für Maschinenwesen, Technische Universität München

Programmausschuss und Vorsitz

Prof. Dr. Birgit Vogel-Heuser, Technische Universität München
Emanuel Trunzer, Technische Universität München
Iris Weiß, Technische Universität München

Referenten

Dr. Edwin Becker, PRÜFTECHNIK Condition Monitoring GmbH
Dr. Andreas Binder, SAMSON Pilotentwicklung GmbH
Dr. Norbert Fabritz, Evonik Technology & Infrastructure GmbH
Mina Fahimi Pirehgalin, Technische Universität München
Dr. Jens Folmer, PRÜFTECHNIK Condition Monitoring GmbH
Florian Pethig, Fraunhofer IOSB-INA
Dr. Andreas Gallasch, Software Factory GmbH
Christian Kloh, Evonik Industries AG
Frieder Loch, Technische Universität München
Monica Romero Lopez, GEFASOFT GmbH
Dr. Jörg A. Nagel, Neoception GmbH
Dr. Matthias Odenweller, Evonik Technology & Infrastructure GmbH
Dr. Dorothea Pantförder, Technische Universität München
Dr. Christoph Paulitsch, Siemens AG
Dr. Thorsten Pötter, Bayer AG
Peter Schleinitz, IBM Deutschland GmbH
Dr. Daniel Schütz, GEFASOFT GmbH
Dr. Matthias Steffen, Bayer AG
Benjamin Stracke, Neoception GmbH
Emanuel Trunzer, Technische Universität München
Stefan Unland, SAMSON AG
Christian Vermum, Evonik Industries AG
Prof. Dr. Birgit Vogel-Heuser, Technische Universität München
Iris Weiß, Technische Universität München
Ralf Winkelmann, FANUC Deutschland GmbH

Vorwort

Produktions- und Verfügbarkeitsoptimierung mit Smart Data Ansätzen – wie aus Big Data Smart Data wird

Prof. Dr.-Ing. B. Vogel-Heuser
*Lehrstuhl für Automatisierung und Informationssysteme,
Technische Universität München, Garching bei München
vogel-heuser@tum.de*

Big Data und Datenanalyse sind in aller Munde. Laut Bundeskanzlerin Merkel sind sie „die Rohstoffe des 21. Jahrhunderts“ [C16]. Auch im industriellen Umfeld rücken im Rahmen von Industrie 4.0 Datenanalysen bei Produktionsanlagen immer weiter in den Fokus [VH16]. Hersteller versprechen sich durch das Angebot von smarten Dienstleistungen neue Marktpotentiale, während Anlagenbetreiber auf eine optimierte Fahrweise ihrer Anlagen hoffen. Daten werden inzwischen bereits als „das neue Gold der Wirtschaft“ betrachtet [J15, MK17].

Typische Anwendungsbeispiele für industrielle Datenanalysen von Produktionsanlagen sind unter anderem die Zustandsüberwachung (Condition Monitoring), die Qualitätsvorhersage, sowie die Reduktion von Alarmschauern. Dazu werden unterschiedlichste Daten ausgewertet: Neben den Aktor- und Sensorwerten aus der Feldebene werden auch Rezept- und Auftragsdaten aus den überlagerten Systemen wie Manufacturing Execution System (MES) bzw. Enterprise-Resource-Planning (ERP) Systemen genutzt. Weiterhin sind Daten aus der Engineeringphase und Informationen zu aufgetretenen Ereignissen aus Schichtbüchern, sowie dokumentierte Reparaturen aus den Werkstätten von Relevanz.

Bei näherer Betrachtung der in Analysen verwendeten Datenarten fällt auf, dass derzeit nur ein Bruchteil der Unternehmen Daten des technischen Prozesses oder Engineeringdokumente oder Dokumente aus der Betriebsphase (bspw. Auslegungsdaten, Schichtbücher oder Wartungsberichte) für Analysen verwenden (vgl. Abbildung 1). Nach den Ergebnissen der in Abbildung 1 betrachteten Umfrage spielt die Verwendung von Prozessdaten im Vergleich zu anderen Datenarten eine untergeordnete Rolle. Big Data Analysen zur Optimierung von Marketing- oder Verkaufsaktivitäten sind inzwischen auch industriell weit verbreitet. Andererseits finden aber Analysen in der Produktion

aufgrund der Vielzahl an zu berücksichtigenden Datenquellen, den verschiedenen IT-Systemen der Feld- bis zur ERP-Ebene, der Heterogenität der Datenarten (Zeitreihen, Abtastraten der Zeitreihen, Wartungsberichte) und der Komplexität der zugrundeliegenden Phänomene nur begrenzt Anwendung. Denn dadurch sind rein datengetriebene Analysen in diesem Bereich oftmals nicht ausreichend, was die Verarbeitung der Daten deutlich erschwert. Insbesondere die Komplexität der physikalischen Phänomene und der Vielzahl am Analysenprozess beteiligten Fachdisziplinen begrenzen die Anwendung rein datengetriebener Analysen in diesem Bereich.

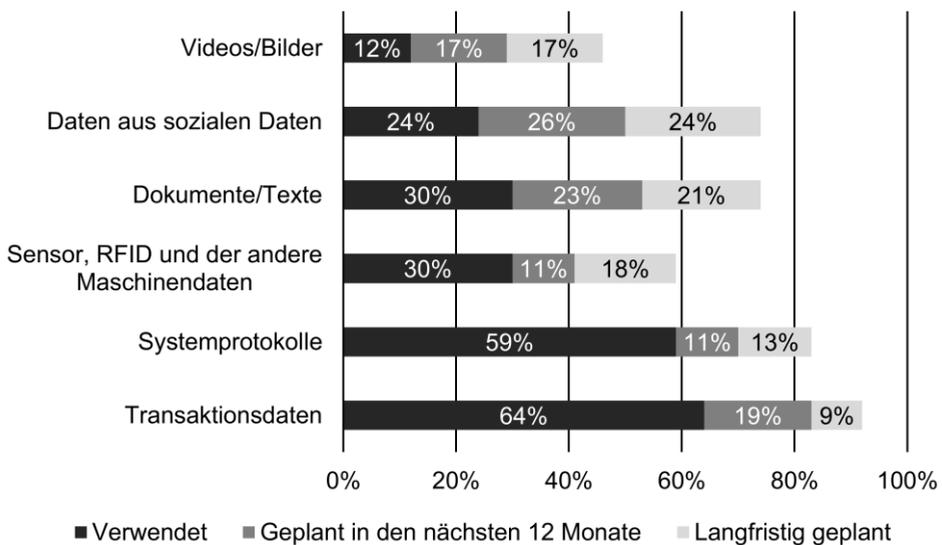


Abbildung 1: Verwendete Arten von Daten bei industriellen Datenanalysen.

Frage: „Welche der folgenden Datentypen verwendet Ihre Firma derzeit für Big Data Analysen?“, n=208 [BG+15].

Der vorliegende Bericht stellt mehrere aktuelle Forschungsprojekte in den Mittelpunkt: SIDAP (Skalierbares Integrationskonzept zur Datenaggregation, -analyse, -aufbereitung von großen Datenmengen in der Prozessindustrie), gefördert durch das Bundesministerium für Wirtschaft und Energie (BMWi), sowie IMPROVE (Innovative Modeling Approaches for Production Systems to Raise Validatable Efficiency), gefördert von der Europäischen Union, und ausgewählte Beiträge aus diesem Bereich.

Im Projekt SIDAP zeigte sich schnell, dass ohne die Berücksichtigung von Expertenwissen keine zielführenden Analysen möglich sind. Für den untersuchten Anwendungsfall der Ventildiagnose liegt zwar eine große Menge an Sensor- und Aktordaten aus der Feldebene vor, jedoch beinhalten diese nur eine sehr geringe Anzahl an Fehlerfällen, sprich Ventilversagen. Dies liegt darin begründet, dass kontinuierlich arbeitende Anlagen oftmals „überwartet“ sind, weil ungeplante Komponentenausfälle zu kompletten Anlagenausfällen führen können und unter allen Umständen vermieden werden sollen. Deshalb werden beispielsweise Ventile bei geplanten Stillständen für Wartungen frühzeitig ausgewechselt und die verfügbaren Reserven in der Restnutzungsdauer nicht genutzt. Kann ein Ventil aber aufgrund einer korrekten Vorhersage dieser Restnutzungszeit länger genutzt werden, können Wartungszeiträume besser genutzt und durch die Priorisierung von Wartungsaufträgen Kosten gesenkt werden. Andererseits kann bei Anlagen mit häufigeren Wartungsstillständen ein drohender Ausfall durch Datenanalyse frühzeitig erkannt werden, so dass optimierte Fahrweisen die Restnutzungsdauer verlängern können oder die ungeplante Wartung im Rahmen eines Anlagenstillstands anderer Ursache durchgeführt werden kann.

Datengetriebene Detektionsmodelle müssen an die vorhandenen Fehlerfälle angelernt werden, weshalb im betrachteten Anwendungsfall, trotz der enormen Menge an Datensätzen, nicht genügend Daten vorhanden sind. Expertenmodelle, welche das exakte Ventilverhalten auf physikalischer Ebene mittels komplexer Modelle beschreiben, sind zwar theoretisch erstell- und anwendbar, aufgrund der vielen zu bestimmenden Parametern und der dazu notwendigen Messkampagnen in der Breite aber kaum rentabel. Für eine automatisierte Zustandsüberwachung prozesstechnischer Ventile oder Komponenten in Produktionsanlagen muss darüber hinaus auch die Anbindung der Analyse an die Prozessdaten in Echtzeit und die Strukturierung dieser Daten berücksichtigt werden. Insgesamt ist neben dem Wissen des Datenanalysten, auch das der Prozesstechnologen, sowie der IT-Systemarchitekten gefragt.

Voraussetzungen für eine erfolgreiche Diagnose ist eine geeignete Systemarchitektur (siehe Abbildung 2), in welcher die Anbindung der Datenquellen an die Analyse gelingt. Hierauf aufbauend wird die Big Data Infrastruktur, bestehend aus Datenbanken und Analysewerkzeugen, erstellt. Datenanalysten erstellen die Analysemodelle und wenden diese auf die Daten an. Hierfür ist neben der Kenntnis über die Infrastruktur auch Wissen über die konkret zu untersuchenden Sachverhalte notwendig. Für den Anwendungsfall der Ventildiagnose wurde hierfür in Zusammenarbeit der verschiedenen Disziplinen

eine Fehlerklassifikation erstellt, welche der Kommunikation zwischen den beteiligten Fachdisziplinen dient. Nur wenn das Wissen der Prozessexperten und –technologien in den Analyseprozess mit einfließt, können die Daten zielgerichtet analysiert werden.

Auch bei der Bewertung der Ergebnisse spielt die Experteneinschätzung eine wichtige Rolle. Versteht das Anlagenpersonal nicht, auf welcher Basis eine Handlungsempfehlung im Rahmen einer Analyse gefällt wurde, ignorieren diese oft die Empfehlung oder schalten das System aufgrund fehlendem Vertrauen gar ab, wie bereits in einem Erfahrungsbericht von Dr. Kuschnerus (ehemals NAMUR-Vorstand) und Anwendung von Computational Intelligence im Bereich von Sinteranlagen und Span- bzw. Faserplattenanlagen festgestellt wurde [L02, BS98]. Deshalb ist es entscheidend, die Ergebnisse, sowie den Lösungsweg der Maßnahmen, klar und nachvollziehbar zu visualisieren. Wenn bereits die Analyse das Wissen der Experten berücksichtigt, ist auch deren Vertrauen in die Ergebnisse größer.

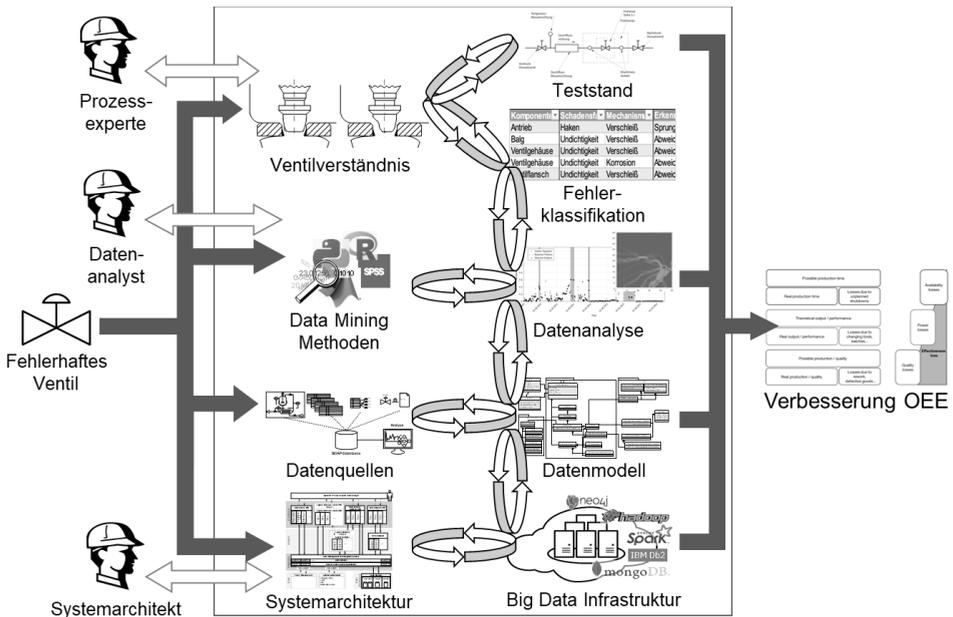


Abbildung 2: Beteiligte Fachdisziplinen und zu betrachtende Themenkomplexe für eine erfolgreiche Ventildiagnose.

Dies zeigte sich auch im Anwendungsfall der Vorhersage von Produktqualität [VK+17], welcher im Rahmen von IMPROVE bearbeitet wird. Expertenwissen unterstützt auf der einen Seite die Identifizierung von komplexen, ineinander verschachtelten Zusammenhängen zwischen Prozesswerten und Produktqualität. Auf der anderen Seite erhöht der Eingebzug und die Visualisierung von Expertenwissen die Validität von Vorhersagemodellen.

Um die Qualität von Rohdaten besser beurteilen zu können und die Korrektheit der Datenanalyse einschätzen zu können, muss die Varianz und Verteilung der Daten analysiert und visualisiert werden. Sind in den Daten lediglich wenige, eingeschränkte Parametersätze enthalten, können trainierte Modelle auch nur in diesem beschränkten Bereich korrekte Aussagen wie Qualitäts- oder Fehlervorhersagen treffen (vergleiche Abbildung 3). Die normalisierten Variablen werden auf den Achsen eines Spinnendiagramms abgebildet. Die Verbindung zwischen den Daten repräsentiert dabei einen Parametersatz, der in den Daten vertreten ist. Somit ist ersichtlich welche Bereiche des Merkmalsraumes im Datensatz vertreten sind und in welchen Bereichen Lücken (weiße Bereiche) zu finden sind. Zusätzlich können die Parametersätze geclustert und farblich markiert werden. Folglich kann mit dieser Abbildung gezeigt werden, wo ein bestimmter Parametersatz im Merkmalsraum liegt, wie dieser im Vergleich der bereits beobachteten Parametersätze zu beurteilen ist und welchen Gültigkeitsbereich ein auf Basis dieser Daten trainiertes Modell aufweist. [WV18]

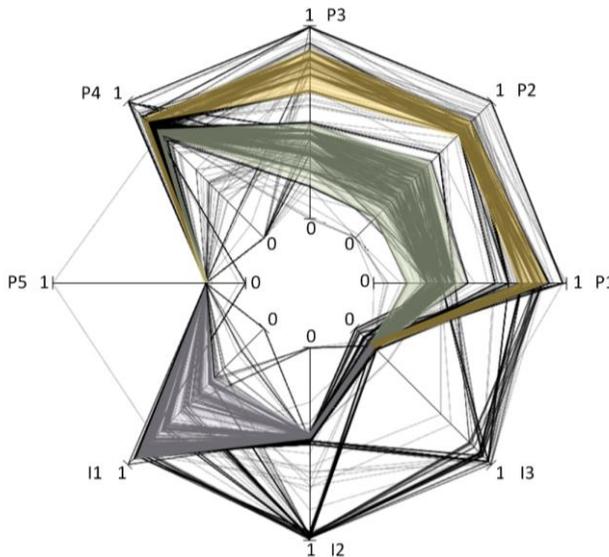


Abbildung 3: Visualisierung der Daten im Merkmalsraum zur Beurteilung von Varianz und Verteilung [WV18].

Ausgehend von den beispielhaft vorgestellten Erkenntnissen der beiden Projekte SIDAP und IMPROVE kann man ableiten, dass für industrielle Analysen im Produktionsumfeld hybride Datenanalysen notwendig sind. Hybride Datenanalysen, welche die Stärken datengetriebener Ansätze und das vorhandene Expertenwissen kombinieren, sind deshalb ein pragmatischer Ansatz die Potentiale der Big Data Analysen mit dem Expertenwissen sinnvoll zu kombinieren, um den größtmöglichen Nutzen zu erreichen.

Es geht bei smarten Ansätzen der Datenanalyse nicht darum, möglichst viele Daten zu analysieren, sondern die vorhandenen Daten klug auszuwählen, zielgerichtet zu analysieren und nachvollziehbar darzustellen. Der Begriff *Smart Data* beschreibt genau das. Während Big Data Analysen im Produktionsumfeld nur begrenzt anwendbar sind, können die Potentiale dennoch mit Smart Data Analysen gehoben werden.

Danksagung

Die Konsortialpartner des Projekts SIDAP bedanken sich beim BMWi für die Förderung des Projekts *Skalierbares Integrationskonzept* zur Datenaggregation, -analyse, -aufbereitung von großen Datenmengen in der Prozessindustrie (SIDAP), Förderkennzeichen 01MD15009F, www.sidap.de) und die Unterstützung der Veranstaltung im Rahmen des Smart Data Programms.

Gefördert durch:



aufgrund eines Beschlusses
des Deutschen Bundestages

Weiterhin danken wir der Europäischen Union für die Förderung des Projektes *Innovative Modeling Approaches for Production Systems to Raise Validatable Efficiency* (IMPROVE, Förderkennzeichen 678867, www.improve-fof.eu) und *Smart and Adaptive Interfaces for INCLUSIVE Work* (INCLUSIVE, Förderkennzeichen. 723373, www.inclusive-project.eu) und die Unterstützung der Veranstaltung im Rahmen von *Horizon 2020*.



Der Lehrstuhl für Automatisierung und Informationssysteme dankt allen Konsortial- und Industriepartnern.

Literatur

- [C16] <https://www.cebit.de/de/news-trends/news/bundeskanzlerin-merkel-daten-sind-die-rohstoffe-des-21-jahrhunderts-1190>, aufgerufen am 14.08.2018.
- [VH16] B. Vogel-Heuser, D. Hess. „Guest Editorial Industry 4.0–Prerequisites and Visions,” in *IEEE Trans. Automat. Sci. Eng.*, 13, 2016, S. 411–413.
- [J15] J. Schreier: „Big Data – das neue Gold der Wirtschaft,“ *Maschinenmarkt*, 2015, <https://www.maschinenmarkt.vogel.de/big-data-das-neue-gold-der-wirtschaft-a-511659/>, aufgerufen am 14.08.2018.
- [MK17] S. Mühlenkamp, J. Kempf: „Big-Data-Analysen – auf der Suche nach dem neuen Gold,“ *PROCESS*, 2017, <https://www.process.vogel.de/big-data-analysen-auf-der-suche-nach-dem-neuen-gold-a-657581/>, aufgerufen am 14.08.2018.
- [BG+15] C. Bange, T. Grosser, N. Janoschek: „Big Data Use Cases – Getting real on data monetization,“ *BARC*, 2015.
- [L02] M. Langer: „Synthese eines Prozessstufen übergreifenden Qualitätsmodells für eine Prozessklasse mit ausgewählten Methoden der Computational –Intelligence am Beispiel einer Sinteranlage,“ *Dissertation*, Universität Wuppertal, 2002.
- [BS98] G. Bemardy, B. Scherff: „SPOC-Process modelling provides on-line quality control and predictive process control in particle and fibreboard production,“ *IECON*, Vol. 3, 1998, S.1703-1707.
- [WV18] I. Weiß and B. Vogel-Heuser: "Assessment of Variance & Distribution in Data for Effective Use of Statistical Methods for Product Quality Prediction," *Automatisierungstechnik (at)*, vol. 66, no. 4, S. 344-355
- [VK+17] B. Vogel-Heuser, V. Karaseva, J. Folmer and I. Kirchen: "Operator Knowledge Inclusion in Data-Mining Approaches for Product Quality Assurance using Cause-Effect Graphs," in *20th IFAC World Congress (IFAC)*, Jul. 2017, S. 1358-1365.

Inhaltsverzeichnis

1	Smart Data in der Prozessindustrie	1
	<i>Dr. T. Pötter</i>	
1.1	Nutzen von Smart Data in der Prozessindustrie	1
1.2	Typische Herausforderungen und Lösungsansätze	3
1.3	Ausblick: Gemeinsame Datenanalyse in der Cloud	9
1.4	Zusammenfassung	9
1.5	Danksagung	10
2	Systemarchitekturen für Smart Data Ansätze	13
	<i>E. Trunzer, F. Pethig</i>	
2.1	Einleitung und Motivation	13
2.2	Aktueller Stand der Forschung und Technologie	15
2.3	SIDAP/IMPROVE-Systemarchitektur	18
2.4	Zusammenfassung	24
2.5	Danksagung	25
3	Schadensfallklassifikation von Ventilen und Retrofitting von bestehenden Anlagen.....	29
	<i>C. Vermum, S. Unland</i>	
3.1	Einleitung und Motivation	29
3.2	Klassifikation von Ventilfehlern und Einflussfaktoren.....	30
3.3	Retrofitting von bestehenden Anlagen	32
3.4	Zusammenfassung	35
3.5	Danksagung	36
4	Fehlerdiagnose an Ventilen.....	39
	<i>Dr. N. Fabritz, I. Weiß</i>	
4.1	Einleitung	39
4.2	Problemstellung.....	40
4.3	Tests am Versuchsstand	43
4.4	Übertragung auf Industriedaten.....	48
4.5	Ausblick auf Fehlerprognose	51
4.6	Zusammenfassung	51
4.7	Danksagung	52

5	Remote Operations	53
	<i>Dr. M. Odenweller, Dr. D. Pantförder, M. Fahimi Pirehgalin</i>	
5.1	Leckageüberwachung in prozesstechnischen Anlagen	53
5.2	Einführung in den Demonstrator	56
5.3	Leckagesuche mittels Datenanalyse	57
5.4	Zusammenfassung und Ausblick.....	66
5.5	Danksagung	66
6	Smart Data in klein- und mittelständischen Unternehmen der Fertigungstechnik	69
	<i>Dr. D. Schütz, M.R. Lopez</i>	
6.1	Motivation und Einleitung.....	69
6.2	Das Manufacturing Execution System Legato Sapient.....	70
6.3	Ziele des Projekts SIDAP-sMES.....	72
6.4	Lösungen des Projekts SIDAP-sMES	74
6.5	Zusammenfassung und Ausblick.....	81
6.6	Danksagung	82
7	ThingWorx – Plattform zur Integration herausfordernder Anforderungen auf dem Shopfloor	83
	<i>Dr.-Ing. A. Gallasch</i>	
7.1	Herausfordernde Anforderungen an IT Lösungen in der Operational Technology.....	83
7.2	Konnektivität	84
7.3	Agile Applikationsentwicklung.....	85
7.4	Künstliche Intelligenz.....	87
7.5	Augmented Reality	90
7.6	Zusammenfassung	91
8	Das SIDAP-Cloud-Konzept für Smart Data-Anwendungen in der Prozessindustrie	93
	<i>P. Schleinitz, Dr. M. Steffen</i>	
8.1	Einleitung	93
8.2	Der Nutzen der Cloud.....	94
8.3	SIDAP Cloud-Konzept.....	94
8.4	Umsetzung des Cloud-Konzepts	101
8.5	Zusammenfassung	105

	8.6 Definitionen.....	105
	8.7 Danksagung.....	107
9	Integration von Feldgerätedaten aus Bestandsanlagen.....	109
	<i>Dr. J.A. Nagel, B. Stracke, C. Vermum, C. Kloh</i>	
	9.1 Ausgangssituation	109
	9.2 Konzept	110
	9.3 Umsetzung.....	112
	9.4 Erkenntnisse	115
	9.5 Zusammenfassung.....	118
	9.6 Danksagung.....	118
10	Condition Monitoring Systeme als Datenlieferant für Big Data Anwendungen	119
	<i>Dr.-Ing. J. Folmer, Dr. rer. nat. E. Becker</i>	
	10.1 Einleitung und Motivation	119
	10.2 CMS kann mehr als nur Zustandsdaten zu liefern	123
	10.3 Zusammenfassung.....	130
11	Intelligente Interfaces zur effektiven Wartung.....	133
	<i>F. Loch, Prof. Dr.-Ing. B. Vogel-Heuser</i>	
	11.1 Einführung und Motivation	133
	11.2 Stand der Technik.....	135
	11.3 Anwendungsfall	137
	11.4 Entwicklung eines Systems zur Intelligenten Wartungsunterstützung	139
	11.5 Zusammenfassung.....	142
	11.6 Danksagung.....	143
12	Container basierte KI, ein Lösungsansatz.....	145
	<i>Dr. A. Binder</i>	
13	ZeroDownTime	147
	<i>R. Winkelmann</i>	
	13.1 FANUC ZDT und FIELD System	147
	13.2 FANUC FIELD System	153

**14 Industrieller Datenanalyseprozess für vorausschauende
Wartung in der Cloud 155**

Dr. C. Paulitsch

14.1	Einleitung	155
14.2	Datenanalyse in der Industrie	155
14.3	Problemstellungen identifizieren.....	157
14.4	Visualisierung der Daten	158
14.5	Anomaliedetektion	161
14.6	Ursachenanalyse	162
14.7	Interpretation	164
14.8	Vorhersage.....	166
14.9	Optimierung.....	168
14.10	Zusammenfassung	169
14.11	Danksagung	169

1 Smart Data in der Prozessindustrie

Herausforderungen, Lösungsansätze und Best Practices

Dr. T. Pötter
Bayer AG, Leverkusen
thorsten.poetter@bayer.com

1.1 Nutzen von Smart Data in der Prozessindustrie

Hoch automatisierte, prozesstechnische Anlagen generieren im täglichen Betrieb einen kontinuierlichen Strom an Messdaten. Hinzu kommen beispielsweise Qualitätswerte, Auftrags- und Wartungsdaten, die zusammengenommen eine enorme Anhäufung an Daten (Big Data [MB12]) und potentieller Information darstellt. Die Methoden des Maschinellen Lernens haben das Versprechen abgegeben aus diesen Unmengen an anfallenden Daten sinnvolle Schlussfolgerungen zu ziehen. Im Gegensatz zu wissensbasierten Systemen [GP+12], welche formalisiertes Wissen zur Analyse nutzen, ist hierbei kein Vorwissen über den Inhalt der Daten notwendig. Aber auch Big Data Ansätze versuchen zunehmend mehr Vorwissen in die Analyse zu integrieren, um die komplexen Sachverhalte besser erklären zu können und die Ergebnisse der Analysen zu verbessern. Der Begriff Smart Data drückt diese Anpassung von Big Data hin zur wissensunterstützten Analyse von großen Datenmengen und die Nutzung der Analyseergebnisse aus. Die zugrundeliegenden Methoden und Ansätze können hierbei an unterschiedlichsten Stellen in der Prozessindustrie eingesetzt werden. So befasst sich das Forschungsprojekt SIDAP¹ mit der Vorhersage von Geräteausfällen in chemischen Anlagen, der Analyse von Alarmschauern [VS+15] und der Vorhersage der Prozessqualität, um Assistenzsysteme zur besseren Führung der Anlagen anbieten zu können.

In Bezug auf die Vorhersage von Geräteausfällen stellt sich folgende Situation dar. Die Geräte verschiedener Anbieter erzeugen in einer heterogenen IT-Landschaft eine Flut von verschiedenen Daten, darunter Nutzungs-, Wartungs- und Qualitätsdaten. Bisher werden diese Daten von den Unternehmen häufig in unterschiedlichen IT-System gesammelt und nur als lokales Ereignis (in einer Anlage) betrachtet. Aggregierte Daten aus mehreren Anlagen werden von den Unternehmen selten weiterverwendet. Der Gerätehersteller

¹ Skalierbares Integrationskonzept zur Datenaggregation, -analyse, -aufbereitung von großen Datenmengen in der Prozessindustrie; <http://www.sidap.de>, aufgerufen am 18.07.2018.

sammelt unabhängig davon eigene Daten z.B. Aktivitätsstatistiken oder Belastungskennwerte. Das Potential einer übergreifenden Analyse möglichst aller Daten wird derzeit nicht ausreichend genutzt. Ziel von SIDAP ist die Entwicklung und Erprobung von Big-Data Technologien für diese innovativen und wettbewerbsrelevanten Nutzungsszenarien. Es werden unternehmensübergreifende, sichere und skalierbare Daten-Integrationsarchitekturen, sowie Analysemethoden zur Datenaggregation und zur Unterstützung der Entscheidungsfindung im Betrieb entworfen. Dies erfolgt in enger Zusammenarbeit zwischen Betreibern und Geräteanbietern der Prozessindustrie, IT-Anbietern und Forschung. SIDAP entwickelt hierzu eine datengetriebene sowie serviceorientierte Integrationsarchitektur. Diese Integrationsarchitektur macht vorhandene Strukturinformationen und Daten aus dem Engineering und den Prozessleitsystemen unter Berücksichtigung ihrer unterschiedlichen Semantik in abstrahierter, integrierter und zugriffsgeschützter Form für interaktive Analysen zugänglich. So können Gerätehersteller anhand von ausgewählten Nutzungsdaten ihrer Geräte in den Produktionsanlagen und der Wartungs- und Reparaturdaten Gerätestörungen analysieren. Basierend auf der Datenauswertung können Zusammenhänge identifiziert und somit präventiv mögliche Fehler identifiziert und vor dem Eintritt Abhilfemaßnahmen getroffen werden. Für den Anlagenbetreiber wird eine optimalere Nutzung der Geräte und damit einhergehend ein möglichst störungsfreier Betrieb sichergestellt.

Das Forschungsprojekt zielt somit auf eine Erhöhung der Overall Equipment Effectiveness (OEE) ab. Diese kann durch unterschiedliche Faktoren, wie Verbesserung der Produktqualität, Erhöhung der Anlagenleistung oder Steigerung der Anlagenverfügbarkeit, erreicht werden (vgl. Abbildung 1.1). In SIDAP soll die Anlagenverfügbarkeit durch die Vorhersage von Geräte- und Equipmentausfällen und die entsprechend Umplanung der Wartung erreicht werden. Die Nutzung der verfügbaren Daten verbessert die Kenntnisse der Geräte- und Equipmentzustände über Unternehmen und Unternehmensstandorte hinweg. Durch diese integrale Betrachtung können die Lebenszykluskosten der Feldgeräte in verfahrenstechnischen Anlagen zudem gesenkt werden.

Im Folgenden werden typische Herausforderungen und Lösungsansätze bei der Anwendung von Smart Data Prinzipien in der Prozesstechnik genannt. Abschließend wird ein Ausblick auf zukünftige Entwicklungen und Anwendungsfälle gegeben. Dieser Beitrag ist eine erweiterte Fassung der Veröffentlichung in der Zeitschrift „Automatisierungstechnische Praxis (atp)“ [FK+2017].

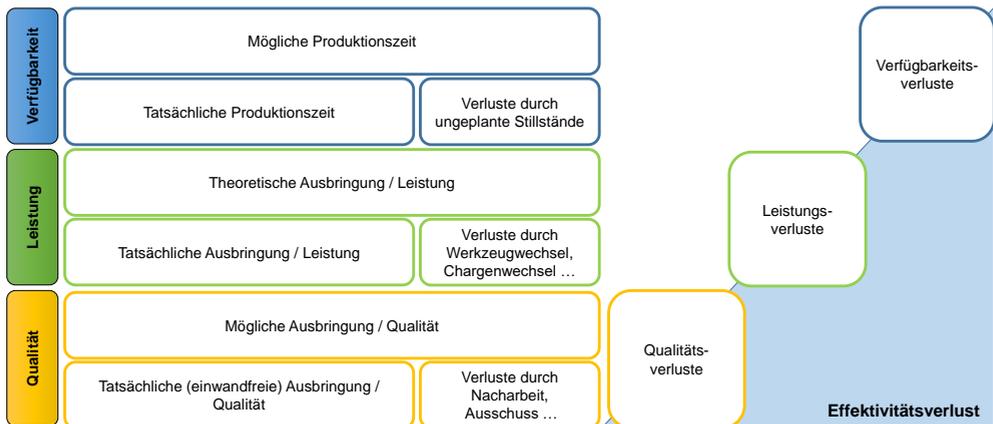


Abbildung 1.1: Faktoren für die Beeinflussung der Overall Equipment Effectiveness (OEE) [FK+2017].

1.2 Typische Herausforderungen und Lösungsansätze

In der Prozesstechnik müssen für die Anwendung von Smart und Big Data Ansätzen eine Zahl von verschiedenen Herausforderungen überwunden werden. Teilweise sind diese typisch für die Prozesstechnik, zumeist treffen diese aber auch auf andere Branchen zu. Neben der Beschreibung der Herausforderungen werden im Folgenden auch pragmatische Lösungsansätze und –perspektiven aufgezeigt.

1.2.1 Systemvernetzung

Die Heterogenität der einzelnen Daten drückt sich auch in der Gestaltung der Schnittstellen der Systeme aus. Diese gehen üblicherweise von unterschiedlichen Datenmodellen aus. Einige der Probleme sind die Modellierung in unterschiedlichem Detaillierungsgrad und die Nutzung von verschiedenen Größeneinheiten. Darüber hinaus ist die Erfassung von relevanten Informationen (etwa wichtige Daten aus Stellungsreglern) nicht immer ohne Mehraufwand möglich, weil die dafür notwendige Kommunikation entweder nicht konfiguriert wurde oder von der Datenübertragungsrate zu langsam ist (z.B. bei HART). Des Weiteren stellt sich die Frage nach der optimalen Datenhaltung, die je nach konkretem Anwendungsfall unterschiedlich beantwortet werden muss. Einerseits kann es sinnvoll sein eine zentrale Datenhaltung über Unternehmensgrenzen hinweg zu etablieren, um den Zeitbedarf für eine Abfrage großer Datenmengen möglichst klein zu halten. Andererseits weist diese Form der zentralisierten Datenhaltung den Nachteil auf, dass der eigentliche Datenerzeuger diese nicht mehr unter seiner Kontrolle hat. Um die Sicherheit

und Integrität der Daten trotzdem sicherzustellen, müssen diese durch geeignete technische Verfahren ausreichend gesichert und eventuell anonymisiert werden, bevor sie übertragen werden. Alternativ bietet sich weiterhin die dezentrale Speicherung der Daten beim Datenerzeuger an, was jedoch bei kontinuierlicher Übertragung großer Datenmengen die Netzwerklast und Latenz deutlich erhöhen kann. Andererseits kann die dezentrale Datenhaltung die zu übertragenden Datenmengen je nach Anwendungsfall auch verringern, wenn nicht ständig ein kontinuierlicher Datenstrom zwischen den einzelnen Datenbanken übertragen werden muss, sondern gezielt für die Analyse benötigte Daten abgefragt werden. Auch hier bildet ein gemeinsames Datenverständnis die Grundlage zur Überwindung der Hindernisse.

Darüber hinaus sind derzeitige Systeme (-installierte Basis in der Produktion) oft geschlossene, monolithische Softwaresysteme ohne ausreichende Offenheit und Schnittstellen. Die Vernetzung dieser Systeme untereinander und mit neuen Systemen ist deshalb mit erheblichen Aufwand verbunden, da eine große Anzahl von spezifischen Punkt-zu-Punkt Schnittstellen für die Interaktion zwischen zwei Systemen implementiert und gewartet werden muss.

Die Namur Open Architecture (NOA), welche von der Interessengemeinschaft Automatisierungstechnik der Prozessindustrie (NAMUR) vorgestellt wurde [KT+17], öffnet die bekannte Automatisierungspyramide und bietet eine pragmatische Lösung zur Überführung bestehender Automatisierungslösungen in das Industrie 4.0-Zeitalter. Über einen zweiten, offenen Datenkanal (vgl. Abbildung 1.2) können die beteiligten System miteinander kommunizieren ohne die Echtzeitkommunikation und proprietäre Interaktion höhergelegener Systeme zu beeinflussen. Die NOA schafft somit eine Basis, um bestehende Systeme enger zu vernetzen, ohne den produktiven Betrieb zu beeinflussen. Weiterführende Konzepte werden beispielsweise von Trunzer et al. [TK+17] vorgestellt, welche aber oftmals kompatibel zur NOA-Sichtweise sind.

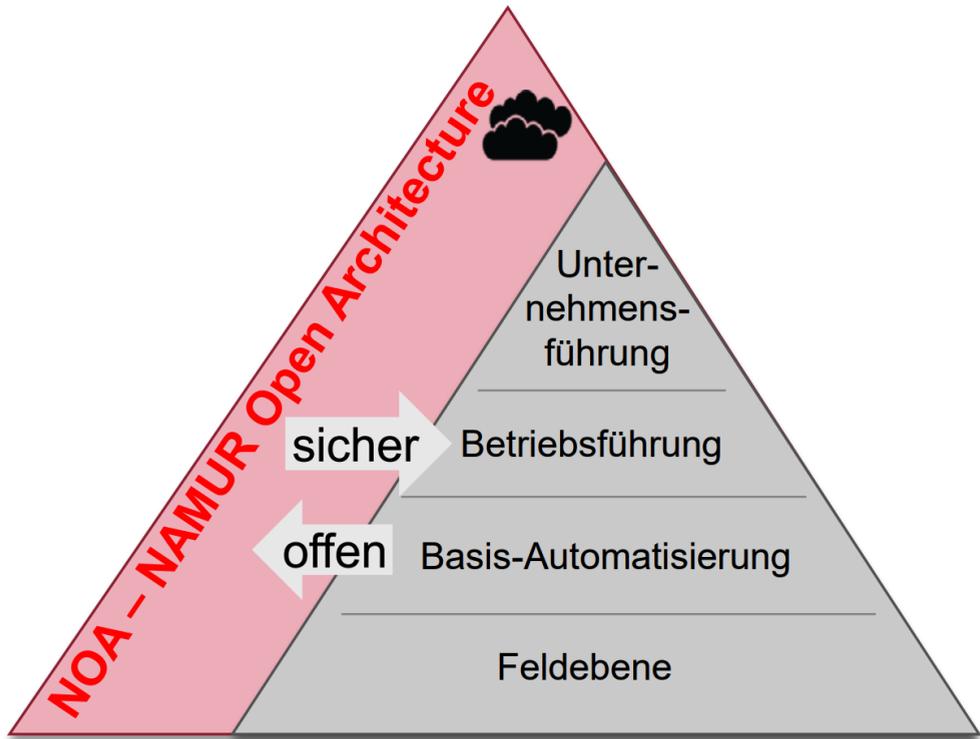


Abbildung 1.2: Schematische Darstellung der Namur Open Architecture (NOA) [KT+17].

1.2.2 Integration von Systemen

Obwohl die Forderung nach einer Integration von Anlagendaten nicht neu ist, zeichnet sich diese Aufgabe in der Realität durch erhebliche Herausforderungen aus. Beispielsweise weisen die Daten, welchen einem Equipment zugeordnet werden müssen, in unterschiedlichen Datenbanken verschiedene Bezeichnungen oder Einheiten auf. Zudem unterscheiden sich die Abstraten der einzelnen Signale und müssen vor der Analyse auf eine gemeinsame Referenzzeit übertragen werden (Zeitsynchronisation). Änderungskomprimierte Signale, vor allem Sollwerte, die nur bei Änderung übertragen werden, erfordern erweitertes Wissen beim Auffüllen der Datenreihen. Zudem sind häufig spezifische Informationen für die Auswertung von Daten in Kommentarfeldern versteckt (z.B. Soll vs. Istwerte), die eine automatische Integration erschweren.

Als Lösungsansatz kommen gemeinsame Datenmodelle in Frage, welche die relevanten Daten in einheitlicher Form strukturieren und speichern. Voraussetzung hierfür ist ein gemeinsames Verständnis zwischen den beteiligten Fachdisziplinen. Um den Datenaustausch effizient zu gestalten, sind akzeptierte Datenmodelle erforderlich, welche von mehreren Partnern unterstützt werden. Weiterhin müssen Anwendungen, welche am Prozess beteiligt sind, über geeignete Im- und Exportschnittstellen verfügen. Für die Prozesstechnik stellt das Datenmodell der DEXPI-Initiative [TA+16, DE18], welche sich neben großen Betreibern verfahrenstechnischer Anlagen auch aus Herstellern von CAE-Programmen zusammensetzt, ein solch unternehmensübergreifendes Datenmodell dar. Ziele von DEXPI ist die Schaffung von Datenaustauschstandards zur Darstellung relevanter Informationen in prozesstechnischen Anlagen entlang des gesamten Lebenszyklus der Anlage.

1.2.3 Datenqualität und Vollständigkeit

Die Instrumentierung prozesstechnische Anlagen ist vorwiegend auf die Regelung des Prozesses und damit der Sicherung des einwandfreien Betriebs und nicht für die Datenanalyse ausgelegt. Zudem wird die Messdatenarchivierung meist durch die Dokumentationspflicht des Betreibers bestimmt, so dass Datenpunkte aggregiert und nicht hochfrequent gespeichert werden. Dies verursacht, dass die Messreihen oftmals aufgrund ihrer Abtastrate für eine Datenanalyse unzulänglich und spezifische Messgrößen gar nicht verfügbar sind. Die gespeicherten Datensätze sind darüber hinaus oftmals nicht mit dem Betriebszustand der Anlage zum Zeitpunkt der Messung verknüpft. Mittels einer vorgelagerten Datenvorverarbeitung sind deshalb Abtastraten zu synchronisieren und instationäre Betriebsphasen sowie Zeiten mit fehlerhafter Messdatenerfassung aus den Rohdaten zu entfernen. Weiterhin können durch den Einbezug von Prozesswissen zusätzlich Datenreihen vervollständigt oder ergänzt werden.

Derzeit werden Daten oftmals ohne Berücksichtigung der Anforderungen durch die Datenanalyse erhoben und gespeichert. Um die Datenqualität und –vollständigkeit nachhaltig zu erhöhen, müssen Ansätze entwickelt werden, die die gesamte Prozesskette von der Datenerhebung bis zur Nutzung der Daten kontrollieren. Neben zweiten Datenkanälen müssen auch Wege gefunden werden, um die Anforderungen zu formalisieren und diese im Betrieb zu überwachen.

Ein weiterer Aspekt stellt das Vorliegen nicht digitaler bzw. unstrukturierter Daten dar. Selbst wenn Formulare bereits digitalisiert sind (häufig bei

Schichtbüchern) und nicht auf Papier vorliegen (Aufnahme von Schadensfällen in Werkstätten), führen z.B. Freitexteingaben zu unterschiedlichen Eintragung für denselben Fehler (vgl. „Ventil klemmt“ und „Ventil fährt nicht auf“). Die Informationsextraktion aus solchen unstrukturierten Daten ist eine große Herausforderung. Neben der Entitäts-Auflösung ist vor allem das Matching der Entitäten mit Domänen-Begriffen und deren Synonymen schwierig. Bei nicht digital vorgehaltenen Planungsdaten ist zudem ein Re-Engineering mit Wissensextraktion aus Bildern (P&IDs in PDF) notwendig. Hier besteht Bedarf für weitere Forschung und eine zunehmende Digitalisierung der Prozesse.

1.2.4 Anlagenevolution

Eine weitere Problematik liegt in der stetigen Änderung von prozesstechnische Anlagen über ihre Lebensdauer. So werden bei planmäßigen Stillständen Komponenten ausgewechselt und modernisiert sowie Prozessführungsstrategien im Zuge einer kontinuierlichen Optimierung angepasst. Damit verändert sich das Verhalten einer Anlage und die angelernten Modelle für die Datenanalytik verlieren über die Zeit an Wert. Nichtsdestotrotz kann man zu einem gewissen Teil veraltete Modelle weiternutzen, da sich nicht das komplette Verhalten einer Anlage ändert und weil direkt nach einem Umbau oder einer Umstellung noch keine Daten für das Anlernen neuer Modellen zur Verfügung stehen. So ist das ständige Anlernen und Weiterlernen von Big Data Modellen ein fester Teil im Lebenszyklus von Anlagen und Geräten und muss als Prozess gelebt werden. Weiterhin kann die gezielte Berücksichtigung von Expertenwissen die Unsicherheit nach einer Anlagenevolution vermindern, indem die Auswirkung der Änderung auf das Datenanalysemodell abgeschätzt wird. Darüber hinaus kann durch Vorlage bekannter Zusammenhänge der erneute Lernprozess beschleunigt werden.

1.2.5 Fehllarme und Erkennungsrate

Die Güte einer Analyse kann nicht nur durch die korrekt erkannten Fehler- oder Ausnahmestände charakterisiert werden. Ebenso bedeutend ist die Rate an Fehllarmen bei der das Modell eine Meldung ausgibt, obwohl keine kritische Situation oder ein Fehler in der Anlage vorliegen. Fehllarme werden beispielsweise durch instationäre Betriebsbedingungen hervorgerufen, bei denen das Modell eine Anomalie zum gelernten, normalen Anlagenverhalten feststellt. Die Berücksichtigung des aktuellen Betriebszustands kann daher die Rate an Fehllarmen senken. Fehllarme schädigen zum einen das Vertrauen in die Ergebnisse der Datenanalytik und können andererseits auch

konkret zu unnötigen Maßnahmen veranlassen (z.B. das Herunterfahren einer Anlage zur Fehlerbeseitigung), welche einen vermeidbaren Ausfall der Produktionsanlage zur Folge hat. Je nach Anwendungsfall und Zielsetzung ist deshalb abzuwägen, wie das Modell angepasst werden muss.

1.2.6 Überwachung der Anlagen

Beim Betrieb von prozesstechnischen Anlagen steht die Vermeidung von Anlagenstillständen im Vordergrund. Wartungsstrategien, bei denen technische Einrichtungen in festen Intervallen untersucht und gegebenenfalls ausgetauscht werden, sollen eine hohe Verfügbarkeit der Anlage sicherstellen. Dies geschieht mit dem Ziel, durch die zeitnahe Inspektion und Instandhaltung potentielle Ausfälle auszuschließen. Das Versagen von technischen Anlagen tritt somit, je nach Wartungsstrategie und Beanspruchung der Anlage, relativ selten auf. Dieses erfolgreiche Beispiel für geplante, vorausbestimmte Instandhaltung ist jedoch für die Datenanalyse von Nachteil. Die Anlagen sind sozusagen überwacht. Durch das seltene Auftreten von bewiesenen Ausfällen von technischen Einrichtungen ist die Zahl an Fehlerfällen für die von der Datenanalyse benötigten Vergleichsdaten stark begrenzt. Die Datensätze enthalten somit größtenteils sogenannte „Gutdaten“, welche den korrekten Betrieb der Anlage beschreiben, während „Schlechtdaten“, mit welchen beispielsweise ein defektes Ventil beschrieben werden kann, fehlen. Dies führt zu großen Unsicherheiten bei der Bestimmung von Problemen in technischen Einrichtungen.

Aus Sicht der Datenanalysten ist die Erhebung von „Schlechtdaten“ am Naheliegendsten. Da dies jedoch zumeist nur mit hohen Kosten oder überhaupt nicht realisierbar ist, müssen andere Wege zur Überwindung der Probleme gefunden werden. So kann beispielsweise Expertenwissen genutzt werden, um Zusammenhänge, welche in den Daten nicht abgebildet sind, in der Analyse zu ergänzen. Weiterhin besteht die Möglichkeit, durch gezielte Prüfstandmessungen die fehlenden Daten unter vergleichbaren Randbedingungen aufzufüllen. Zielführend, aber mit sehr hohem Aufwand verbunden, sind flottenbasierte Ansätze, bei denen bekannte Fehler aus anderen technischen Einrichtungen bei der Analyse mitbenutzt werden. Durch die Kombination der verschiedenen Datenreihen kann somit aus vergleichbaren Fehlern in der Vergangenheit gelernt werden. Hierfür ist jedoch eine breite Anwendung der entwickelten Methoden erforderlich, da ansonsten wieder nur begrenzt gültige Einzelfallbetrachtungen erfolgen.

1.3 Ausblick: Gemeinsame Datenanalyse in der Cloud

Für das Beispiel der Ventildiagnose sind in der Datenanalyse Betriebs- und Auslegungsdaten aus unterschiedlichen Quellen zu kombinieren, um suboptimale oder kritische Zustände erkennen und bewerten zu können. Dies erfordert oftmals die Vernetzung über Unternehmensgrenzen hinweg, da die notwendigen Daten nicht gesammelt im Unternehmen selbst vorliegen. Durch eine solche unternehmensübergreifende Nutzung der Daten kann Wissen extrahiert werden, welches sonst aufgrund lückenhafter Datenlage im Verborgenen bleiben würde. Im Fokus steht hierbei die Datensicherheit und -integrität: zunächst müssen die Daten, die zwischen den Unternehmen geteilt werden sollen, gemeinsam ausgewählt werden, so dass einerseits die vertraulichen Informationen über den technologischen Prozess geschützt und andererseits die wesentlichen Informationen für die Beurteilung des Geräts bereitgestellt werden können. Die Rohdaten werden gemäß den Vorgaben des Datenbesitzers, z.B. des Anlagenbetreibers, automatisch anonymisiert. Dies beinhaltet zum Beispiel das Entfernen unnötiger Metainformationen oder die Normalisierung von Datenreihen. Des Weiteren muss neben einer manipulationsicheren und verschlüsselten Übertragung der Daten auch eine sichere Speicherung der Daten am Ort der Verwendung gewährleistet werden.

Geteilte Cloudumgebungen, in denen Anlagenbetreiber, Hersteller von Aktorik und Sensorik, sowie weitere Partner (Wartungsdienstleister, Analyse-dienstleister) kooperieren und als Marktplätze dienen, können diese Interaktion in Zukunft deutlich vereinfachen. Nur durch unternehmensübergreifende Vernetzung der Datensilos wird das volle Potential der einzelnen Datensätze nutzbar gemacht.

1.4 Zusammenfassung

Die Anwendung datengetriebener Verfahren zur Steigerung der Gesamtanlageneffektivität birgt ein großes, derzeit oftmals noch ungenutztes Potential. Betreiber verfügen klassischerweise über große Mengen an historischen Prozessdaten, die es zu nutzen gilt. Rein datengetriebene Verfahren, sogenannte Big Data Methoden, scheitern im Umfeld der Prozesstechnik jedoch oft an den spezifischen Randbedingungen der Branche. Beispiele hierfür ist das Fehlen von Daten, welche Fehlerfälle ausreichend beschreiben. Weiterhin ist auch die Qualität der aufgezeichneten Daten aus Datenanalyse-sicht nicht ausreichend. Neben den Daten selbst birgt auch deren Erfassung Hindernisse. Oftmals werden zusätzliche Daten erhoben, welche aber aufgrund von Feld-

busbeschränkungen oder der Geschlossenheit der Systeme nicht oder nur teilweise genutzt werden. Zuletzt sind auch stetige Anlagenevolutionen eine Herausforderung für die Nutzung von Datenanalysen im Feld.

Die effiziente Kombination datengetriebener Verfahren mit Expertenwissen, aber auch die Beeinflussung und Kontrolle der gesamten Prozesskette von der Datenerhebung bis zur –nutzung, kann diese Hindernisse überwinden. Neben offenen Schnittstellen, und zweiten, rückwirkungsfreien Datenkanälen spielt auch die Formalisierung von Expertenwissen eine entscheidende Rolle. Fehlende Daten können so beispielsweise durch einfache Korrelationen ausgedrückt und berücksichtigt werden. Weiterhin können Prüfstandmessungen die Rohdaten ergänzen. Diese Ansätze werden unter dem Begriff Smart Data zusammengefasst.

Letztlich kann das volle Potential der Datenanalyse aber erst durch flottenbasierte Analysen über gesamte Unternehmen oder sogar unternehmensübergreifend entfaltet werden. Durch die Vereinigung der Datensätze und das gemeinsame Lernen aus diesen Daten kann die Qualität der Analysen deutlich verbessert werden. Insofern beschreibt Industrie 4.0 nicht nur die Vernetzung von Anlagen und technischen Einrichtungen innerhalb eines Standorts oder Unternehmens, sondern darüber hinaus die Vernetzung zwischen Unternehmen. Durch die Etablierung von Marktplätzen können potentiell auch externe Anbieter eingebunden werden, um beispielsweise Anlagenausfälle als Dienstleistung vorherzusagen.

Das Forschungsprojekt SIDAP hat in diesem Bereich und bei der Analyse der spezifischen Herausforderungen, sowie Entwicklung von Lösungskonzepten entscheidende Pionierarbeit geleistet. Für die industrielle Nutzung müssen die entwickelten Ansätze nun weiterentwickelt werden. Auch hierbei können die in SIDAP involvierten Akteure voneinander profitieren und Synergieeffekte nutzen.

1.5 Danksagung

Der Autor bedankt sich beim BMWi für die Förderung des Projekts SIDAP (Förderkennzeichen 01MD15009F) als auch bei den Kooperationspartnern des SIDAP-Konsortiums für die Unterstützung.

Literatur

- [MB12] A. McAfee, E. Brynjolfsson, T.H. Davenport, D.J. Patil, D. Barton. "Big Data. The management Revolution". Harvard Bus Review, Vol. 90(10), S. 61-67, 2012.
- [GP+12] M. Graube, J. Pfeffer, J. Ziegler, L. Urbas. "Linked Data as Integrating Technology for Industrial Data". International Journal of Distributed Systems and Technologies (IJ DST), Vol. 3(3), S. 40–52, 2012.
- [VS+15] B. Vogel-Heuser, D. Schütz, J. Folmer. "Criteria-based Alarm Flood Pattern Recognition using Historical Data from Automated Production Systems (aPS)". In: Mechatronics, Vol. 3, 2015, S. 89-100.
- [FK+05] J. Folmer, I. Kirchen, E. Trunzer, B. Vogel-Heuser, T. Pötter, M. Graube, S. Heinze, L. Urbas, M. Atzmüller, D. Arnu. "Big und Smart Data – Herausforderungen in der Prozessindustrie," Automatisierungstechnische Praxis (atp), Vol. 59, Nr. 1-2, S. 58-69, 2017.
- [KT+17] C. Klettner, T. Tauchnitz, U. Epple, L. Nothdurft, C. Diedrich, T. Schröder, D. Großmann, S. Banerjee, M. Krauß, C. Latrou, L. Urbas. „Namur Open Architecture – Die Namur-Pyramide wird geöffnet für Industrie 4.0,“ Automatisierungstechnische Praxis (atp), Vol. 59, Nr. 1-2, S. 20-37, 2017.
- [TK+17] E. Trunzer, I. Kirchen, J. Folmer, G. Koltun, B. Vogel-Heuser. "A Flexible Architecture for Data Mining from Heterogeneous Data Sources in Automated Production Systems," in IEEE International Conference on Industrial Technology (ICIT), 2017, S. 1106-1111.
- [TA+16] H. Temmen, U. Argast, R. Welke, M. Theißen, M. Wiedau. „Intelligenter R&I-Austausch – DEXPI hat einen wesentlichen Meilenstein erreicht,“ Automatisierungstechnische Praxis (atp), Vol. 58, Nr. 3, S. 54-65, 2016.
- [DE18] www.dexpi.org (aufgerufen am 28.06.2018)

2 Systemarchitekturen für Smart Data Ansätze

Aggregiertes Konzept aus mehreren Projekten

E. Trunzer

*Lehrstuhl für Automatisierung und Informationssysteme,
Technische Universität München, Garching bei München
emanuel.trunzer@tum.de*

F. Pethig

*Fraunhofer IOSB-INA, Institutsteil für industrielle Automation, Lemgo
florian.pethig@iosb-ina.fraunhofer.de*

2.1 Einleitung und Motivation

Globalisierung und hoher Wettbewerbsdruck erfordern von produzierenden Unternehmen neue Lösungen wie die Digitalisierung bestehender Produktionsprozesse, massiven Informationsaustausch und die Entwicklung neuer Geschäftsmodelle. Die neuen Technologien werden unter anderem als Industrie 4.0, Cyber-Physikalische Produktionssysteme (CPPS) oder Industrial Internet of Things (IIoT) bezeichnet. [BB+15]

Eine wesentliche Voraussetzung, um das volle Potenzial von Industrie 4.0-Anwendungen auszuschöpfen ist die Nutzung großer Datenmengen und Datenanalysemethoden in Produktionssystemen. Diese Methoden werden eingesetzt, um unbekanntes Wissen aufzudecken, Prozessverbesserungen zu ermöglichen und die Gesamtanlageneffektivität (OEE) zu erhöhen. In modernen automatisierten Produktionssystemen haben die erzeugten Daten viele Gemeinsamkeiten mit großen Daten aus dem IT-Umfeld (Big Data), welche über die vier V's (Volumen, Vielfalt, Geschwindigkeit (Velocity) und Nutzen (Value)) definiert werden [HY+15]. Mehrere Faktoren erschweren die automatisierte Datenanalyse im Bereich der Produktionssysteme. Insbesondere die Vielzahl und Heterogenität von Datenquellen, Formaten und Protokollen durch lange Lebenszyklen (bis zu 30 Jahre) in der Produktionsumgebung stellen eine Herausforderung dar (Vielfalt). Darüber hinaus müssen große Mengen an historischen Daten (Volumen) mit kontinuierlich übertragenen Daten aus der Anlage kombiniert werden, um Entscheidungen (Nutzen) zeitnah auf Basis der Analyseergebnisse (Geschwindigkeit) zu treffen. Klassische Ansätze der Datenanalyse sind in diesem heterogenen Automatisierungskontext nicht direkt anwendbar. Daher müssen neue, innovative Systemarchitekturen

für den Einsatz von Big Data Analysen in automatisierten Produktionssystemen entwickelt werden, welche die Automatisierungstechnische Sicht und die Datenanalyse verbinden [VH16, JO+17].

Diese Schwierigkeiten werden am Beispiel der Prozessindustrie deutlich: Eine Vielzahl von Sensoren erfasst kontinuierlich Prozessdaten, die hauptsächlich zu Dokumentationszwecken in Datenbanken gespeichert werden. Ein Manufacturing Execution System (MES) dient der Verwaltung von Daten zur Ressourcenplanung und Auftragsabwicklung. Darüber hinaus enthält ein Schichtbuch Informationen über Bediener, die für die Überwachung der Betriebsweise und der Vorkommnisse während ihrer Schichten verantwortlich sind. Ergänzend können weitere Qualitäts- und Wartungsdaten in anderen Systemen oder Datenbanken gespeichert werden. Zusammen bilden sie ein komplexes Netzwerk aus ineinander verwobenen IT-Systemen, die an unterschiedlichen Standorten auf unterschiedlichen, oft inkompatiblen Datenformaten basieren. Die Gewinnung von Wissen aus dieser heterogenen Struktur ist schwierig und ohne großen manuellen Aufwand von Experten oft unmöglich. Eine Architektur zur Vereinheitlichung des Datenzugriffs könnte daher die Möglichkeiten und Auswirkungen der Datenanalyse in Produktionsumgebungen erheblich verbessern. Dies kann erreicht werden, indem alle relevanten Quellen einbezogen und ihre Daten für Analysewerkzeuge zur Verfügung gestellt werden. So wird eine transparente Berechnung ermöglicht. Unter dem Begriff "Architektur" verstehen die Autoren in diesem Zusammenhang die Beschreibung des Gesamtsystems nach Prinzipien und Regeln, um dessen Aufbau, Erweiterung und Nutzung zu beschreiben. Diese Definition entspricht dem Referenzarchitekturmodell Industrie 4.0 (RAMI 4.0) [DIN16].

Neben der reinen Vernetzung der Systeme und der Ermöglichung von technischer Interoperabilität ist auch die Schaffung syntaktischer und semantischer Interoperabilität notwendig [EN11]. Hierunter versteht man ein gemeinsames Verständnis über die Bedeutung und Interpretation der Daten. Beispielsweise werden Durchflusswerte in Produktionsanlagen als Massen- und Volumendurchflüsse erhoben. In den Datenbanken der Prozessleitsysteme fehlt die Information über die physikalischen Einheiten zumeist. Deshalb ist bei der Übertragung der Daten unklar, um welche Art von Durchfluss es sich handelt und ob dieser beispielsweise in Tonnen pro Stunde oder Liter pro Minute gespeichert wurde. Das Fehlen dieser Informationen erschwert die Datenanalyse deutlich oder macht diese sogar unmöglich. Bei der Vernetzung einer großen Anzahl an Systemen mit den Zielen einer nahtlosen Zu-

sammenarbeit und des transparenten Datenzugriffs, ist eine Selbstbeschreibung der Daten notwendig. Zwischen allen Partnern und Systemen muss ein einheitliches Verständnis für die Daten hergestellt werden. Nur so kann das volle Potential der Daten gehoben werden. Die Schaffung eines sogenannten gemeinsamen Informations- oder Datenmodells ist ein aufwändiger Schritt und muss zu Beginn meist händisch ausgeführt werden.

Dieser Beitrag beschreibt eine generische Architektur, die auf verschiedene Szenarien angewendet werden kann, und deren konkrete Anwendung und Umsetzung für ein Produktionssystem im Labormaßstab gezeigt wird. Besonderes Augenmerk wird dabei auf die vielfältigen Anforderungen aus automatisierten Produktionssystemen, Altsystemen, heterogenen Quellen und Datenverarbeitung gelegt. Der Beitrag ist eine angepasste Version der auf der IEEE ICIT 2017 [TK+17] und im Rahmen des IMPROVE-Sammelbandes [TL+18] präsentierten Beiträge. Die Architektur wurde für Anwendungsfälle innerhalb von SIDAP² und IMPROVE³ gleichermaßen entwickelt um eine möglichst universelle Lösung zu entwickeln. Während sich SIDAP im Umfeld der chemischen Prozesstechnik bewegt, verfolgt IMPROVE das Ziel der Schaffung einer digitalen Fabrik, welche zur Optimierung echter Produktionsprozesse verwendet werden kann.

2.2 Aktueller Stand der Forschung und Technologie

Im Rahmen von Industrie 4.0 und des Industrial Internet of Things (IIoT) existieren mehrere Referenzarchitekturen. Die wichtigsten sind das deutsche Referenz-Architekturmodell Industrie 4.0 (RAMI 4.0) [DIN16], die American Industrial Internet Reference Architecture (IIRA) [IIRA17] und der Entwurf des internationalen Standards ISO/IEC CD 30141 [ISO16] für die Internet of Things Reference Architecture (IoT RA). Diese Referenzarchitekturen bieten eine abstrakte, technologieneutrale Darstellung eines IIoT-Systems und Regeln für die Entwicklung einer realen Architektur. Sie stellen daher eine abstrakte Beschreibung dar, die übernommen werden soll, um die spezifischen Eigenschaften eines realen Systems darzustellen.

Die Namur Open Architecture (NOA) von Klettner et al. [KT+17] ist eine zusätzliche Struktur zur klassischen Produktionspyramide [EN14]. Ihre

² Skalierbares Integrationskonzept zur Datenaggregation, -analyse, -aufbereitung von großen Datenmengen in der Prozessindustrie; <http://www.sidap.de>, aufgerufen am 18.07.2018.

³ Innovative Modelling Approaches for Production Systems to Raise Validatable Efficiency; <http://www.improve-vfof.eu>, aufgerufen am 18.07.2018.

Struktur ermöglicht einen offenen Informationsaustausch über einen sekundären Kommunikationskanal zwischen nicht benachbarten Ebenen der Automatisierungspyramide und einen sicheren Rückfluss aus einer IT-Umgebung in die Prozesssteuerung. Die NOA legt fest, wie Informationen von der Kernprozesssteuerung auf anlagenspezifische Überwachungs- und Optimierungsanwendungen übertragen werden. Dies wird durch offene und herstellerunabhängige Schnittstellen erreicht. Ein besonderes Interesse der NOA ist die Unterstützung verschiedener bestehender Systeme und Datenquellen. Die Architektur kann mit verschiedenen Anwendungen und Analysemiteln verbunden werden. Ein organisationsübergreifender Datentransfer ist über den Teil "Zentrales Monitoring + Optimierung" vorgesehen. NOA beschreibt zwei Kanäle für den Datentransfer von Feldgeräten zum Analyseteil ("Central M+O"). Der direkte Weg kann für die Übertragung von Echtzeitdaten genutzt werden, während offene Schnittstellen für die Verarbeitung von Chargendaten genutzt werden können.

Das Konzept des Enterprise Service Bus (ESB) wurde von Chappell [C04] vorgeschlagen. Der ESB beschreibt eine Kommunikations- und Integrationsplattform, um verschiedene Anwendungen und Technologien in einem Unternehmen zu verbinden. Er nutzt Webservicetechnologien und unterstützt verschiedene Kommunikationsprotokolle und -dienste. Eines der Hauptziele des ESB ist die Einbeziehung verschiedener heterogener Quellen und Dienste. Dies wird durch die Verwendung eines gemeinsamen Datenmodells für die Weiterleitung von Nachrichten über den zentralen Bus erreicht, welches aber im Konzept des ESB selbst nicht beschrieben wird und anwendungsfallsspezifisch zu erstellen ist. Typische Vertreter von ESB sind die OpenSource-Projekte Apache Camel⁴ und RabbitMQ⁵, sowie verschiedene kommerzielle Vertreter (z.B. IBM WebSphere ESB, Microsoft BizTalk, Oracle ESB und SAP Process Integration).

Auch die OPC Unified Architecture (OPC UA) der OPC Foundation [DIN15] kann als Integrationsplattform genutzt werden. OPC UA sieht einen klar strukturierten Adressraum (Metamodell) und ein einheitliches Informationsmodell (genormte Knoten) vor. Das OPC UA Informationsmodell beschreibt sowohl genormte Typen, als auch genormte Instanzen (z. B. zur Diagnostik). Von diesen Basismodellen abgeleitete serverspezifische Informationsmodelle müssen für die übergreifende Anwendung jedoch weiterhin vereinheitlicht

⁴ <http://camel.apache.org/>, aufgerufen am 18.07.2018.

⁵ <https://www.rabbitmq.com/>, aufgerufen am 18.07.2018.

werden. Zur Vereinheitlichung arbeitet die OPC Foundation an branchenspezifischen Informationsmodellen, sogenannten Companion Specifications. Ein Beispiel für eine Companion Specification ist EUROMAP 77⁶. EUROMAP 77 definiert ein Informationsmodell für Spritzgieß- und Gummimaschinen. Doch auch die branchenspezifischen Informationsmodelle müssen in einen übergeordneten Kontext zur Datenanalyse eingebettet werden. Aktuelle OPC UA-Implementierungen basieren zumeist auf dem Client/Server-Kommunikationsparadigma, dessen Skalierbarkeit in Zeiten von Industrie 4.0 oftmals unzureichend ist. Über sogenannte Discovery Services können OPC UA Server im Netzwerk identifiziert werden. Die bereitgestellten Daten müssen dann dezentral von Clients abgefragt werden. Alternativ bietet sich die Verwendung eines Aggregation Servers an, welcher die Informationen mehrerer OPC UA Server sammelt und zentral bereitstellt. In größeren Netzwerken stößt dieser Ansatz aber an seine Grenzen. Mit dem zweiten spezifizierten Kommunikationsparadigma, PubSub, begegnet die OPC Foundation dieser Herausforderung [OF18]. PubSub bietet eine lose Kopplung von Publishern und Subscribern, die sich nicht gegenseitig kennen und eine Verbindung zueinander aufbauen müssen. In einem lokalen Netzwerk wird diese lose Kopplung durch UDP-Multicast-Mechanismen (UADP) erreicht. In einer Broker-basierten Variante wird ein Protokoll-Mapping der zu übertragenden Informationen auf MQTT [ISO16] oder AMQP [ISO14] spezifiziert. Mit PubSub unterstützt OPC UA die Verwendung von ESBs zur Verteilung und Zustellung der modellierten Informationen. Dies ermöglicht eine bessere Skalierbarkeit und Quality of Service (QoS). OPC UA ist in Form einer Referenzimplementierung und von OpenSource-Projekten⁷ frei verfügbar, die PubSub-Spezifikation wird von diesen wahrscheinlich im Laufe dieses Jahres abgedeckt.

Eine Alternative zu OPC UA stellt der Data Distribution Service (DDS) der Object Management Group (OMG) dar [OMG15]. Der Ansatz beschreibt eine dezentrale Architektur zum Verteilen von Daten in großen Netzwerken. DDS bietet daher eine gute Skalierbarkeit, eine umfassende Unterstützung für Quality of Service und Echtzeitfähigkeit durch Verwendung eines geeigneten Protokolls für die Kommunikation. Während die Spezifikation von DDS frei verfügbar ist, existieren verschiedene offene und proprietäre Umsetzungen, welche die Spezifikation unterschiedlich und in verschiedenen Umfängen umsetzen.

⁶ <http://www.euromap.org/en/euromap77/>, aufgerufen am 18.07.2018.

⁷ <https://open62541.org/>, aufgerufen am 18.07.2018.

2.3 SIDAP/IMPROVE-Systemarchitektur

Im Folgenden wird das Konzept der SIDAP/IMPROVE Systemarchitektur unter besonderer Berücksichtigung der Eignung für unterschiedliche Anwendungsfälle abgeleitet. Der Fokus liegt auf der Definition des Gesamtkonzeptes in technologieunabhängiger Form, d.h. die spezifischen Technologien für eine Implementierung können an die Anforderungen des jeweiligen Anwendungsfalles angepasst werden (z.B. Einsatz von MQTT anstelle von OPC UA oder Apache Kafka⁸ anstatt eines Enterprise Service Bus). Anschließend wird die prototypische Umsetzung auf Labormaßstab unter Verwendung konkreter Technologien gezeigt.

2.3.1 Konzept der Systemarchitektur

Um verschiedene Analysemethoden, Werkzeuge und bestehende Altsysteme zu unterstützen, sind standardisierte Schnittstellen notwendig. Die Verwendung einer Schichtenstruktur mit klar definierten Schnittstellen vereinfacht die Rekonfiguration und Anpassung an eine Vielzahl von Anwendungsfällen. Die Architektur unterscheidet zwischen Schichten für die Bereitstellung von Rohdaten, die Analyse von Daten und die Anzeige von Daten. Der so genannte Datenmanagement- und -integrationsbroker verbindet Datenquellen mit ihren Konsumenten und überträgt Daten zwischen den Komponenten und Schichten der Architektur. Diese Aufteilung ermöglicht sowohl die Anbindung bestehender Altanwendungen als auch neu hinzukommender Software- und Hardwarekomponenten über die definierten Schnittstellen.

Die Architektur verfügt über einen zentralen Datenspeicher, um Daten zu speichern und für spätere Analysen zur Verfügung zu stellen. Echtzeitdaten aus Datenquellen werden vom Broker in den Datenspeicher übertragen und dort zur Verfügung gestellt. Je nach Anwendungsfall (z.B. Anzahl der Quellen und Nachrichtenintensität) kann die Datenspeicherung eine relationale oder nicht-relationale Datenbank sein. Komponenten der Analyse- oder Anzeigeschicht können über die oben genannten Standardschnittstellen Daten aus dem Storage über den Broker anfordern. Die zentrale Datenhaltung gewährleistet eine breite Verfügbarkeit der Daten für alle Schichten. Der Datenmanagement- und -integrationsbroker stellt nicht nur historische Daten, sondern auch Echtzeitdaten zur Verfügung und kann Live-Daten an Teilnehmer der oberen Schichten übertragen.

⁸ <http://kafka.apache.org/>, aufgerufen am 18.07.2018.

Für den Datentransfer über Organisationsgrenzen hinweg ist eine Zugriffskontroll- und Anonymisierungskomponente erforderlich. Insbesondere bei der Arbeit mit Daten aus anderen Organisationseinheiten oder Unternehmen kommt dem Datenschutz und der Integrität der Daten eine große Bedeutung zu. Das Bekanntwerden von Daten, welche nicht übertragen werden sollten, muss vermieden werden. Daher verfügt der Broker über eine Zugriffskontroll- und Anonymisierungsschicht, die nur einen genehmigten Datenzugriff garantiert. Die Inhalte können je nach Anforderung und Sicherheitsfreigabe anonymisiert oder zugriffsbeschränkt sein.

Ein gemeinsames Datenmodell ist notwendig, um das dargestellte System und seine Daten einheitlich und in einer Sprache zu beschreiben, welche von allen Schichten und Komponenten verstanden wird. Das Datenmodell muss Darstellungen der Rohdaten, zusätzliche Metadaten (Anreicherung der Rohdaten mit Informationen über Maßeinheiten, zugehörige Geräte usw.), zuvor erlernte und vorkonfigurierte Modelle, Bedienerkenntnisse, Parametersätze und Konfigurationen der Komponenten enthalten. Jedes System kann mit einer Teilmenge des Gesamtdatenmodells zur Durchführung seiner Operationen arbeiten. Daten, die nicht mit dem gängigen Modell übereinstimmen müssen von Datenadaptern umgewandelt und übertragen werden, um mit den anderen Daten kompatibel zu sein. Mit Wrappern können Anwendungen von Drittanbietern gekapselt und standardisierte, kompatible Schnittstellen bereitgestellt werden. Die Zuordnung und Anpassungen der verschiedenen Sichtweisen auf die Daten müssen derzeit von Hand durchgeführt werden, wenn es sich um ein neues Datenmodell oder Änderungen während des Asset-Lebenszyklus handelt. Insbesondere bei Altsystemen kann der Aufwand für die Übersetzung von Daten hoch sein, aber die Vorteile, die sich aus dem Umgang mit nur einem gemeinsamen Datenformat ergeben, wie die einfache Inbetriebnahme neuer Funktionen, sowie die hohe Kompatibilität und erhöhte Flexibilität, sind erheblich. Dies ist auch ein Grund, warum ein paralleler Rollout der Architektur zu bestehenden Systemen und eine schrittweise Anpassung, vorgeschlagen werden. Dies minimiert den initialen Übersetzungsaufwand, nutzt aber die Vorteile der Architektur und des Datenmodells an den notwendigen Stellen. Je größer die Zahl an portierten Systemen, desto größer wird mit der Zeit auch der Synergieeffekt, der sich durch die Portierung weiterer Systeme ergibt. Zukünftig können geeignete Verfahren des maschinellen Lernens auf Basis der manuellen Verknüpfungsregeln, welche bei der händischen Verknüpfung zweiter Informationsmodelle erstellt wurden, Anpassungen automatisch vornehmen bzw. den Aufwand verringern.

Abbildung 2.1 zeigt die konzeptionierte Architektur, die eine Unternehmens- oder Organisationsstruktur widerspiegelt. Jedes Unternehmen oder jede Struktur kann einen eigenen Teil der Architektur einsetzen, was eine Kommunikation über den Broker und die Analyse der an einem anderen Ort gespeicherten Daten ermöglicht. Mehrere Instanzen des Brokers können miteinander kommunizieren und Daten austauschen.

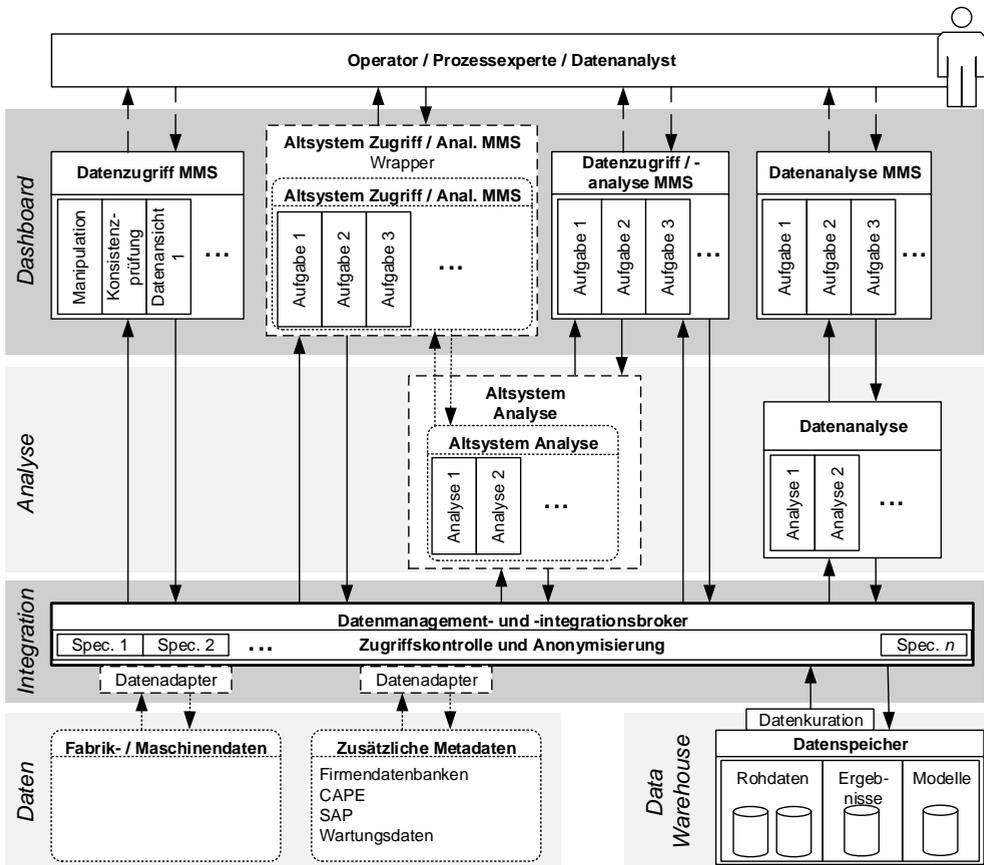


Abbildung 2.1: Schematischer Aufbau der entwickelten Systemarchitektur [TK+17, TL+18].

2.3.2 Praktische Umsetzung des Ansatzes an einem Beispiel

Um die Anwendbarkeit des Konzepts zu überprüfen, wird eine prototypische Umsetzung im Labormaßstab umgesetzt. Zur Simulation einer heterogenen Produktionsumgebung wird als Hauptdatenquelle für Produktionsdaten eine Laboranlage, die so genannte Extended Pick and Place Unit (xPPU) [VL+14], verwendet. Die xPPU ist in der Lage, Werkstücke zu sortieren, zu kommissionieren und zu platzieren, unter anderem mit Kränen, Förderbändern und einer Vielzahl von Sensoren. Als sekundäre Datenquelle werden Auftragsdaten aus einer csv-Datei gelesen. Die Daten werden an einen Message Broker gesendet, in ein gemeinsames Datenformat übersetzt und in einer relationalen Datenbank gespeichert. Analyser können Anfragen nach Chargendaten an den Broker senden. Diese Anfragen werden an die Datenbank weitergeleitet, die Ergebnisse ggf. anonymisiert und den Analysen zur Verfügung gestellt. Darüber hinaus können Analysatoren Live-Daten abonnieren, die aus den beliebigen Quellen stammen. Um die Heterogenität der Produktionsumgebung zu replizieren, werden verschiedene Betriebssysteme sowie Programmiersprachen zur Realisierung der einzelnen Anwendungen eingesetzt. Der gesamte Aufbau ist in Abbildung 2.2 dargestellt und zeigt Hardwarekomponenten, Betriebssysteme, Software und Datenflüsse zwischen den Elementen der Architektur. Der Aufbau ist im Folgenden detailliert beschrieben.

Im prototypischen Aufbau kommunizieren die Buskoppler der xPPU über EtherCAT mit einer Speicherprogrammierbaren Steuerung (SPS) der Firma Beckhoff vom Typ CX9020, die mit Windows 7 CE und TwinCAT 3 betrieben wird. Diese SPS stellt ihre Prozessdaten im Beispiel über zwei verschiedene Kommunikationskanäle, MQTT und einen OPC-UA-Server, zur Verfügung.

MQTT [ISO16] ist ein Publish-Subscribe-basiertes, leichtgewichtiges Protokoll, das für Machine-to-Machine-Kommunikation (M2M) geeignet ist. Mit dem TwinCAT-Funktionsbaustein *Tc3_IotMqttClient*⁹ wird die MQTT-Client-Funktionalität auf der SPS verfügbar. Auf diese Weise werden Meldungen mit sogenannte Topics, zum Beispiel mit der Bezeichnung "EnergyMonitoringHardware/CurrentPressure/Int" oder "LightGrid/EmergencyStop/Bool" pro Zyklus (im Beispiel eine Zykluszeit von 10ms) gesendet. Diese Nachrichten enthalten die Prozesswerte der jeweiligen Variablen der xPPU.

⁹ https://infosys.beckhoff.com/english.php?content=../content/1033/tf6701_tc3_iot_communication_mqtt/4221526923.html&id=, aufgerufen am 18.07.2018.

Darüber hinaus stellt die SPS einen OPC-UA-Server zur Verfügung, der den Clients die Zustände anderer ausgewählter Variablen zur Verfügung stellt. Im Beispiel wird ein Einplatinencomputer vom Typ Raspberry Pi 3 als Client für die SPS verwendet. Er arbeitet mit Raspbian (Debian-Linux für ARM), das einen OPC UA Client unter Verwendung der .Net Standard Referenzimplementierung der OPC Foundation¹⁰ ausführt. Außerdem abonniert er eine Reihe von Variablen und übersetzt die empfangenen Daten in das gemeinsame Datenmodell über im Client implementierte Verknüpfungsregeln. Diese Daten werden dann an den angeschlossenen Broker gesendet.

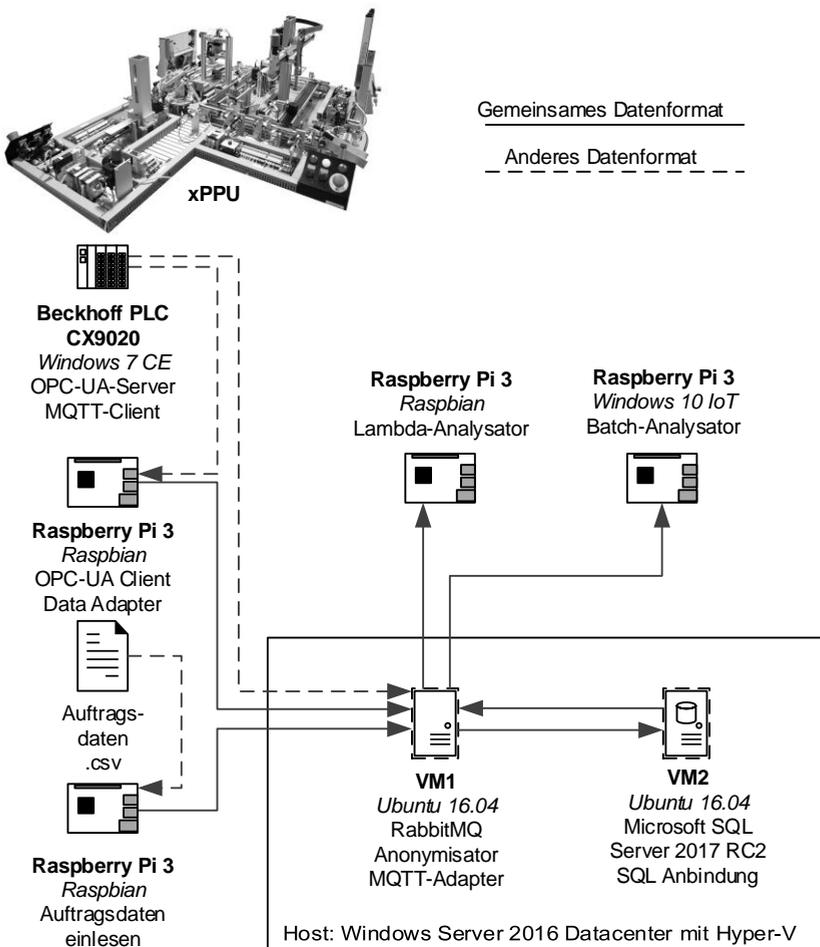


Abbildung 2.2: Hardware- und Softwareaufbaue der prototypischen Implementierung der Systemarchitektur am Beispiel der xPPU [TL+18].

¹⁰ <https://github.com/OPCFoundation/UA-.NETStandard>, aufgerufen am 18.07.2018.

Um die Verarbeitung von historischen Daten zu simulieren, wird eine csv-Datei mit Auftragsinformationen von einem Java-Programm auf einem anderen Raspberry Pi 3 mit Raspbian gelesen, direkt in das gängige Datenformat überführt und an den Broker gesendet. Das Gerät simuliert einen Datenadapter, der Daten von einem in das andere Format übersetzt und somit die Anbindung von bestehenden Altsystemen in die Industrie 4.0-Umgebung erlaubt.

Mit Hyper-V (Hypervisor zur Virtualisierung) auf einem Windows Server 2016 Datacenter Host, der mit einer Core i7-6700 CPU und 16 GB RAM ausgestattet ist, wurde Ubuntu Linux 16.04 LTS x64 auf zwei virtuellen Maschinen (VM) installiert.

Auf der ersten VM sind der Open-Source-ESB RabbitMQ in der Version 3.6.11, sowie ein auf .Net Core 2.0 basierender Anonymisator und Datenadapter für MQTT-Nachrichten, installiert. RabbitMQ arbeitet mit sogenannten Queues (Warteschlangen), an die Nachrichten gesendet werden können, und Exchanges (Austauschpunkte), welche Queues verbinden. Dieses Setup ermöglicht eine Verteilung der Nachrichten an die richtigen Empfänger. Der Datenadapter empfängt von der SPS gesendete MQTT-Nachrichten und übersetzt diese in das gängige Datenformat. Hat der anfragende Analysator nur eingeschränkte Zugriffsrechte, ändert der Anonymisator beispielsweise Daten und Zeitwerte zu relativen Werten.

Die zweite VM führt die Datenbankkomponenten aus. In diesem Fall handelt es sich um einen Microsoft SQL Server 2017 RC2 und einen .NET Core 2.0 basierten SQL Connector, der Nachrichten und Anfragen vom Broker empfängt und die Datenbankkommunikation mit Microsoft Entity Framework Core 2.0 abwickelt. Im Vergleich zu den Vorgängerversionen ist der SQL Server in Version 2017 erstmals auch auf Linux ausführbar.

Mit zwei weiteren Raspberry Pi 3, einer mit Raspbian, einer mit Windows 10 IoT, werden Instanzen von .NET Core 2.0 basierten Analysatoren ausgeführt. Diese können Live-Daten aus Quellen abonnieren, Daten aus der Datenbank anfordern, Berechnungen der Daten durchführen, berechnete Daten an den Broker senden oder die Ergebnisse anderer Analysatoren anhören.

Mit diesem Aufbau wird die Machbarkeit der Implementierung einer Architektur zur Vereinheitlichung des Datentransfers in automatisierten Produktionssystemen demonstriert. Basierend auf plattformunabhängigen Technologien wie .NET Core 2.0, Java und einem Open Source Message Broker, der

unter Windows, Linux und MacOS ausgeführt werden kann, kann die Implementierung in heterogenen IT-Umgebungen ausgerollt werden. Mit Hilfe von Adaptern und Übersetzern wird die Transformation von Nachrichten in ein gemeinsames Datenmodell durchgeführt. Es ist möglich, beliebige Analytoren (einschließlich Altsystemen) an den Message Broker RabbitMQ anzuschließen, da er Clients und Entwicklertools für viele Programmiersprachen (z.B. Java, .Net, Python, PHP, JavaScript, Objective-C, C, C++) zur Verfügung stellt, was auch in der für die Demonstration gewählten heterogenen Umgebung gezeigt wurde. Analyser können sowohl auf historische als auch auf Live-Daten zugreifen. Durch die Verwendung verschiedener Rollen mit unterschiedlichen Zugriffsrechten auf den Broker ist die Datensicherheit gewährleistet. Da die Daten bei Bedarf automatisch anonymisiert werden können, können auch sensible Informationen ausgetauscht werden. Mit dem Shovel-Plugin¹¹ von RabbitMQ ist es möglich verschiedene Standorte anzubinden. Für die Realisierung der Architektur wird betont, dass die ausgewählten Technologien, Sprachen oder Broker nur von untergeordneter Bedeutung sind; die dargestellte prototypische Umsetzung ist nur eine mögliche Lösung für diesen speziellen Anwendungsfall.

2.4 Zusammenfassung

Die Anwendung von Big Data-Technologien im Bereich der Fertigung ist derzeit aufgrund der Vielzahl von Protokollen und Datenformaten, die von bestehenden System verwendet werden, stark eingeschränkt. Die manuelle Datenerfassung aus einem geschlossenen, proprietären System und die anschließende Integration der Daten durch Experten sind oft die einzige Möglichkeit, auf die große Menge an Messdaten zuzugreifen. Es besteht jedoch die Notwendigkeit, diese Daten automatisch verfügbar zu machen, um daraus Informationen zu gewinnen, insbesondere mit dem Aufkommen der Ideen des IIoT und der Industrie 4.0. Für CPS und CPPS spielen die Transparenz von Informationen sowie die Big Data-Analyse eine große Rolle. Neue, flexible Architekturen sind notwendig, um diese Informationen zugänglich zu machen und große Datenmengen im Bereich der Automatisierung einzusetzen.

Dieser Beitrag stellt eine konzeptionelle Industrie 4.0-Architektur für die Datenerfassung, Integration und Handhabung von der Feldgeräteschicht bis hin zu Geschäftsanwendungen vor. Sie bietet Mechanismen für die vertikale und horizontale Integration. Die Vereinheitlichung von Datenzugriff und -transport zur Abstraktion der Komplexität der beteiligten Systeme ist ein zentraler

¹¹ <https://www.rabbitmq.com/shovel.html>, aufgerufen am 18.07.2018.

Bestandteil des Ansatzes. Referenzmodelle für IIoT, wie das deutsche RAMI4.0 oder das amerikanische IIRA, legen den Grundstein für eine solche Architektur, erfassen aber aufgrund ihrer generischen Natur keine anwendungsspezifischen Aspekte. Bestehende Konzepte zur Datenerfassung und -integration im Bereich der Automatisierung lassen oft die Berücksichtigung eines unternehmensübergreifenden Datenaustausches für die Zusammenarbeit und Offenheit der Schnittstellen vermissen. Die konzeptualisierte Architektur verwendet einen Middleware-Ansatz, um die Daten verfügbar zu machen und die Anzahl der Datentransformationen zwischen den angebundenen Systemen zu minimieren, indem sie die Verwendung eines gemeinsamen Informationsmodells vorschlägt.

Am Beispiel einer Laboranlage wird gezeigt, dass die Architektur prototypisch implementiert werden kann und in der Lage ist, Daten aus heterogenen Quellen zu übertragen und zu verarbeiten. Als Middleware-Komponente erhielt der Open Source Message Broker RabbitMQ Dateneingaben von MQTT und OPC UA Quellen, die über Adapter in ein gemeinsames Informationsmodell übertragen wurden. Sowohl der Zugriff auf übertragene Live-Daten, als auch auf historische Daten, konnte demonstriert und neue Möglichkeiten der Datenanalyse konnten eröffnet werden.

Um die Eignung für reale Produktionsumgebungen nachzuweisen, sind weitere Tests mit größeren Prototypen und mehr Datenquellen erforderlich. Besonderes Augenmerk muss auf die Formulierung eines Informationsmodells gelegt werden, das für generische Anwendungsfälle geeignet ist und die Übertragung aus verschiedenen Datenformaten ermöglicht. Andere Technologien für die Middleware, wie z.B. Apache Kafka, OPC UA oder DDS-Systeme, sollten ebenfalls evaluiert und ihre Eignung für den Einsatz in der Praxis verglichen werden. Noch wichtiger ist die reale Analyse der Daten und die Nutzung des neu gewonnenen Wissens.

2.5 Danksagung

Die Autoren bedanken sich beim BMWi für die Förderung des Projekts SIDAP (Förderkennzeichen 01MD15009F), als auch bei der Europäischen Union für die Förderung des Projekts IMPROVE (Förderkennzeichen 678867). Durch den gemeinsamen Ansatz innerhalb der Projekte konnte eine größere Bandbreite an Anforderungen ermittelt und adressiert werden. Weiterhin bedanken sich die Autoren bei den Kooperationspartnern der SIDAP und IMPROVE-Konsortien für die Unterstützung bei Konzeption und Umsetzung.



Literatur

- [BB+15] H. Bauer, C. Baur, G. Camplone. “Industry 4.0. How to Navigate Digitization of the Manufacturing Sector,” 2015, tech. rep., McKinsey Digital.
- [HY+15] I.A.T. Hashem, I. Yaqoob, N.B. Anuar, S. Mokhtar, A. Gani, S. Ullah Khan. “The Rise of “Big Data” on Cloud Computing,” in Review and Open Research Issues. Information Systems, 2015, 47, S. 98–115.
- [VH16] B. Vogel-Heuser, D. Hess. „Guest Editorial Industry 4.0–Prerequisites and Visions,” in IEEE Trans. Automat. Sci. Eng, 13, 2016, S. 411–413.
- [JO+17] V. Jirkovsky, M. Obitko, V. Marik. “Understanding Data Heterogeneity in the Context of Cyber-physical Systems Integration,” in IEEE Trans. Ind. Inf., 13, 2017, S. 660–667.
- [DIN16] Deutsches Institut für Normung (DIN). „Referenzarchitekturmodell Industrie 4.0 (RAMI4.0),“ DIN SPEC 91345, 2016.
- [EN11] Europäisches Komitee für elektrotechnische Normung (CENELEC). “Fortgeschrittene Automatisierungstechnologien und deren Anwendung – Anforderungen für das Erreichen einer Prozessinteroperabilität in Fertigungsunternehmen – Teil 1: Rahmenwerk für die Unternehmensinteroperabilität (ISO 11354-1:2011),“ DIN EN 11354-1, 2011.
- [TK+17] E. Trunzer, I. Kirchen, J. Folmer, G. Koltun, B. Vogel-Heuser. “A flexible architecture for data mining from heterogeneous data sources in automated production systems,” in 2017 IEEE International Conference on Industrial Technology (ICIT), 2017, S. 1106-1111.
- [TL+18] E. Trunzer, S. Lötzerich, B. Vogel-Heuser. „Concept and Implementation of a Software Architecture for Unifying Data Transfer in Automated Production Systems,” in O. Niggemann, P. Schüller (Hrsg.): “IMPROVE - Innovative Modelling Approaches for Production Systems to Raise Validatable Efficiency,” Springer Vieweg, Wiesbaden, 2018.
- [IIRA17] The Industrial Internet of Things (IIRA). “Volume G1: Reference Architecture,” 2017.
- [ISO16] International Organization for Standardization (ISO). “Information technology – Internet of Things Reference Architecture (IoT RA),” ISO/IEC CD 30141, 2016.
- [KT+17] C. Klettner, T. Tauchnitz, U. Epple, L. Nothdurft, C. Diedrich, T. Schröder, D. Großmann, S. Banerjee, M. Krauß, C. Latrou, L. Urbas. „Namur Open Architecture – Die Namur-Pyramide wird geöffnet für Industrie 4.0,“ Automatisierungstechnische Praxis (atp), Vol. 59, Nr. 1-2, S. 20-37, 2017.

- [EN14] Europäisches Komitee für elektrotechnische Normung (CENELEC). “Integration von Unternehmensführungs- und Leitsystemen - Teil 1: Modelle und Terminologie,” DIN EN 62264-1, 2014.
- [C04] D. Chappell. “Enterprise Service Bus,” O'Reilly Media, Sebastopol, 2004.
- [DIN15] Deutsches Institut für Normung (DIN). “OPC Unified Architecture – Teil 1: Übersicht und Konzepte,” DIN CLC/TR 62541-1, 2011.
- [ISO16] International Organization for Standardization (ISO). “Information Technology – Message Queuing Telemetry Transport (MQTT) v3.1.1,” ISO/IEC 20922, 2016.
- [ISO14] International Organization for Standardization (ISO). “Information technology – Advanced Message Queuing Protocol (AMQP) v1.0 specification,” ISO/IEC 19464, 2014.
- [OF18] OPC Foundation. “OPC Unified Architecture – Specification – Part 14: PubSub,” Release 1.04, 2018.
- [OMG15] Object Management Group, “Data Distribution Service (DDS),” Version 1.4, 2015.
- [VL+14] B. Vogel-Heuser, C. Legat, J. Folmer, S. Feldmann. „Researching Evolution in Industrial Plant Automation. Scenarios and Documentation of the Pick and Place Unit,” 2014.

3 Schadensfallklassifikation von Ventilen und Retrofitting von bestehenden Anlagen

Anwendung für die Ventilfehlerdiagnose

C. Vermum

Evonik Industries AG, Marl

christian.vermum@evonik.com

S. Unland

SAMSON AG, Frankfurt am Main

sunland@samson.de

3.1 Einleitung und Motivation

Ungeplante Stillstandzeiten, verursacht durch technische Ausfälle oder menschliche Fehler, führen zu erheblichen Produktionsausfällen bei automatisierten Produktionssystemen (aPS) wie von Aoudia et al. in ihrer Untersuchung dargestellt [AB+08]. Die reale Gesamtverfügbarkeit der im Fallbeispiel untersuchten Anlage beträgt im Durchschnitt 79 % innerhalb der untersuchten fünf Jahre. Die Kosten für die verlorene Verfügbarkeit, vor allem verursacht durch ungeplante Ausfallzeiten, werden für diese einzelne Anlage auf rund 566 Mio. US\$ pro Jahr geschätzt. Dies unterstreicht die Bedeutung einer erhöhten Gesamtanlageneffektivität (OEE), durch das Reduzieren von ungeplante Stillstandzeiten und damit Produktionsausfällen. Insbesondere im Rahmen von Industrie 4.0 und Data-Mining spielt die Optimierung bestehender aPS zur Verbesserung der Anlageneffektivität eine wichtige Rolle [VH16]. Big-Data-Methoden zur Erkennung von Anomalien im Betrieb haben das Potenzial, ungewöhnliche Vorgänge zu identifizieren und mit entsprechenden Maßnahmen ungeplante Stillstandzeiten zu reduzieren. Um diese Algorithmen für die Anomalie-Erkennung effektiv nutzen zu können, muss jedoch zuvor Expertenwissen formalisiert werden, um geeignete Erkennungsmerkmale für die Datenanalyse zu definieren. So muss dem Algorithmus übergeben werden, nach welchen Merkmalen er beispielsweise den aktuellen Zustand eines Regelventils zu bewerten hat. Dies kann der Algorithmus zwar prinzipiell auch aus den Daten selbst lernen, doch ist häufig die Datenlage nur unzureichend. Sind nicht genügend Fehlerfälle in den Daten enthalten oder sind diese zu spezifisch und ist unklar, wann der Fehler aufgetreten ist, ist eine Merkmalsgewinnung aus Daten nur schwer möglich. Hier

kann die gezielte Nutzung von formalisiertem Expertenwissen im Analyseprozess den Ausschlag für eine erfolgreiche oder misslungene Datenanalyse geben.

Prozesstechnische Anlagen sind instrumentiert, um einen reibungslosen Betrieb und eine Erfüllung der gesetzlichen Dokumentationspflichten zu garantieren. Unter Berücksichtigung der Komplexität der zugrundeliegenden physikalischen Phänomene wird klar, dass für eine Datenanalyse an Regelventilen notwendige Daten oft nicht aufgezeichnet werden. So wird beispielsweise der tatsächliche Hub des Ventils oftmals nicht erfasst und lediglich der Sollwert übermittelt. Darüber hinaus wird eine Vielzahl der relevanten Messgrößen nicht im Ventil selbst erfasst, sondern durch benachbarte Sensoren aufgezeichnet. Soll die Anlage unter den Anforderungen der effizienten Datenanalyse nachgerüstet werden, um mehr Signale zu erfassen, müssen unter anderem oft Explosionsschutzbestimmungen berücksichtigt werden. Die Geschlossenheit der derzeitigen Systeme erschwert darüber hinaus die Anpassung der Instrumentierung an die gestiegenen Anforderungen durch die Datenanalyse. Hier sind Konzepte für eine einfache Nachrüstung industrieller Produktionsanlagen gefragt, die einen reibungslosen Weiterbetrieb der Anlagen sicherstellen.

In diesem Beitrag stellen die Autoren eine Systematisierung der Ausfallmodi von Regelventilen und ihrer zugrundeliegenden Mechanismen vor. Darüber hinaus werden Erkennungsmerkmale sowie erforderliche Parameter identifiziert. Dieser Teil basiert auf der Publikation der Autoren auf der IEEE IEEM [TW+17]. Weiterhin wird ein Retrofitting-Konzept für bestehende Anlagen vorgestellt, mit dem die zur Datenanalyse notwendigen Prozesswerte über einen zweiten Datenkanal verfügbar werden. Dieses wurde im Rahmen der VDI AUTOMATION 2018 vorgestellt [TV+18].

3.2 Klassifikation von Ventilfehlern und Einflussfaktoren

Im Folgenden wird die innerhalb von SIDAP erfolgte Schadensfallklassifikation von Ventilfehlern dargestellt. Zunächst wird der Prozess der Strukturierung und Formalisierung des Expertenwissens beschrieben, anschließend wird ein beispielhafter Auszug der Ergebnisse gezeigt und diskutiert.

3.2.1 Konzept und Vorgehen der Klassifikation

Nachfolgend wird das Konzept einer Datenanalyse in Kombination mit Expertenwissen abgeleitet. Die Klassifikation der Fehler verlangt nach einer Identifizierung der verschiedenen Fehlermodi und der zugrundeliegenden

Mechanismen durch Experten analog zur gängigen FMEA [EN15]. Aus diesem Grund muss das Wissen über den Prozess und mögliche Fehler formalisiert werden, dies geschieht im Beispiel in Form einer Schadensfallklassifizierungstabelle. Darüber hinaus wird die Klassifikation durch eine Liste der für eine Analyse der Fehler relevanten Parameter und möglicher Annahmen zur Vereinfachung des Problems ergänzt. Die Erstellung der Fehlerklassifikationstabelle wird in Form von gemeinsamen Sitzungen mit Experten durchgeführt. Mehrere Iterationen sind erforderlich, um alle relevanten Aspekte zu erfassen. Mit Hilfe eines interdisziplinären Teams aus Datenanalysten, Ventil- und Prozessexperten werden die genannten Merkmale erarbeitet. Während die Ventil- und Prozessexperten die Schädigung und den Mechanismus der Schädigung beschreiben, fokussieren sich die Datenanalysten auf mögliche Erkennungsmerkmale. Ein Fehler kann sich hierbei durch mehrere Erkennungsmerkmale äußern. Durch die Erarbeitung der Klassifikationstabelle wird somit eine Schnittstelle zwischen Prozesswissen und Datenanalyse geschaffen, um die vorhandenen Informationen möglichst effizient zu nutzen und gegenseitiges Verständnis für die Probleme der anderen Disziplinen zu schaffen. Basierend auf der Klassifikation können dann durch die Datenanalysten Analysen ausgeführt werden, die anschließend von den Experten mit bewertet werden. Die Korrektheit der erfolgten Klassifikation kann somit geprüft und notwendige Anpassungen vorgenommen werden.

3.2.2 Schadensfallklassifikation für Regelventile

In Tabelle 3.1 ist ein beispielhafter und vereinfachter Auszug der vollständigen Schadensfallklassifikation aus SIDAP gezeigt. Die Klassifikation fasst die verschiedenen Fehlerbilder zusammen und ordnet diesen den Mechanismen, welche die Schädigung hervorrufen, zu. Beispielsweise kann Verschleiß am Ventilkegel oder -sitz durch Kavitation (Implosion von Gasblasen aufgrund des Druckanstiegs nach der Vena Contracta), Erosion (z. B. hervorgerufen durch Feststoffpartikelabrieb) oder Korrosion hervorgerufen werden. Als Erkennungsmerkmal im Datenanalyseprozess kann eine Abweichung zwischen gemessenem und berechnetem Durchfluss dienen. Denn diese Mechanismen induzieren eine Veränderung im Durchflussquerschnitt und damit eine Veränderung im gemessenen Durchfluss. Zur Abbildung des Idealverhaltens des Ventils werden daher Modelle im Gutzustand (nach Einbau) trainiert. Degradiert das Ventil im Laufe der Zeit, unterscheidet sich das Ist- vom Idealverhalten zunehmend. Für den Fall von Verschleiß am Kegel kann ein im Vergleich zur Ventilauslegung zu großer Istdurchfluss bestimmt werden. Ein anderes Beispiel von Schädigungen sind Anhaftungen am Kegel aufgrund

von Fouling. Hier ist der Istdurchfluss kleiner als das berechnete Idealverhalten. In beiden Fällen können die gleichen Prozessgrößen zur Berechnung verwendet werden, jedoch werden diese oftmals nicht erhoben (Spalte praktische Umsetzung).

Tabelle 3.1: Auszug der Schadensfallklassifikation für Regelventile [TW+17, M18].

FEHLERBILD	URSÄCHLICHER MECHANISMUS	ERKENNUNGSMERKMAL	PRAKTISCHE UMSETZUNG
Verschleiß am Ventilkegel oder -sitz	Kavitation Erosion Korrosion	Gemessener Durchfluss des Ventils ist größer als der zu erwartende Durchfluss (modell- oder signalbasiert ermittelt)	Benötigte Messgrößen (Soll- oder Ist-Hub, Vordruck und Nachdruck sowie Durchfluss und Temperatur) nicht standardmäßig vorhanden
Anhaftungen am Ventilkegel oder -sitz		Gemessener Durchfluss des Ventils ist kleiner als der zu erwartende Durchfluss (modell- oder signalbasiert ermittelt)	
Festsitzen des Ventilkegels im Sitz	Fouling	Durchfluss annähernd 0 bei Sollwert des Ventilhubes größer 0	Benötigte Messgrößen (Soll-Hub sowie Ist-Hub oder Durchfluss) meist vorhanden. Erste Beobachtungen/Modelle erstellt
Erhöhte Haftreibung im Ventil		Phasenversatz zwischen Durchfluss und Ventilhub und sprunghafte Änderungen	
Erhöhte Haftreibung in der Dichtung	Verschleiß Fouling	Phasenversatz zwischen Durchfluss und Ventilhub und sprunghafte Änderungen	

3.3 Retrofitting von bestehenden Anlagen

Fehlende Prozesswerte erschweren eine Datenanalyse oder machen diese gänzlich unmöglich. Ein typisches Beispiel für Regelventile ist das Fehlen einer Übertragung des Ist-Ventilhubes. Aufgrund von geschlossenen Systemen und Limitation bei den Kommunikationsmitteln werden Konzepte zur zielgerichteten Nachrüstung prozesstechnischer Anlagen benötigt. Nachfolgend wird das innerhalb von SIDAP entwickelte Vorgehen beispielhaft gezeigt.

3.3.1 Konzept des Retrofittings

Die Struktur der Steuerungstechnik und übergeordneter Systeme ist in der industriellen Praxis sehr stark durch die klassische Automatisierungspyramide (ISA-95 [ISA00]) geprägt. Diese Systemstruktur garantiert eine klare Trennung zwischen Prozesssteuerung und Organisation des Betriebs. Während dies für klassische Systeme, bei denen der reibungslose Betrieb der Anlage

allein im Vordergrund steht, ein akzeptiertes Vorgehen ist, verlangen neuartige Anwendungen nach Veränderungen in dieser Struktur. Für den konkreten Fall der Ventildiagnose beschränkt beispielsweise die Übertragung von Messwerten über HART [Sa00] durch die geringe Anzahl an auslesbaren Variablen die Analyse. Während moderne Stellungsregler umfassende, integrierte Diagnosefunktionalitäten und eine Vielzahl auslesbarer Variablenwerte zur Verfügung stellen [KE+11], sind per HART nur vier vorkonfigurierte Werte abrufbar. Weiterhin ist auch die Nachrüstbarkeit der Anlage mit zusätzlicher Sensorik durch die bestehende Hierarchie eingeschränkt. Da derzeit alle Signale direkt an das Prozessleitsystem übermittelt werden und diese Systeme in sich stark geschlossen sind, ist eine Erhebung zusätzlicher Signale derzeit mit enormem Aufwand verbunden.

Moderne Anwendungen wie die Ventildiagnose verlangen deshalb nach erweiterten, schichtenübergreifenden Wegen der Kommunikation. Hierzu muss jedoch nicht das bestehende System in seiner Gänze aufgebrochen werden. Es reicht vielmehr, einen zweiten Kommunikationskanal für nicht steuerungsrelevante Signale zu öffnen. SIDAP verfolgt hier einen ähnlichen Ansatz wie er von der NAMUR in Form der NAMUR Open Architecture (NOA) [KT+17] vorangetrieben wird (vergleiche Abbildung 3.1). Über den zweiten Kanal werden weitere Daten übertragen, ohne die bestehende Prozesssteuerung zu beeinflussen. Hierdurch können prozesstechnische Anlagen zielgerichtet nachgerüstet werden, ohne den laufenden Betrieb zu beeinflussen (Rückwirkungsfreiheit). Nachfolgend wird eine praktische Umsetzung innerhalb von SIDAP gezeigt.

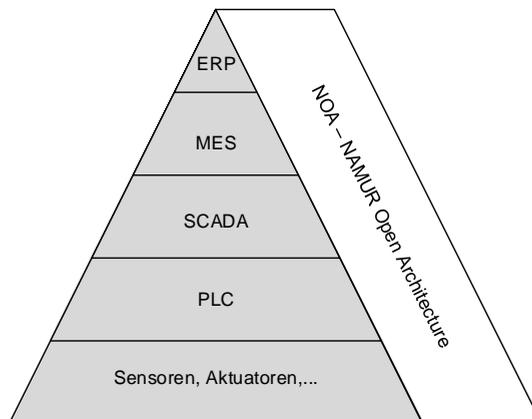


Abbildung 3.1: NAMUR Open Architecture als Ergänzung zur bestehenden Automatisierungspyramide nach ISA-95 [ISA00] (Abbildung nach Klettner et al. [KT+17]).

3.3.2 Beispielhafte Umsetzung für Regelventile

Durch die Nachrüstung eines zweiten Kommunikationskanals kann die Messung der Prozessgrößen von der weiteren Datennutzung (z. B. Datenanalyse) entkoppelt werden. Weiterhin kann die notwendige Sensorik direkt im Ventil integriert werden, um bisher nicht erfasste Messsignale aufzuzeichnen. Abbildung 3.2 gibt eine innerhalb von SIDAP erfolgte Nachrüstung einer prozesstechnischen Anlage mit zusätzlicher Sensorik wieder. Prototypisch angepasste Ventile mit erweiterter Sensorik wurden neben der für die Steuerung relevanten Kommunikation über HART auch über einen zweiten Kanal in Form von WirelessHART [Gr+13] angeschlossen. Die beiden Datenkanäle werden auf dem Analysesystem wieder zusammengeführt, ohne die Steuerung und das Prozessleitsystem zu beeinflussen.

Von Interesse war für die nachgerüsteten Ventile neben Vor- und Nachdruck auch die Temperatur des Mediums. Die drei Messgrößen dienen zur Verbesserung der Analysemodelle und versetzen diese in die Lage, den Solldurchfluss noch besser in Abhängigkeit der relevanten Einflussfaktoren zu beschreiben. Weiterhin werden auch die internen Diagnosedaten der Stellungsregler übertragen und erlauben somit eine noch detailliertere Analyse der Vorgänge im Ventil. Im Analyseschritt werden diese Daten sowie die Daten aus dem Prozessleitsystem selbst (bspw. Durchflussmessungen) kombiniert, um einen vollständigen Datensatz zu erhalten. Des Weiteren kann über eine definierte Schnittstelle ein Datenzugriff nahezu in Echtzeit erfolgen, was für ein zukünftiges Überwachen der Ventile im echten Betrieb notwendig ist. Die gesamte Nachrüstung erfolgte im genannten Beispiel unter Berücksichtigung der spezifischen Anforderungen durch Installation im explosionsgeschützten Bereich und den Sicherheitsanforderungen seitens der informationstechnischen Umsetzung.

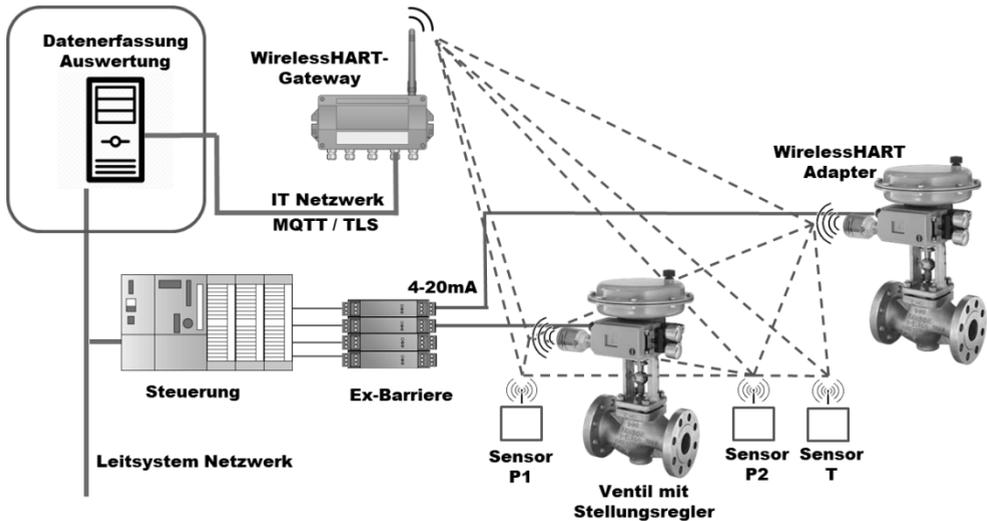


Abbildung 3.2: Nachrüstung von prozessrelevanten Regelarmaturen und Anbindung an Datenanalyse über einen zweiten Kommunikationskanal (z. B. WirelessHART [Gr+13]) aus [TV+18].

3.4 Zusammenfassung

Das Fehlen relevanter Fehlerfälle und Datensätze macht eine rein datengetriebene Analyse zur Erkennung und Vorhersage von Fehlern oftmals zu ungenau für eine praktische Anwendung. Das Anreichern der Analyse mit vorhandenem Expertenwissen hat das Potenzial, diese Lücke teilweise zu schließen. Hierfür ist es jedoch erforderlich, das interdisziplinäre Expertenwissen zu systematisieren und so nutzbar zu machen. Dieser Beitrag stellt anhand der Schadensfallklassifikation von Regelarmaturen ein Beispiel aus dem Projekt SIDAP und das Vorgehen zur Erstellung der Schadensfallklassifikation vor. Weiterhin fehlen für Datenanalysen oft relevante Prozessgrößen, die in Anlagen nicht erhoben oder übertragen werden. Hier werden Retrofitting-Konzepte zur Einbindung von bestehenden Anlagen in das moderne Industrie-4.0-Umfeld benötigt. Diese Konzepte müssen die spezifischen Randbedingungen der Branche und Anwendungsfälle berücksichtigen. Mit der NOA wird ein solches Konzept in Form eines zweiten, rückkopplungsfreien Datenkanals vorgestellt. Innerhalb von SIDAP wurden auf Basis der NOA-Idee Ventile für Analysezwecke nachgerüstet, um die bestehenden Modelle durch die Ergänzung bisher nicht erhobener Daten zu verbessern.

3.5 Danksagung

Die Autoren bedanken sich beim BMWi für die Förderung des Projekts SIDAP (Förderkennzeichen 01MD15009F) und bei den Kooperationspartnern des SIDAP-Konsortiums für die Unterstützung.

Literatur

- [AB+08] M. Aoudia, O. Belmokhtar, G. Zwingelstein, „Economic impact of maintenance management ineffectiveness of an oil and gas company”, *JQME*, Vol. 14, Nr. 3, S. 237–261, 2008.
- [VH16] B. Vogel-Heuser, D. Hess, „Guest editorial industry 4.0–prerequisites and visions”, *IEEE T-ASE*, Vol. 13, Nr. 2, S. 411–413, 2016.
- [TW+17] E. Trunzer, I. Weiß, C. Schrüfer, B. Vogel-Heuser, S. Erben, S. Unland, C. Vermum, „Failure Mode Classification for Control Valves for Supporting Data-Driven Fault Detection”, 2017 IEEE International Conference on Industrial Engineering and Engineering Management (IEEM), S. 2346-2350, 2017.
- [TV+18] E. Trunzer, B. Vogel-Heuser, C. Vermum, „Datengetriebene Diagnose von Regelarmaturen zur Steigerung der Anlagenverfügbarkeit“, 19. VDI-Leitkongress AUTOMATION 2018, VDI-Berichte Nr. 2330, S. 319-328, 2018.
- [EN15] Europäisches Komitee für Normung, „Fehlzustandsart- und -auswirkungsanalyse (FMEA) (IEC 56/1579/CD:2014)“, DIN EN 60812, 2015.
- [M18] S. Mühlenkamp, „Dieser Weg wird kein leichter sein“, *PROCESS*, Nr. 3, S. 60-62, 2018.
- [ISA00] The Instrumentation, Systems, and Automation Society (ISA), „Enterprise-Control System Integration – Part I: Models and Terminology”, ANSI/ISA 95.00.01, 2000.
- [Sa00] SAMSON AG, „Technische Information: HART-Kommunikation”, Frankfurt a. M., 2000.
- [KE+11] J. Kiesbauer, S. Erben, und D. Hoffmann, „Neue Asset-Management-Konzepte bei Stellventilen Diagnose von intelligenten Stellgeräten: Diagnose von intelligenten Stellgeräten”, *atp edition*, Vol. 52, Nr. 03, S. 40–43, 2011.
- [KT+17] C. Klettner, T. Tauchnitz, U. Epple, L. Nothdurft, C. Diedrich, T. Schröder, D. Großmann, S. Banerjee, M. Krauß, C. Latrou, L. Urbas. „Namur Open

Architecture – Die Namur-Pyramide wird geöffnet für Industrie 4.0“, Automatisierungstechnische Praxis (atp), Vol. 59, Nr. 1-2, S. 20-37, 2017.

[GR+13] J. Grebner, S. Rotmensen, und R. Skowronek, „Wireless vom Feld in die Welt: Sicher drahtlos kommunizieren im Automatisierungsumfeld: WirelessHart, WLAN und Mobilfunk bieten zuverlässige Lösungen für nahezu alle Szenarien, Teil 1“, atp edition, Vol. 55, Nr. 09, S. 22–25, 2013.

4 Fehlerdiagnose an Ventilen

Herausforderungen, Ergebnisse und zukünftige Möglichkeiten

Dr. N. Fabritz
Evonik Industries AG, Marl
norbert.fabritz@evonik.com

I. Weiß
Lehrstuhl für Automatisierung und Informationssysteme,
Technische Universität München, Garching bei München
iris.weiss@tum.de

4.1 Einleitung

Im Zuge der Digitalisierung von Produktionsanlagen im Umfeld von Industrie 4.0 stehen eine Vielzahl von Daten, wie z.B. Prozess-, Anlagen- oder Wartungsdaten für Analysen zur Verfügung. Diese können unter anderem genutzt werden, um durch eine datengetriebene Zustandsüberwachung bedarfsgerechte Instandhaltung zu betreiben und somit sowohl die Verfügbarkeit als auch die Nutzung der verfügbaren Lebensdauer von Equipments zu erhöhen. Denn im Gegensatz zur ausfallbedingten Instandhaltung, welche nach einem Ausfall des Equipments und damit nach dem Stoppen des Prozesses korrektiv ansetzt, erlaubt die Zustandsüberwachung eine gezielte Planung von Wartungsaktivitäten bevor eine Anlage ausfällt. Darüber hinaus bietet dies zudem die Möglichkeit, die verfügbare Restlebensdauer eines Equipments (Remaining Useful Life) maximal auszunutzen und nicht durch vorbeugende Instandhaltungsmaßnahmen noch intakte Geräte auszutauschen. Im Projekt SIDAP¹² ist die Zustandsüberwachung besonders von Ventilen in prozesstechnischen Anlagen von Interesse. Die äußere Beobachtbarkeit der inneren Abläufe eines Ventils ist im Prozess stark eingeschränkt bzw. nicht möglich und eine optische Sichtprüfung erfordert das Stoppen des Prozesses und den Ausbau des Ventils. Um dennoch eine Überwachung des Zustandes des Ventils während des Prozesses zu ermöglichen, müssen deshalb die zur Verfügung stehenden Daten analysiert, ein Modell des Normalverhaltens ermittelt und somit ein stetiger Abgleich des Ist-Verhaltens mit dem Normalverhalten

¹² Skalierbares Integrationskonzept zur Datenaggregation, -analyse, -aufbereitung von großen Datenmengen in der Prozessindustrie; <http://www.sidap.de>, aufgerufen am 18.07.2018.

erstellt werden, um eine Einschätzung des Zustandes von Ventilen im laufenden Betrieb zu ermöglichen. Die Herausforderungen bei der Ventildiagnose, die Ergebnisse des Projektes SIDAP und mögliche zukünftige Potentiale werden in diesem Beitrag erläutert.

Im Abschnitt 4.2 wird zunächst die Problemstellung detailliert erläutert und die Anforderungen an eine Lösung definiert. Zudem werden die Herausforderungen, die sich im Projekt SIDAP hinsichtlich der Datenanalyse und Fehlerdetektion ergeben haben, diskutiert und mögliche Lösungen aufgezeigt. Im Abschnitt 4.3 werden die Ergebnisse von Versuchen an einem Messstand vorgestellt. Diese ermöglichen, gezielt Fehler zu simulieren und deren Auswirkungen auf das Analysemodell zu untersuchen. Darauf folgend werden die Erkenntnisse aus den Versuchen auf industrielle Daten aus echten Produktionsanlagen übertragen (Abschnitt 4.4). Abschließend wird ein Ausblick auf die Prognose von Ventilfehlern gegeben (Abschnitt 4.5), bevor eine Zusammenfassung im Abschnitt 4.2 den Beitrag schließt.

4.2 Problemstellung

Die datengetriebene Ventildiagnose ermöglicht eine Erhöhung der Anlagenverfügbarkeit durch frühzeitiges Erkennen von Ventilbeschädigungen und dem entsprechenden Eingreifen durch Wartungs- und Instandhaltungsmaßnahmen. In der Diagnose werden dahingehend drei Schritte unterschieden: Fehlerdetektion, Fehlerisolation und Fehleridentifikation [JLB06]. Bei der Detektion muss festgestellt werden, dass ein Fehler vorliegt, d.h. das Ist-Verhalten vom Normalverhalten abweicht. Bei der Isolation stehen die Lokalisierung des Fehlers und bei der Identifikation die Beschreibung des Fehlertyps im Vordergrund. Da in diesem Anwendungsfall ein einzelnes Bauteil und keine gesamte Anlage überwacht wird, ist der Fokus der folgenden Arbeit auf die Detektion und Identifikation gerichtet. Hierbei werden zwei spezifische Fehlerfälle, die besonders häufig in Ventilen beobachtet werden, betrachtet. Es handelt sich dabei zum einen um Anhaftungen am Ventilkegel (vgl. Abbildung 4.1 (2)), welche den Durchflussquerschnitt des Ventils und somit das Ventilverhalten (Ventilkennlinie) verändern, und zum anderen um Absplitterungen des Kegels (vgl. Abbildung 4.1 (1)), was ebenfalls eine Änderung des Durchflussquerschnitts und somit der Ventilkennlinie verursacht. Im Projekt SIDAP werden die folgenden Anforderungen gestellt:

- A1. Erkennung von Abweichungen des Ist-Verhaltens zum Normalverhalten bezüglich der Ventilkennlinie,
- A2. *Datenbasierte* Identifizierung der Fehler Anhaftung und Absplittung und
- A3. Bestimmung der Schwere des Fehlers.

In der Umsetzung dieser Anforderungen wurden bei den Industriepartnern des Projektes Daten für eine datengetriebene Analyse extrahiert. Zwei Datensätze mit circa 320.000.000 bzw. 175.000.000 Messpunkten für 4 bzw. 38 Ventile wurden bereitgestellt. Die ersten Analysen haben Modelle mit hoher Falsch-Positiv-Rate ergeben [FS+16]. Weitere Untersuchungen der Zusammenhänge im Ventil sind deshalb zwingend erforderlich. Folgende Herausforderungen wurden dabei identifiziert:

1) Verfügbarkeit von relevanten Prozessgrößen

Die Instrumentierung von prozesstechnischen Anlagen ist auf die Regelung des Prozesses optimiert. Die verbaute Sensorik stellt die für den Prozess relevanten Regelgrößen zur Verfügung. Eine vollständige datenbasierte Beschreibung von Prozessen und Ventilverhalten ist damit nicht zwingend Rechnung getragen. Die in den extrahierten Daten übermittelten Messstellen sind je Ventil unterschiedlich. Unter anderem sind Messgrößen wie Durchfluss, Ist-Hub oder Soll-Hub des Ventils, Nachdruck oder auch Vordruck und Temperatur gegeben. Die geringe Anzahl und Verschiedenheit der Messstellen pro Ventil haben Anlass gegeben, eine Experten-getriebene Evaluation von relevanten Messgrößen durchzuführen. In einer Schadensklassifizierung wurden die Fehlerfälle an Ventilen zusammengetragen, deren Ursach

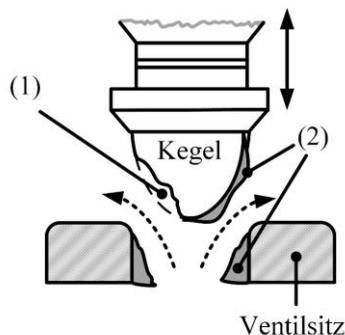


Abbildung 4.1: Schematische Darstellung der betrachteten Fehlerbilder

chenmechanismen identifiziert und die benötigten Größen für eine datengetriebene Analyse des Ventilzustandes definiert [TW+17]. Für die Fehlerfälle Anhaftung und Absplitterung wurden das sogenannte Fouling bzw. Korrosion, Kavitation und Erosion als Mechanismen identifiziert. Zur datengetriebenen Erkennung dieser Fehlerfälle müssen folgende Größen verfügbar sein: Soll- oder Ist-Hub des Ventils (vorausgesetzt der Annahme, dass die beiden nicht gleich sind), der Vor- sowie der Nachdruck und der Durchfluss. Ist der Einfluss der Temperatur des Mediums, der thermodynamischen Eigenschaften oder des Phasenzustands nicht vernachlässigbar klein (Experteneinschätzung), müssen diese ebenfalls mit geeigneten Größen berücksichtigt werden.

2) Verfügbarkeit von Fehlerfällen in historischen Daten

Aufgrund der Kritikalität von Ausfällen und abrupten Stopps von Prozessen in prozesstechnischen Anlagen, verfolgen die Betreiber derzeit eine vorbeugende Instandhaltungsstrategie. Durch regelmäßige Wartung bzw. Wechsel der Ventile wird stets eine einwandfreie Funktionsfähigkeit sichergestellt. Aus diesem Grund sind in den historischen Daten lediglich 17 bzw. 2 Fehler abgebildet. Ausgenommen einer generellen Anomaliedetektion im Prozess können auf Basis dieser wenigen Fehlerfälle keine Fehlerdetektions- bzw. Fehleridentifikationsmodelle trainiert werden. Aus diesem Grund wurden Tests auf einem Versuchsstand gefahren, um mögliche Fehlerbilder in den Daten abbilden zu können. Das Vorgehen und die Ergebnisse werden in Abschnitt 4.3 erläutert.

3) Verfügbarkeit von Metadaten

Eine weitere Herausforderung in der datengetriebenen Zustandsüberwachung von Ventilen in prozesstechnischen Anlagen stellt die Verfügbarkeit von Metadaten dar. Im speziellen werden Angaben zu den Betriebsphasen benötigt, um eine zielgerichtete Analyse zu ermöglichen. In der Entwicklung erster Fehlerdetektionsmodelle auf Basis der Ventilkennlinie sind eine Vielzahl an Fehlalarmen aufgetreten, die auf das abweichende Ventilverhalten in Anfahr-, Abfahr- oder z.B. Spülprozessen zurückzuführen sind. Aus diesem Grund müssen die historischen Daten in Abschnitte der verschiedenen Phasen untergliedert werden, um eine Analyse der tatsächlichen Zeiträume in stabilen Betriebsphase zu ermöglichen. Verschiedene Clustering Modelle wurde

als datengetriebene Methoden zur Unterscheidung der Betriebsphasen entwickelt und mit Hilfe von Prozessexperten evaluiert [TW+18].

4.3 Tests am Versuchsstand

Das Generieren von Daten an einem Versuchsstand eröffnet die Möglichkeit, alle zuvor als relevant identifizierten Messgrößen zu erheben, gezielt Fehlerbilder in die verwendeten Ventile einzubringen und somit sowohl Fehlerdetektions- als auch Fehleridentifikationsmodelle zu entwickeln. Aus diesem Grund wurden 30 kontrollierte Messreihen an einem Versuchsstand gefahren und Daten mit einer Abtastrate von 50ms erhoben. Dabei wurden Sensoren für den Vor- sowie Nachdruck, Temperatur, Durchfluss, Schallintensität und Hub eingesetzt (vgl. Tabelle 4.1). Jeweils 10 Messreihen wurden mit demselben Ventilkegel erhoben, um zufällige Schwankungen und Abweichungen ausgleichen zu können. Im Versuchsstand wurde Ventil mit einem V-Kegel verwendet. Der Ventilkegel 0 ist ein Original-Kegel ohne Beschädigungen. Ventilkegel 1 weist eine Beschädigung im oberen Hubbereich in Form einer Materialabtragung auf (vgl. Abbildung 4.2 (1)). Ventilkegel 2 weist ebenfalls eine Materialabtragung, allerdings im mittleren Hubbereich, auf (vgl. Abbildung 4.2 (2)). Als Medium wurde Wasser eingesetzt.

Tabelle 4.1 Messstellen am Versuchsstand.

Messstelle	Einheit
Zeit	s
Vordruck	bar
Nachdruck	bar
Temperatur	°C
Durchfluss	m ³ /h
Schallintensität	dB
Hub	mm

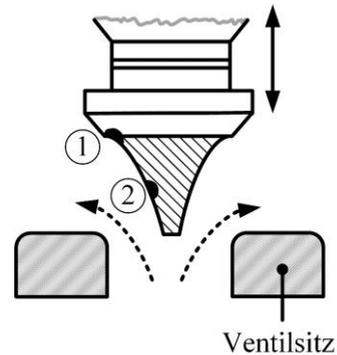


Abbildung 4.2: Indizierte Ventilfehler.

Zur Analyse der Daten wurde die Random Forest Regression herangezogen. Diese generiert auf Basis der Trainingsdaten eine Vielzahl an Entscheidungsbäumen, welche mittels Stimmenmehrheit oder Mittelwertberechnung die abhängige Variable berechnet. Gegenüber anderen nicht-linearen Regressionsmethoden wie der Support Vektor Regression bietet die Random Forest Regression den Vorteil, dass keine Annahmen über die Art des Zusammenhangs (gleichprozentige oder lineare Ventilkennlinie) getroffen werden muss, diese

schnell berechnet werden kann (dadurch auch für sehr große Datensätze geeignet ist) und eine Interpretation der Einflussstärke der Variablen durch Experten zulässt.

In der Datenvorbereitung wurden die Datenreihen um die ersten 20 Sekunden bereinigt, um das Anfahren des Prozesses aus der Modellbildung auszuschließen. Zudem wurde der Differenzdruck aus dem Vor- und Nachdruck berechnet und der Ventilhub in einen relativen Hub überführt.

Um ein Modell des Normalverhaltens zu entwickeln, wurden die 10 Datenreihen des Ventilkegels 0 herangezogen. Dieser Datensatz wurde in 80% Trainings- und 20% Testdatensatz untergliedert, um die Validität des Modells zu prüfen. Drei unterschiedliche Modelle basierend auf einer unterschiedlichen Zusammensetzung der Variablen wurden trainiert:

Modell 1: Durchfluss, Ventilhub, Differenzdruck und Druckniveau:
Abbildung der Ventilkennlinie

Modell 2: Durchfluss, Ventilhub, Differenzdruck, Druckniveau und Schallintensität:
Abbildung der Ventilkennlinie + Einbezug widriger Effekte wie Kavitation durch die Schallintensität

Modell 3: Durchfluss, Ventilhub, Differenzdruck, Druckniveau und Temperatur:
Abbildung der Ventilkennlinie + Einbezug des Einflusses von Temperatur auf die Eigenschaften des Mediums und damit auf die Ventilkennlinie

Der Durchfluss ist für alle Modelle als abhängige Variable definiert, d.h. der Durchfluss wird über die Veränderung der unabhängigen Variablen Ventilhub und Druck erklärt. Zum Vergleich der Ergebnisse wurden die Residuen (tatsächlicher Wert – berechneter Wert) im Testdatensatz ermittelt und auf den relativen Ventilhub aufgetragen (vgl. Abbildung 4.3 (A)). Zudem wurde ein relatives Residuum berechnet (vgl. Abbildung 4.3 (B)). Das relative Residuum ist vor allem zur Bestimmung der Schwere eines vorliegenden Fehlers von Bedeutung. Eine Abweichung von z.B. $0.5 \text{ m}^3/\text{h}$ lässt bei einem fast vollständig geschlossenen Ventil mit einem Normaldurchfluss von $1 \text{ m}^3/\text{h}$ auf eine größere Beschädigung schließen als bei einem weit geöffneten Ventil mit einem Normaldurchfluss von $30 \text{ m}^3/\text{h}$.

Da das Residuum zufällig um den Wert 0 (Abweichung zwischen tatsächlichem und berechneten Wert gleich 0) schwankt, kann ein guter Modellfit im

Testdatensatz für alle Modelle 1-3 festgestellt werden. Jedoch ist ein leichter Anstieg der Standardabweichung des Residuums ab einem relativen Ventilhub von circa 70% zu erkennen (vgl. Abbildung 4.3 (C+D)). Es ist zu vermuten, dass bei größer werdendem Hub Phänomene wie sich verändernde Vorwiderstände höhere Unsicherheit ins Modell eintragen. Die Standardabweichung der relativen Residuen zeigen, dass bei minimalem Ventilhub Abweichungen um $\pm 10\%$ als Normalverhalten eingeschätzt werden müssen, da das Modell keine genaueren Werte liefern kann.

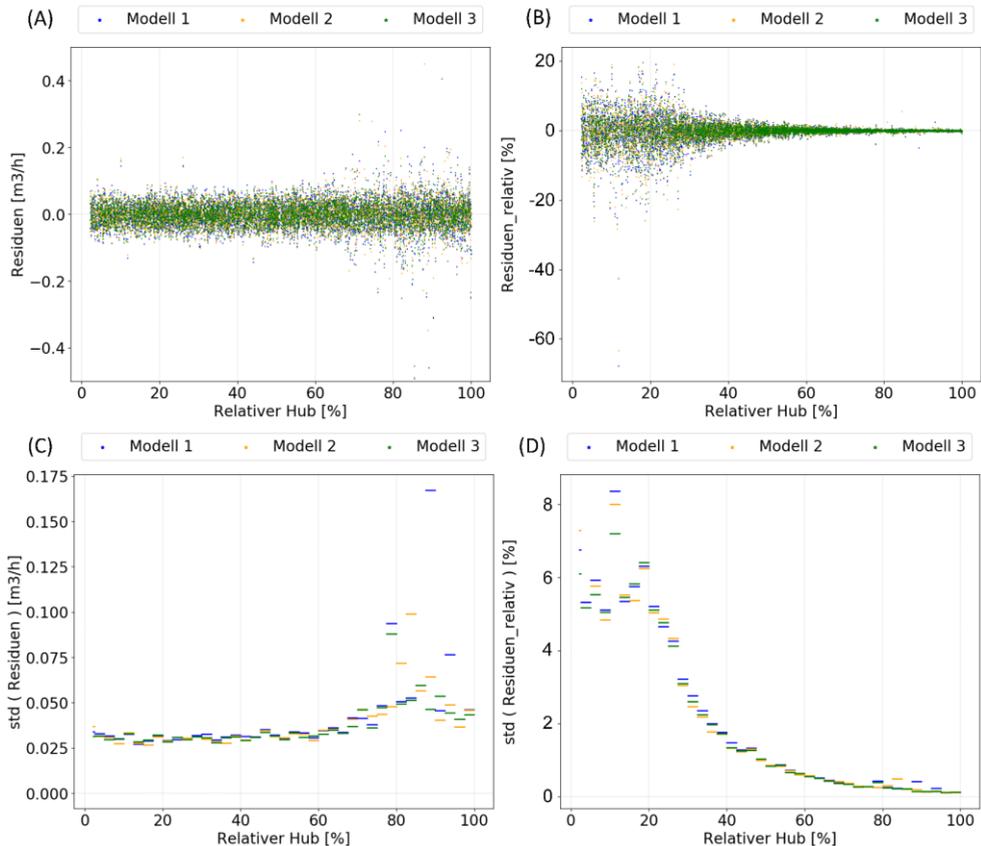


Abbildung 4.3: Mittelwert und Standardabweichung der Residuen des Modells 1-3 im Testdatensatz.

Im Folgenden werden die trainierten Modelle auf die vorgeschädigten Kegel 1 und Kegel 2 angewandt. Die Standardabweichungen der Residuen zeigen, dass Modell 1 eine geringere Streuung aufweist und damit auf eine höhere Modellgüte hinweist (vgl. Abbildung 4.4). D.h. die Schallintensität und die Temperatur des Mediums bringen innerhalb dieser Versuchsreihen mehr Unsicherheit in das Modell ein und sollten deshalb aus der Analyse ausgeschlossen werden. Bei der Schallintensität ist zu erwarten, dass die zur Entstehung lauter Geräusche ursächlichen Mechanismen bisher nicht ausreichend berücksichtigt sind. Der Einbezug der Schallintensität verschlechtert daher das Modell. Bei genauerer Betrachtung der Temperatur des Mediums ist festzustellen, dass diese in den Versuchen bei circa 42 °C liegt und lediglich um wenige Grad Celsius schwankt. Einen Einfluss dieser Schwankung auf das Ventilverhalten ist nicht zu erwarten und verursacht aus diesem Grund im Modell mehr Unsicherheiten anstatt eine höhere Modellgüte zu bewirken. Die weitere Analyse bezieht sich deshalb lediglich auf Modell 1.

Die Analyse der relativen Residuen für Modell 1 zeigen (Abbildung 4.5), dass die beiden Fehlerfälle Kegel 1 und Kegel 2 in unterschiedlichen Effekten zum Vorschein treten. Während bei Kegel 1 die Residuen bei 20% Ventilöffnung ein Maximum erreichen, zeigt Kegel 2 größere Abweichungen im niedrigen Hubbereich, welche sich mit größer werdendem Hub abschwächen. Da die Abweichungen in beiden Fällen im unteren bis mittleren Hubbereich die beobachteten Schwankungen von $\pm 10\%$ im Normalverhalten übersteigen, kann hier von einem Fehler ausgegangen werden. Das Modell erkennt das Fehlverhalten, weshalb Anforderung 1 erfüllt ist. Da die Fehler im Kegel 1 und 2 unterschiedliche Muster in den Residuen zeigen ist auch eine Identifikation möglich. Somit ist auch Anforderung 2 erfüllt. Die Schwere des Fehlers kann hier nur durch Experten evaluiert werden. Die Manipulation der Kegel 1 und 2 werden als geringfügige Beschädigung eingeschätzt. D.h. auch geringe Schäden können im unteren Hubbereich bereits durch große Abweichungen zwischen Normal- und Ist-Verhalten detektiert werden.

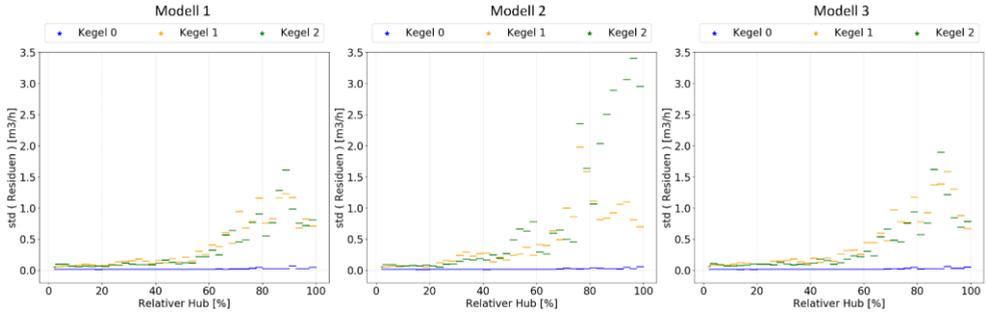


Abbildung 4.4: Standardabweichung der Residuen im Kegel 0-2 für alle Modelle.

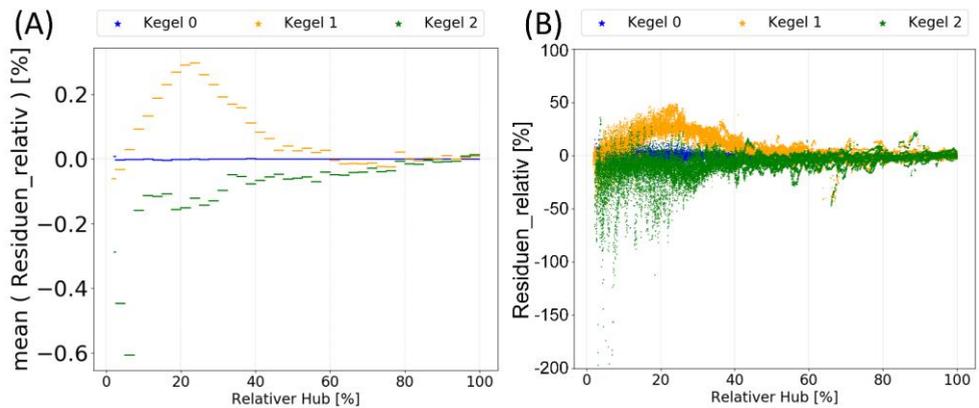


Abbildung 4.5: Gemittelte relative Residuen des Modells 1 für alle Kegel (A) und relative Residuen des Modells 1 für alle Kegel (B).

4.4 Übertragung auf Industriedaten

Die in den Messversuchen gewonnenen Erkenntnisse müssen nun auf reale industrielle Daten übertragen werden. Hierzu wird vorerst ein Ventil mit einem Zeitraum identifiziert, in dem kein Fehler vorgelegen hat (Zeitdiagramme sind in Abbildung 4.6 abgebildet). Dadurch kann überprüft werden, ob externe Einflüsse und Rauschen bereits Abweichungen von über $\pm 10\%$ in fehlerfreien Ventilen verursachen. Trotz einer erhöhten Standardabweichung der Residuen in den industriellen Daten ist bei den zur Verfügung stehenden Daten im Mittel eine Abweichung von unter $\pm 10\%$ zu beobachten. Über die Zeit betrachtet ermittelt das Modell nach dem Training Residuen um die 5%. Einzelne Ausreißer nach oben sind zu beobachten (vgl. Abbildung 4.6). Diese Ausreißer können vor allem durch unterschiedliche Betriebsphasen, die hier keine Berücksichtigung gefunden haben, verursacht werden. Eine vorherige Unterteilung der Daten in stabile Betriebspunkte und Übergangsphasen kann das Modell daher weiter verbessern. Die Anwendung des trainierten Modells nach einer größeren Datenlücke verursacht jedoch Residuen größer $\pm 10\%$ (vgl. Abbildung 4.6). Es ist zu vermuten, dass durch Wartung des Ventils oder der erneuten Initialisierung Verschiebungen z.B. im Nullpunkt und damit im Ventilverhalten verursacht werden. Ein erneutes Training des Modells passt das Modell an die veränderten Randbedingungen an, sodass im Folgenden wieder eine Überwachung durchgeführt werden kann.

Ein weiteres Beispiel aus industriellen Daten zeigt die Anwendbarkeit bei Ventilschäden. Das betrachtete Ventil wurde im November 2015 eingebaut und im Oktober 2016 bereits wieder ausgebaut. Ein Problem mit dem Ventil ist den Bedienern Ende April 2016 aufgefallen. Dies ist in den Stör- und Warnungsmeldungen dokumentiert. Ein Modell zur Überprüfung des Ventilhaltens kann bereits im Februar eine leichte Beschädigung des Ventils anzeigen (vgl. Abbildung 4.7). Die Residuen zeigen bereits unmittelbar nach dem Modelltraining eine ansteigende Tendenz. Es ist daher zu vermuten, dass bereits unmittelbar nach dem Einbau eine kontinuierliche Degradierung des Ventils eingesetzt hat. Eine dauerhafte Überschreitung des 10%-Grenzwertes wird ab Februar erreicht. Im weiteren Verlauf nimmt der Grad der Beschädigung kontinuierlich zu. Sprunghafte Anstiege sind vor allem im April erkennbar. Diese sind auch von den Bedienern der Anlage wahrgenommen worden.

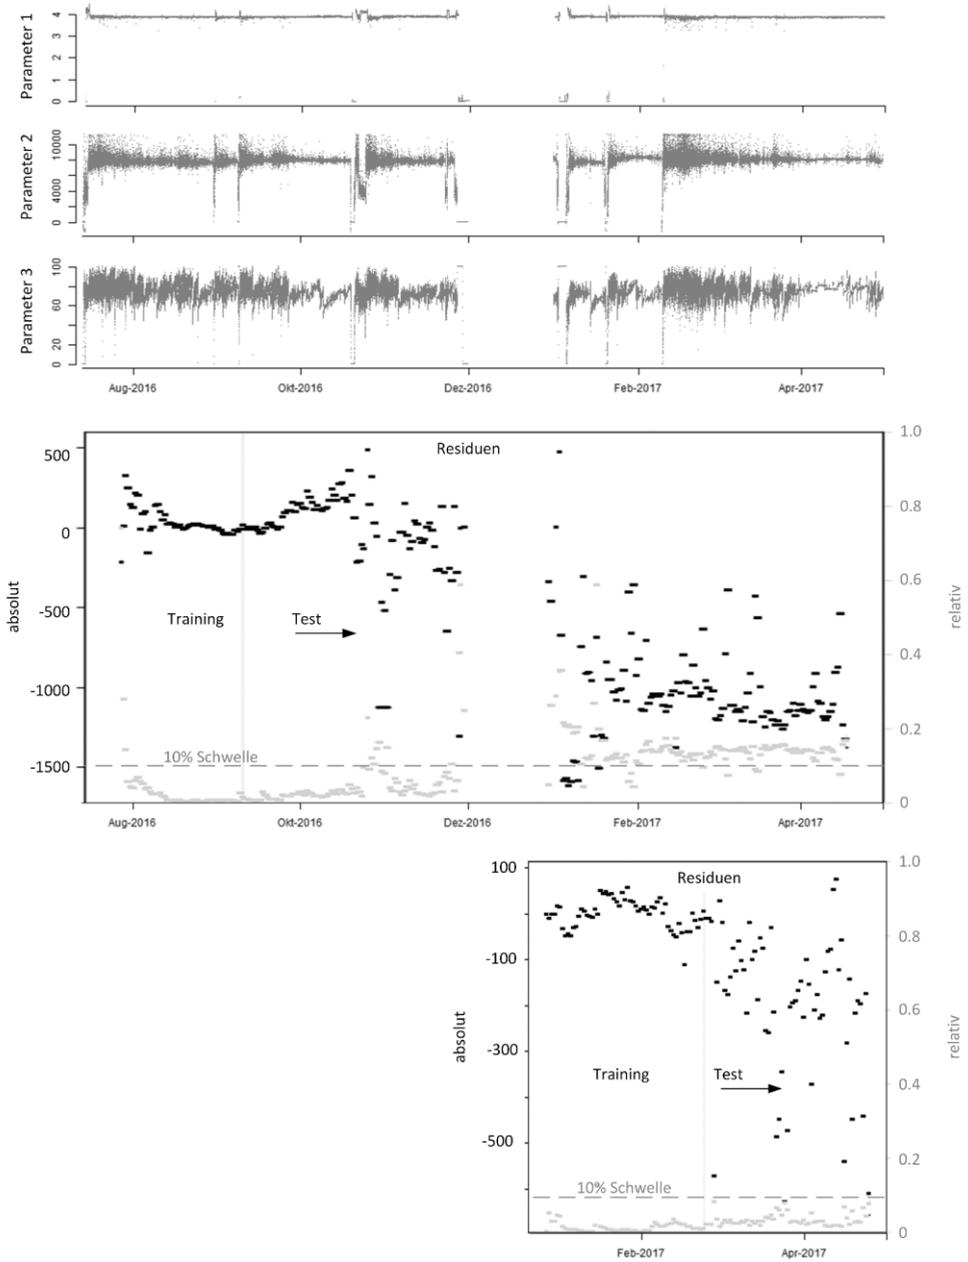


Abbildung 4.6 Anwendung des Modells auf industrielle Daten eines intakten Ventils; Erneutes Modelltraining nach Datenlücke.

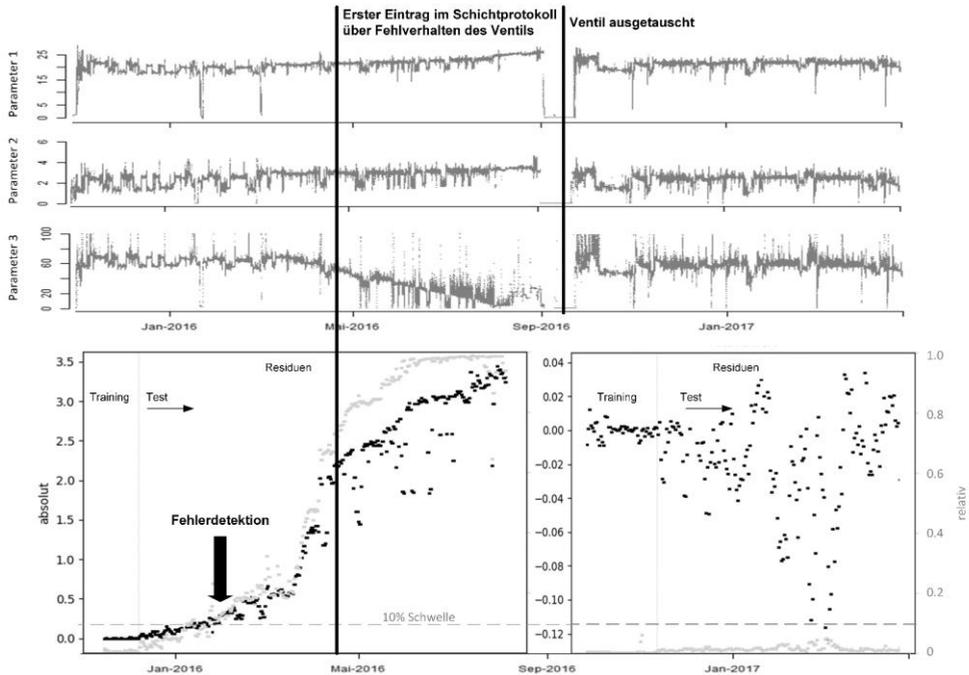


Abbildung 4.7: Anwendung des Modells auf industrielle Daten eines Ventils mit Wartung im September 2016.

Die Analyse der industriellen Daten zeigt, dass das Modell eine robuste Möglichkeit zur Zustandsüberwachung von Ventilen darstellt. Ventilfehler wurden frühzeitig detektiert (Anforderung 1), weshalb eine frühe Planung von Wartungstätigkeiten durchgeführt werden kann und gegebenenfalls bereits Ersatzteile besorgt werden können. Sollte es nicht unmittelbar möglich sein, Wartungstätigkeiten einzuplanen, kann das Modell genutzt werden, um das kontinuierliche Fortschreiten der Beschädigung zu beobachten, um im kritischen Fall gegebenenfalls schnell eingreifen zu können. Darüber hinaus kann die Zustandsüberwachung dazu genutzt werden, bei geplanten Stillständen gezielt Überprüfungen und Wartungen von auffälligen Ventilen durchzuführen. Im Gegensatz zur derzeitigen Praxis in prozesstechnischen Anlagen, bei welcher alle Ventile in den zyklischen Revisionen geprüft und gegebenenfalls gewartet werden, kann wertvolle Zeit gespart werden und der Prozess früher wieder anlaufen, wenn nur auffällige Ventile betrachtet werden müssen. Die Schwere der Beschädigung kann derzeit nur im Vergleich mit Messstanddaten bestimmt werden (Anforderung 3).

4.5 Ausblick auf Fehlerprognose

Die vorliegende Arbeit konnte zeigen, wie Fehler in Ventilen anhand der Prozessdaten detektiert und identifiziert werden können. Um eine Prognose der Remaining Useful Life durchführen zu können, müssen die Ursachen von Ventilschäden und nicht nur deren Auswirkungen genauer untersucht werden. Derzeit bestehende Ansätze konzentrieren sich auf die Berechnung eines Nutzungsgrades, der sich nicht nur auf die Betriebsstunden stützt. Durch das Einbeziehen von zusätzlichen Faktoren, wie die Summe der Ventilhub, kann ein erweiterter Nutzungsgrad identifiziert werden. Nichts desto trotz können schädigende Ereignisse wie Kavitation bisher nicht in die Analysen mit einbezogen werden. Beschreibende Größen, die die Größe der Kavitation im Ventil anzeigen bzw. messbar machen, sind bisher nicht mit Sicherheit identifiziert. Die Schallintensität könnte einen Hinweis auf Kavitation geben. In zukünftigen Arbeiten muss deshalb untersucht werden, wie Kavitation und Schallintensität zusammenhängen und welche Störgrößen im Prozess den direkten Zusammenhang zusätzlich überlagern. Mit diesem Wissen kann untersucht werden, wann Kavitation überhaupt zu Beschädigungen im Ventil führt. Diese Untersuchung von Wirkmechanismen muss auch für Erosion und Anhaftungen durchgeführt werden, damit ein datengetriebenes Modell Vorhersagen treffen kann. Um diese Ursachen untersuchen zu können, müssen die Medien, die durch die Ventile fließen, in eine Analyse miteinbezogen werden.

4.6 Zusammenfassung

Zur Verbesserung der Anlagenverfügbarkeit müssen Methoden entwickelt werden, die eine datengetriebene Überwachung von Systemen und Geräten zulässt, dessen innerer Zustand nicht von außen begutachtet werden kann. In prozesstechnischen Anlagen sind besonders Ventile von Interesse, da deren innerer Zustand nicht ohne die Unterbrechung des Betriebes und den Ausbau und Öffnung des Ventiles zu bestimmen ist. Eine datengetriebene Methode ist in diesem Beitrag entwickelt worden, welche anhand der Größen Durchfluss, Ventilhub und Druckdifferenz das Ventilverhalten überwacht. So kann der Ist-Zustand des Ventils mit dem Normalzustand verglichen und Beschädigungen des Ventils, welche mit einer Veränderung des Ventilverhaltens einhergehen, festgestellt werden. Um die relevanten Größen zu bestimmen, sind zunächst Versuche an einem Messband durchgeführt worden. Dadurch wurde gezeigt, dass eine Detektion von Fehlern möglich ist und über die Modellresiduen eine Aussage über die Art des Fehlers abgeleitet werden kann. Zur Bestimmung eines Beschädigungsgrades wurde die Einschätzung von Experten herangezogen. Die Anwendung in realen Industriedaten hat gezeigt,

dass die Modelle zur Fehlerdetektion, trotz einer gestiegenen Streuung der Modellergebnisse durch Rauschen und Seiteneffekte in den Daten, in diesen Beispielen verlässlich eingesetzt werden können. Es wurde gezeigt, dass durch ein solches Überwachungssystem Fehler früher erkannt und dementsprechend Maßnahmen ergriffen werden können, um die Verfügbarkeit der Anlage zu erhöhen. Nichtsdestotrotz muss noch untersucht werden, wie die Modelle in Ventilen mit anderem Einsatzzweck und anderen Umgebungsparametern reagieren. In zukünftigen Arbeiten muss neben der Detektion von Fehler auch die Prognose der Remaining Useful Life weiter vorangetrieben werden. Während die in dieser Arbeit entwickelten Modelle schleichende Beschädigungsprozesse detektieren können, kann eine Prognose nicht getätigt werden. Hierzu müssen die Mechanismen, die zu einer solchen Schädigung führen, näher untersucht werden, um die relevanten Messgrößen zu identifizieren und eine geeignete Datengrundlage zu schaffen.

4.7 Danksagung

Wir bedanken uns beim Bundesministerium für Wirtschaft und Energie (BMWi) für die Förderung des Projekts SIDAP (Förderkennzeichen 01MD15009F), als auch bei den Konsortial- und Kooperationspartnern des Projekts.

Literatur

- [JLB06] A. K. Jardine, D. Lin, D., Banjevic: A review on machinery diagnostics and prognostics implementing condition-based maintenance. *Mechanical Systems and Signal Processing*, 20 (7), S. 1483–1510, 2006.
- [FS+16] J. Folmer, C. Schrüfer, J. Fuchs, C. Vermum., B. Vogel-Heuser: "Data-Driven Valve Diagnosis to Increase the Overall Equipment Effectiveness in Process Industry," in 14th IEEE International Conference on Industrial Informatics (INDIN), IEEE, Jul. 2016, S. 6.
- [TW+17] E. Trunzer, I. Weiß, J. Folmer, C. Schrüfer, B. Vogel-Heuser, S. Erben, S. Unland, C. Vermum: Failure Mode Classification for Control Valves for Supporting Data-Driven Fault Detection. In: IEEE International Conference on Industrial Engineering and Engineering Management (IEEM), S. 2346-2350, 2017.
- [TW+18] E. Trunzer, C. Wu, K. Guo, C. Vermum, B. Vogel-Heuser: Data-driven Approach to Support Experts in the Identification of Operational States in Industrial Process Plants," in 44th Annual Conference of the IEEE Industrial Electronics Society (IECON), 2018. (in Druck)

5 Remote Operations

Leckage-Erkennung mittels Analyse thermographischer Bilder

Dr. M. Odenweller

Evonik Technology & Infrastructure GmbH, Hanau
matthias.odenweller@evonik.com

Dr. D. Pantförder, M. Fahimi Pirehgalin

Lehrstuhl für Automatisierung und Informationssysteme,
Technische Universität München, Garching bei München
{pantfoerder, mina.fahimi}@tum.de

5.1 Leckageüberwachung in prozesstechnischen Anlagen

Die Prozessindustrie ist eine der wichtigsten und umsatzstärksten Industriezweige in Deutschland. Auch im internationalen Vergleich belegt die deutsche Chemie und Pharmaindustrie einen der vorderen Plätze. Dies ist insbesondere von hoher Wichtigkeit, da sich Chemie- und Pharmakonzerne immer in einem internationalen Marktumfeld bewegen und daher kontinuierlich alle wesentlichen Eckpunkte der Produktion verbessern, um auch zukünftig ihre Positionen behaupten zu können. In diesem Zusammenhang ist ein höheres Automatisierungslevel, auch abseits der herkömmlichen Prozessautomatisierung, ein wichtiger Aspekt. Gerade im Bereich von Remote Operation bieten sich vielversprechende Möglichkeiten [NE161]. Eine technische Herausforderung für die Realisierung von Remote Operation ist eine zuverlässige Anomalieerkennung, zu der auch und insbesondere das Auffinden von Leckagen zählt. Derzeit wird diese Aufgabe vor allem durch menschliche Beobachtung im Rahmen von Rundgängen geleistet. Gerade hier bieten neue Analysemethoden in Verbindung mit geeigneter Sensorik eine vielversprechende Perspektive.

In diesem Beitrag werden bisherige Ansätze zur Leckageüberwachung sowie deren Probleme diskutiert. Anschließend wird ein Ansatz vorgestellt, der einen erfolgsversprechenden Schritt für eine automatisierte Leckageerkennung darstellt und sich wahrscheinlich auch auf die Erkennung anderer Anomalien ausweiten lässt.

5.1.1 Derzeitige Situation bei der Leckageüberwachung

Konventionelle Inspektionsmethoden beruhen auf der audio-visuellen Kontrolle durch das Bedienpersonal, deren Wirksamkeit stark von der Erfahrung des Prüfers und der Häufigkeit der Prüfung abhängt. Problematisch ist, dass es international nicht immer möglich ist, Zugang zu ausreichend geschultem Personal zu haben. Weiterhin zwingt eine zu spätere Erkennung von kritischen Leckagen, bedingt durch die mitunter lange Zeit zwischen den Prüfungen, zu erhöhten Kosten bei den korrektiven Maßnahmen. Bei der konventionellen Zustandsüberwachung kann es daher unabhängig vom hohen menschlichen Aufwand zu einer späten und ungenauen Leckageerkennung kommen. Jedoch ist eine schnelle und genaue Erkennung der Leckageposition von großer Bedeutung und unumgänglich. Zudem sind menschliche Inspektionen an sich sehr zeit- und kostenintensiv. Die aktuelle Situation und die Herausforderungen bei der Fehlererkennung motivieren die Idee der automatisierten Fernüberwachung.

5.1.2 Remote Monitoring – Fernüberwachung

Viele verschiedene Anwendungsbereiche erfordern ein automatisches Fehlererkennungssystem mit Fokus auf Leckageerkennung. Einige dieser Ansätze basieren auf ausgefeilten Sensorsystemen. Die Wirksamkeit der Detektionstechnik hängt dann oft von der Genauigkeit und Leistungsfähigkeit der Sensorsysteme ab. Zudem sind komplexe Sensorsysteme vergleichsweise teuer in der Anschaffung. Daher kann der Einsatz anderer Tools wie Infrarot-(IR-)Bildverarbeitungssysteme als Datenerfassungswerkzeug aus den Großanlagen und Fernüberwachung ein vielversprechender Ansatz bei der Fehlererkennung sein [N82]. Dies ist insbesondere der Fall, weil Kamerasysteme einen weiten Bereich einer Anlage simultan überwachen, wohingegen andere Sensorsysteme meist nur sehr lokal Informationen liefern. Kamerasysteme bieten weiterhin die Möglichkeit zukünftig auf mobilen Plattformen eingesetzt zu werden, um so mit weniger Hardware einen noch größeren Anlagenbereich effektiv und effizient überwachen zu können.

Aufgrund der so entstehenden großen Datenmenge sind Data-Mining-Strategien leistungsfähige Werkzeuge, die die Zuverlässigkeit der Fernüberwachung erhöhen können. Die Anwendung der maschinellen Lernalgorithmen zur Analyse der Daten von Prozessanlagen könnte zur Erkennung von Anomalien und zur Information des Bedieners genutzt werden. Dadurch ist es

möglich, ein kontinuierliches, autonomes Überwachungssystem zu entwickeln, welches zuverlässig über Störungen in der Anlage informiert und somit Kosten zu sparen und die Zuverlässigkeit zu erhöhen.

5.1.3 Datenerhebung aus der Ferne – IR-Kamerasysteme

Um über zuverlässige autonome Fernüberwachungssysteme zu verfügen, ist ein geeigneter Datenerfassungsmechanismus für industrielle Großanlagen erforderlich. Ein Ansatz kann der Einsatz von IR-Kameras an verschiedenen Stellen innerhalb der Anlage sein. Diese Geräte sind kostengünstiger als komplexe Sensorsysteme und komfortabler im industriellen Umfeld einzurichten. Der wichtigste Vorteil dieser Geräte ist, dass sie thermografische Bilder aufnehmen können, die die unterschiedlichen Temperaturen in der Umgebung zeigen. Die gelieferten thermografischen Bilder sind aufgrund des im chemischen Umfelds hohen thermischen Kontrasts nützliche Datenquellen für die Bildanalyse und eine vielversprechende Wahl für die Datenerfassung zur Fernüberwachung von Leckagen. Aufgrund der großen Datenmenge aus Kamerasystemen, können Methoden des maschinellen Lernens und Bildverarbeitungsalgorithmen verwendet werden, um Anomalien zu erkennen, zu lokalisieren und in der Fernüberwachung zu visualisieren.

5.1.4 Datenanalyse als leistungsfähiges Werkzeug im Remote-Monitoring

Um eine automatisierte Fernüberwachung zu ermöglichen, können Data-Mining-Ansätze zur Analyse der Thermografie-Bilder von IR-Kameras eingesetzt werden. Bildverarbeitungsalgorithmen können auf Basis thermografischer Videodaten zur Leckagesuche angewendet werden und bieten einen zuverlässigen, genauen und schnellen Leckagesuchmechanismus. In letzter Zeit wurden mehrere Studien durchgeführt, die mit Hilfe von Bildverarbeitungsalgorithmen das Problem der Anomalieerkennung in Produktionsanlagen mit Hilfe von thermografischen Videodaten [AY+15, AZ+16] untersuchen. Sie nutzen die Vorteile der IR-Kameras vor allem wegen ihrer Empfindlichkeit gegenüber Temperaturschwankungen durch austretendes Material (Gas oder Flüssigkeit). Die beiden Anwendungsfälle beschränken sich hierbei auf relativ einfache Aufbauten. Um das Problem der gleichzeitigen automatischen Leckageerkennung einer Vielzahl von Pipelines zu lösen, müssen diese Strategien jedoch weiterentwickelt oder neue, effizientere Verfahren erforscht werden.

Der wichtigste Beitrag dieser Studie ist es, eine Methode zu entwickeln, die auf maschinellen Lernalgorithmen und Bildanalyse basiert, um Leckagen zu erkennen. Zudem soll der entwickelte Algorithmus unabhängig von der Umgebung sein und eine Leckage auch in komplett neuen Randbedingungen erkennen. Zu diesem Zweck ist es notwendig, die relevanten Informationen aus den Bildern zu extrahieren, um die Merkmale der Leckage zu erhalten und die Wirkung von Rauschen zu eliminieren. Schließlich wird eine Klassifizierungsmethode verwendet, um die Videodaten als anomale oder normale Videos zu klassifizieren.

5.2 Einführung in den Demonstrator

Um eine zuverlässige Testumgebung für die Entwicklung einer Methode zur Leckageerkennung bei Rohrleitungen einer Prozessanlage bereitzustellen, wird ein Labor Demonstrator eingesetzt und mit thermostatisiertem Wasser betrieben. Die Leckage von Flüssigkeiten kann so an den dortigen Rohrleitungen einfach und sicher nachgestellt werden. Eine IR-Kamera erfasst Videodaten aus der Demonstrationsanlage und analysiert diese im Rahmen der Bildanalyse. Von diesem Demonstrator werden einige Thermografie-Videoaufnahmen gemacht, während sich die Anlage im Normalbetrieb befindet. Um einen Datensatz für das Modelltraining bereitzustellen, werden verschiedene Flüssigkeitsleckagen mit unterschiedlichen Leckgeschwindigkeiten und -positionen genutzt.

5.2.1 Technische Merkmale des Demonstrators

Im Demonstrator wird ein Thermostat mit integrierter Pumpe verwendet, um Wasser durch eine Reihe von Leitungen zu zirkulieren. Mehrere Rohrverschraubungen, verschiedene mögliche Strömungswege, eine Sackgasse und ein Probennahmehahn ermöglichen die Erzeugung von Leckagen unterschiedlicher Art und Position. Die Rohre sind überwiegend aus Edelstahl gefertigt. An zwei Positionen werden aber auch flexible Gummischläuche verwendet. Um die Sicherheit der Personen zu gewährleisten, die den Demonstrator benutzen, wird die maximale Temperatur des Mediums auf 50°C limitiert. Ein Beispielbild (Einzelframe) der thermografischen Daten aus der Demonstrationsanlage ist in Abbildung 5.1 dargestellt.

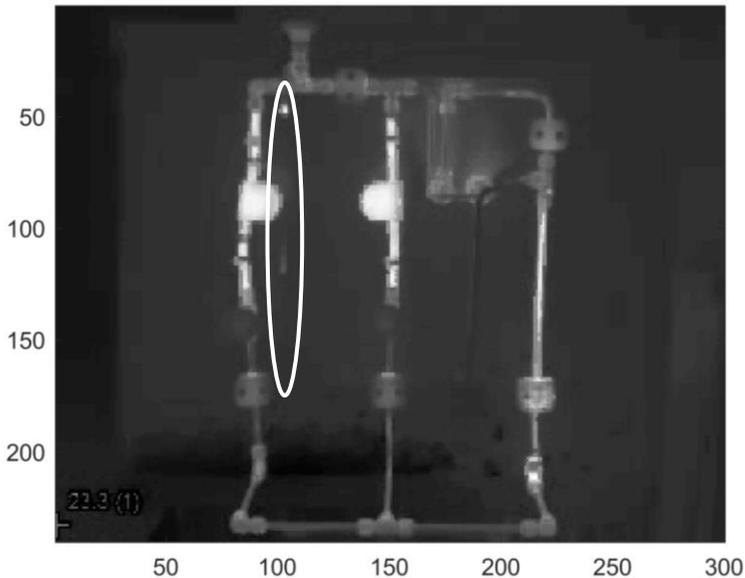


Abbildung 5.1: Unbearbeitetes Beispielbild des Demonstrators mit Leckagen (Heller = Wärmer, Leckage oben links mit weißer Ellipse markiert).

5.2.2 Verwendete Wärmebildkamera und Charakteristik

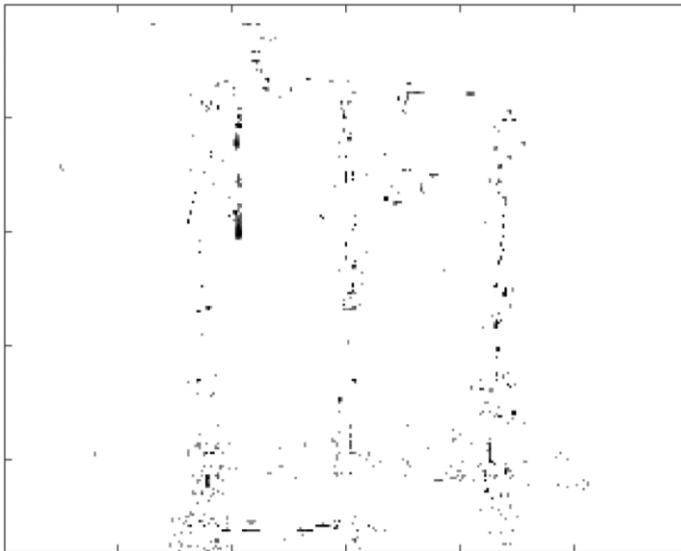
Bei der verwendeten IR-Kamera handelt es sich um eine Micro-Epsilon TIM640. Sie hat 640 x 480 Pixel und eine Temperaturauflösung von 75 mK. Entscheidend für den Einsatz dieser speziellen Kamera ist vor allem ihre Robustheit mit Schutzart IP67, sowie ihre Eignung für den Einsatz in einem Schutz- und Kühlgehäuse. Da die typische räumliche Auflösung einer IR-Kamera 320x240 Pixel beträgt, ist die vorhandene räumliche Auflösung für eine IR-Kamera recht hoch und erlaubt es, kleinere Ereignisse zu beobachten. Darüber hinaus verfügt die Kamera über die Funktionalität für den Rohdatenexport sowie eine Schnittstelle zur direkten Verarbeitung der Echtzeitdaten. Somit kann die Kamera zur Online-Zustandsüberwachung eingesetzt werden.

5.3 Leckagesuche mittels Datenanalyse

In diesem Abschnitt werden die wichtigsten Konzepte und die maschinellen Lernansätze zur Leckageerkennung beschrieben. Die Eingangsdaten für diesen Abschnitt sind die Videodaten aus der Demonstrationsanlage in verschiedenen Situationen. Einige Videoaufnahmen werden bei laufendem normalem Betrieb der Anlage gemacht. Andere Daten enthalten verschiedene Leckageszenarien mit unterschiedlichen Leckgeschwindigkeiten und unterschiedlichen Leckagepositionen. Die Rohdaten werden in Trainings- und Testvideos

unterteilt, in denen jeder Trainings- und Testdatensatz normale und anomale Videos enthält. Die Trainingsdaten werden für den Lernprozess verwendet. Anschließend werden die Testdaten verwendet, um die Genauigkeit und Zuverlässigkeit der entwickelten Methode zu bewerten.

Um die Wirkung von Leckagen in aufeinanderfolgenden Bildern (Frames) in jedem Video zu erhalten und den Einfluss des Hintergrunds zu beseitigen, werden aufeinander folgende Frames subtrahiert. Auf diese Weise wird die Intensität gleichbleibender Pixel deutlich reduziert oder ganz eliminiert, während die Hauptveränderungen in den kontinuierlichen Bildern durch austretende Flüssigkeit beibehalten werden können. Wie in Abbildung 5.2 gezeigt enthalten die subtrahierten Frames Rauschen. Dieses Rauschen resultiert aus dem Rauschen des Sensors und dem Rauschen, welches durch die Videokompression der Rohdaten entsteht. Daher ist es notwendig, das Rauschen herauszufiltern, um eine genauere Leckageerkennung zu erreichen. Nach der Rauschunterdrückung ist ein Feature-Extraktionsmechanismus notwendig, um die Merkmale der Leckage in den subtrahierten Frames zu bestimmen und gleichzeitig nicht ausgefilterte Schwankungen im Hintergrund, sowie anderweitige Anomalien (z.B. Umwelteinflüsse oder Reflektionen), zu eliminieren, um die Rechenkomplexität zu reduzieren. Danach können die Daten anhand der extrahierten Informationen in normale und anomale Kategorien eingeteilt werden.



*Abbildung 5.2: Beispielhaftes Differenzbild
(dunkler = größerer absoluter Temperaturunterschied).*

5.3.1 Verfahren zur Rauschunterdrückung

Um Störrauschen aus verschiedenen Quellen zu entfernen, ist ein Filterprozess notwendig, der sich aus mehreren aufeinanderfolgenden Schritten zusammensetzt.

Der erste Schritt der entwickelten Rauschunterdrückungsmethode ist die Entfernung von Hintergrundrauschen. In diesem Schritt wird ein bestimmter Schwellwert definiert und die Pixel, die einen niedrigeren Wert als diese Schwelle haben, werden aus den subtrahierten Frames entfernt.

Der nächste Schritt bei der Rauschunterdrückung ist die so genannte Einzelpixel-Entfernung. Als Einzelpixel wird ein Pixel betrachtet, dessen Wert ungleich Null ist, dessen benachbarte Pixel aber alle einen Wert von Null haben. Wenn alle benachbarten Pixel eines einzelnen Pixels Null sind, sollte auch das entsprechende Pixel auf null gesetzt werden, da der Verdacht besteht, dass die Daten auf Sensorrauschen oder andere Störungen zurückzuführen sind. Wenn es also Pixel gibt, deren benachbarte Pixel den Wert Null haben, können sie bei der Einzelpixel-Rauschunterdrückung auf null gesetzt werden.

Im nächsten Schritt werden die subtrahierten Frames durch Mittelung über mehrere Frames zusammengeführt, in diesem Beispiel fünf Frames. Die austretende Flüssigkeit, die als Tropfen in allen fünf aufeinanderfolgenden subtrahierten Frames sichtbar ist, wird als deutlicher Streifen im neu erzeugten Bild dargestellt. Tatsächlich kann durch die Berechnung des Durchschnitts von fünf Bildern die Wirkung der Bewegung der Tropfen während dieser Bilder im zeitlichen Mittelwert erfasst werden.

Der letzte Rauschunterdrückungsschritt, der als „Vertical-Neighbourhood“-Filter (vertikaler Nachbarschaftsfilter) bezeichnet wird, erfolgt auf Basis des zeitlichen Mittelwerts. In diesem Schritt werden für jedes verbleibende Pixel alle benachbarten Pixel innerhalb eines vertikalen Bandes um das Pixel berücksichtigt. Wenn ein Pixel Nachbarn in vertikaler Richtung hat, kann das Pixel als Teil einer größeren Leckage beibehalten werden. Das Ergebnis des „Vertical-Neighbourhood“-Filters ist in Abbildung 5.3 dargestellt. Die Wirkung des zeitlichen Mittelwerts (Durchschnitt über fünf kontinuierliche Bilder) und des Vertikalfilters beruht im Wesentlichen auf der Tatsache, dass die Tropfen in der Leckage eine vertikale Bewegung vom Kopf oder der Mitte des Bildes zur Unterseite des Bildes haben. Diese beiden Filterstufen zusammen können den Effekt der Bewegung von Tropfen entlang der vertikalen Achsen aufrechterhalten und gleichzeitig den größten Teil des Hintergrundgeräusches eliminieren.

Das Ergebnis der Rauschunterdrückung für ein Beispielframe aus vier verschiedenen Videos mit Leckagen ist Abbildung 5.4 in dargestellt. Das Ergebnis zeigt, dass der vorgeschlagene Rauschunterdrückungsmechanismus den Effekt des Rauschens minimiert und die relevanten Pixel einschließlich der Leckage erhalten bleiben.

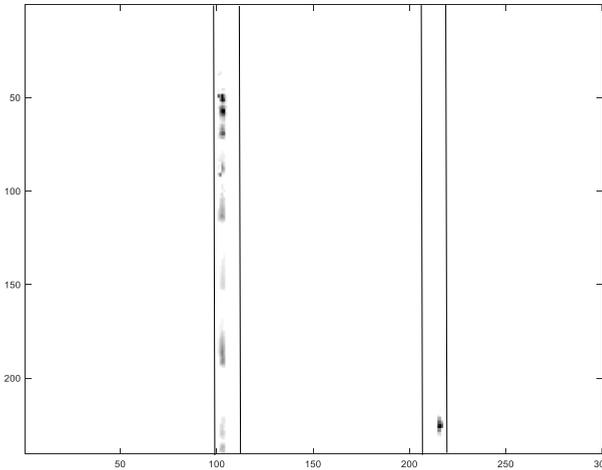


Abbildung 5.3: Funktionsprinzip der „Vertical-Neighbourhood“-Filters.

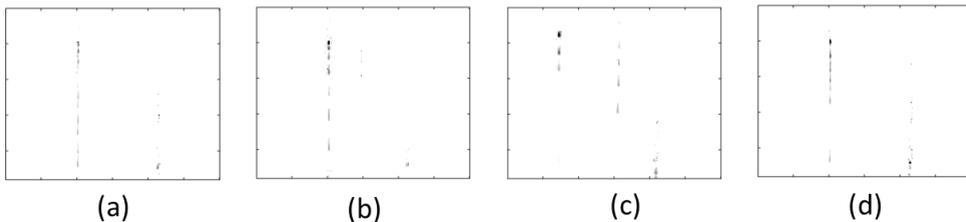


Abbildung 5.4: Vollständig gefilterte und gemittelte Beispielframes mit Leckagen (a-d) (dunkler = größerer absoluter Temperaturunterschied).

5.3.2 Merkmalsextraktion

Da die Anzahl der Pixel (Features) sehr groß ist und eine Berücksichtigung aller Pixel in der Bildanalyse die Rechenkomplexität erhöht, ist ein genauer Merkmals-Extraktionsmechanismus notwendig. Durch die Merkmals-Extraktion (Feature-Extraktion) werden die wichtigsten Pixel und deren Werte erhalten und redundante Daten eliminiert. Mit der linearen Feature-Extraktionsmethode namens Principal Component Analysis (PCA) [DJ+06] ist es möglich, nur Pixel zu berücksichtigen, die die höchste Varianz in den Frames aufweisen und dann die Rohbilder auf diese Pixel zu reduzieren.

Die Transformation der Rohdaten in einen niederdimensionalen Raum wird in der Regel durch Informationsverlust begleitet. Um den Verlust so gering wie möglich zu halten, sollten die wichtigsten Datenmerkmale beibehalten werden. In der PCA werden die Richtungen der höchsten Varianz in den Daten als die wichtigste Dynamik angesehen. Ziel der Transformation ist es daher, alle stark variierenden Datenkomponenten zu finden und zu begünstigen und alle anderen zu verwerfen.

Um eine Feature-Extraktionsmethode sinnvoll auf die Frames anzuwenden und eine spätere Lokalisierung der Leckagen zu ermöglichen, ist es notwendig, die Frames in Blöcke zu unterteilen. Die Unterteilung der Rahmen in Blöcke hilft nicht nur, die Leckage zu erkennen, sondern auch die genaue Position der Leckage zu finden. Jeder Block hat eine Größe von $L \times L$ Pixel und wird verwendet, um den gesamten Rahmen in kleinere Teilungen aufzuteilen. Die Blöcke sind in Abbildung 5.5 als grüne Gitter dargestellt. Dieser Ansatz erlaubt es, den PCA-Mechanismus auf jeden Block einzeln anzuwenden. Mit dem Block-PCA werden Blöcke mit Leckagen (anomale Blöcke) erkannt und im nächsten Schritt die genaue Position der Leckagen in jedem Block ermittelt. Daher können die Leckagen in jedem Block einzeln lokalisiert werden. Die Grundidee der sogenannten Block-PCA ist in Abbildung 5.5 dargestellt. Bei diesem Ansatz erfolgt die PCA-Berechnung pro Block auf Basis der Trainingsdaten. Dann werden aus den Trainingsdaten ein Satz von Blöcken mit Leckagen (anomale Blöcke) und ein Block ohne Leckagen (normaler Block) ausgewählt. Der definierte Satz sollte idealerweise alle möglichen Formen der Leckagen enthalten. Da dies nicht zu erreichen ist, sollte eine ausreichend große Zahl an verschiedenen Leckagen vorgelegt werden. Schließlich wird auch ein normaler Block für dieses Set ausgewählt und zur Klassifizierung normaler Blöcke verwendet. Da alle Pixel im normalen Block den Wert Null haben, sind alle normalen Blöcke gleich. Daher ist es ausreichend, nur einen normalen Block in diesem Set zu berücksichtigen. Der Satz anomaler Blöcke und ein normaler Block ist in Abbildung 5.6 dargestellt. Dieser Satz von Blöcken wird zum Training verwendet und die entsprechend ermittelten PCAs werden für die Klassifizierung der Testdaten herangezogen. Die Autoren bezeichnen diese Menge als $S = \{PCA\ b1, PCA\ b2, \dots, PCA\ b11\}$.

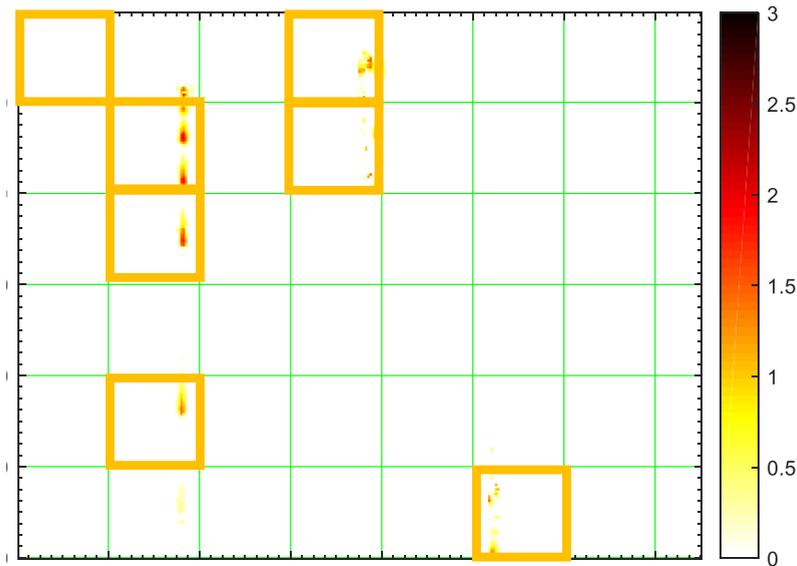


Abbildung 5.5: Block-PCA zur Anomalieerkennung und -lokalisierung. Blöcke in grün gekennzeichnet, erkannte Anomalien in den Blöcken in Gelb, Differenztemperaturskala rechts.

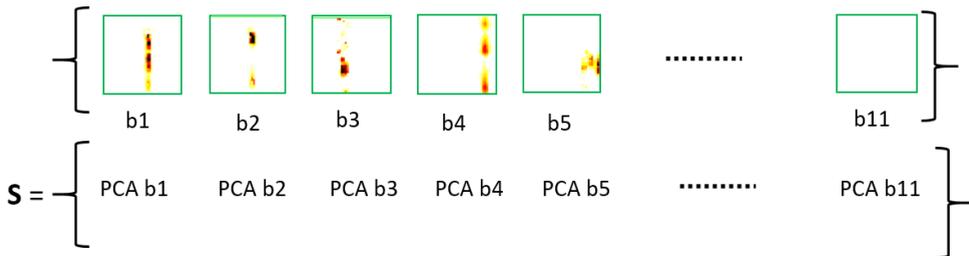


Abbildung 5.6: Blöcke mit Anomalien (b1-b10), normaler Block (b11) und PCA-Berechnungen für jeden der Blöcke.

Wichtig ist hierbei zu nennen, dass nicht die Leckage und deren Position selbst gelernt werden, sondern die Form und Charakteristik von Leckagen erfasst wird. Dies ist eine Voraussetzung für die erfolgreiche Übertragung der Ergebnisse in die industrielle Praxis. Für die Modellerstellung müssen nicht echte Leckagen in der zu überwachenden Anlage erzeugt werden, sondern es können Daten aus Demonstrationsumgebungen mit ähnlichen Umgebungsbedingungen (Temperaturen des Hintergrunds und des Mediums) verwendet werden. Mit Hilfe dieser Trainingsdaten lernt der Algorithmus, Leckagen richtig vom normalen Betrieb zu unterscheiden. Anschließend kann der Algorithmus ohne Neuanpassung in der echten Anlage eingesetzt werden.

5.3.3 Klassifikationsmethoden zur Fehlererkennung

In diesem Beitrag sind die Merkmalsvektoren die Ausgabe der PCA-Blöcke. In jedem Block werden die ersten 10 Hauptkomponenten anhand der Trainingsdaten berechnet.

Um Leckagen in den Testdaten zu erkennen und zu lokalisieren, ist eine Klassifizierung erforderlich, um jeden Block als anomal oder normal zu klassifizieren. Daher werden zur Klassifizierung der Testdaten die Blöcke der Frames in jedem Testvideo an einen binären Klassifikator mit zwei Kategorien in: normal und anomal übergeben.

Ein k-Nearest Neighbour-Algorithmus [PD07] wird als Klassifizierungsmechanismus verwendet. Der nächste Nachbaransatz ist ein nicht-parametrisches Maschinenlernverfahren, das auf die Klassifizierung von Dateninstanzen abzielt. Sie beruht auf der minimalen Entfernung, z.B. der euklidischen Entfernung, zwischen den Proben in jeder Klasse. Daher sind die Proben, die in der gleichen Klasse sind, einander ähnlich (nahe).

In dem in diesem Beitrag beschriebenen Ansatz wird jeder Frame im Testvideo auf die Blöcke aufgeteilt. Dann wird jeder Block der Testdaten (Testblock) mit den in Satz S definierten Blöcken verglichen. Die Trainingsdaten werden tatsächlich auf einen Satz von Blöcken mit anomalen und normalen Blöcken reduziert. Um jeden Testblock zu klassifizieren, wird der euklidische Abstand zwischen der PCA des Testblocks und allen PCAs der definierten Blöcke im Set S berechnet. Dann wird der nächste Block (minimaler euklidischer Abstand) im Set S zum Testblock gefunden. Wenn der nächste Block ein anomaler Block ist, wird der Testblock ebenfalls als anomal klassifiziert, ansonsten als normaler Block.

Nach Erkennung eines anomalen Blocks wird für jeden anomalen Block der Massenschwerpunkt berechnet, um die Leckagen innerhalb des Blocks zu lokalisieren. Ein Beispielframe aus den Testdaten ist in Abbildung 5.7 dargestellt und zeigt das Lokalisierungsergebnis in jedem anomalen Block. Kleine weiße Kreise zeigen die Positionen der Leckagen in jedem der Blöcke an. Die weißen Kreise werden um den Massenpunkt in den jeweiligen Blöcken gezeichnet. Die Ergebnisse zeigen, dass die vorgeschlagene Methode Leckagen in den erhobenen Testdaten erkennen und lokalisieren kann.

Die grafische Markierung von erkannten Leckagen in den Differenz- und Videobildern erlaubt es dem Anlagenpersonal im Anlagenbetrieb, die Schwere der Leckage zu erkennen und mögliche Fehlalarme korrekt einzuschätzen.

Zusammenfassend werden folgende Schritte für die Testdaten durchgeführt:

- a) Das Testvideo wird auf die Frames aufgeteilt.
- b) Gemittelte Differenzbilder werden berechnet.
- c) Der Rauschunterdrückungsmechanismus wird auf die Differenzbilder angewendet.
- d) Differenzbilder werden auf die Blöcke aufgeteilt.
- e) PCA wird pro Block berechnet.
- f) Das Ergebnis der PCA in jedem Block wird mit jedem Anomalieblock und Normalblock in der definierten Menge S in Abbildung 5.6 verglichen.
- g) Der ähnlichste Block zu jedem Block von Testdaten wird gefunden.
- h) Der Block wird dem ähnlichsten Block zugeordnet.
- i) Berechnung des Massenschwerpunkts bei anormalen Blöcken und Visualisierung der Leckage

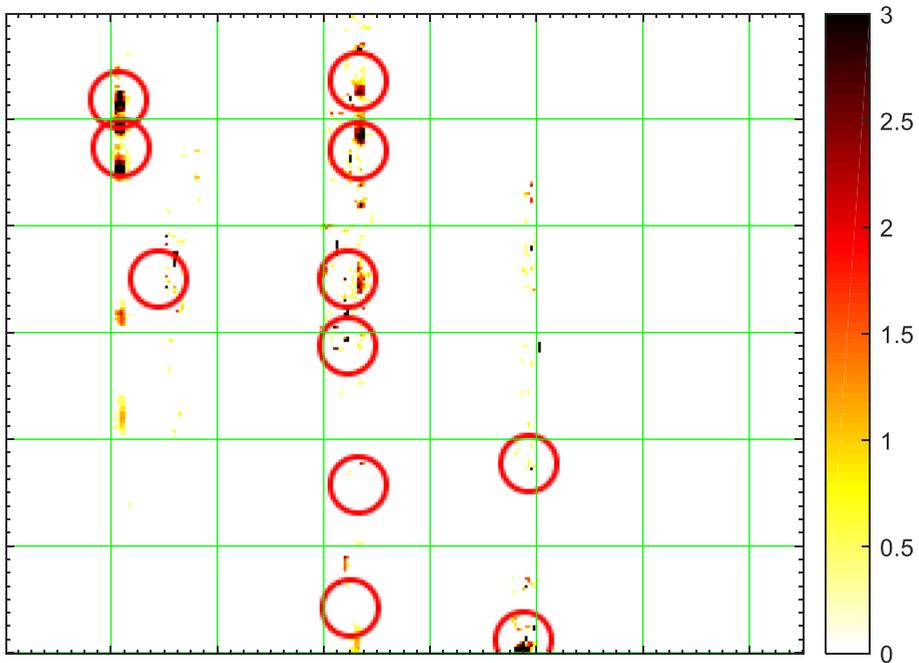


Abbildung 5.7: Lokalisierung der Leckagen (rote Kreise) pro Block (grüne Rechtecke) für einen Beispielframe.

5.3.4 Genauigkeit und Evaluation

Um die vorgeschlagene Methode zu evaluieren werden die am Demonstrator erhobenen Videodaten in jeweils einen Trainings- und Testdatensatz aufgeteilt. Die Anzahl der Datenpunkte verschiedener Klassen (normal und anomal) in jedem Datensatz sind in Tabelle 5.1 dargestellt.

Tabelle 5.1: Anzahl der Datenpunkte (Videosequenzen) im Trainings- und Testdatensatz.

Datensatz	Insgesamt	Normale Videos	Anormale Videos
Training	14	5	9
Test	11	4	7

Das Ergebnis der Validierung ist in Abbildung 5.8 in Form einer Wahrheitstabelle für die Klassifikation des Testdatensatzes gegeben. In der Wahrheitstabelle entsprechen die diagonalen Zellen den Beobachtungen, die richtig klassifiziert sind. Es zeigt, dass alle sieben anomalen Videos in den Testdaten korrekt in der anomalen Klasse klassifiziert sind und von allen vier normalen Videos nur ein Video als anomal eingestuft wird (Fehlalarm). Der Grund dafür ist, dass das fehlerhaft klassifizierte Videos auch nach der Rauschentfernung noch sehr verrauscht ist und der Algorithmus deshalb eine Leckage erkannt hat. Das allgemeine Ergebnis in Bezug auf das F -Maß mit einem $F = 90,9\%$ zeigt jedoch, dass der vorgeschlagene Ansatz ein vielversprechender Ansatz zur Leckageerkennung ist und eine hohe Modellgüte erreicht wurde.

Vorhergesagte Klasse	Normal	3 27,30%	0 0,00%
	Anormal	1 9,10%	7 63,60%
		Normal	Anormal
		Wirkliche Klasse	

Abbildung 5.8: Wahrheitstabelle der Klassifikation für den Testdatensatz.

Betrachtet man die erzielten Modellergebnisse im Kontext des Anwendungsfalls und der Unterstützung des Anlagenpersonals, können die Ergebnisse als sehr gut bezeichnet werden. Einzelne Fehlalarme, welche nur für kurze Zeit auftreten und eine nicht vorhandene Leckage anzeigen, sind aufgrund der menschlichen Überwachung als unkritisch zu bewerten. Hier müssen zur effizienten Unterstützung, aufbauend auf dem Ergebnis der Analyse, noch Maße für Schwere der Leckage entwickelt werden (Dauer seit Auftreten der Leckage, Größe der Leckage). Erst wenn die Schwere ein bestimmtes Maß übersteigt, der Algorithmus also mit hoher Sicherheit eine Leckage erkannt hat, sollte dann eine Alarmmeldung an das Anlagenpersonal ausgegeben werden. Dies verlängert zwar die Zeitspanne bis zur Erkennung der Leckage, vermeidet aber effektiv irreführende Fehlalarme und verringert somit weiter die Belastung des Personals. Im Vergleich zu manuellen Anlagenrundgängen ist die Reaktionszeit auf Leckagen aber immer noch deutlich verkürzt.

5.4 Zusammenfassung und Ausblick

In diesem Beitrag wird eine auf Bildanalyse basierende Methode zur Leckageerkennung vorgestellt. Die Ergebnisse zeigen, dass die implementierte Methode mit den am Demonstrator erhobenen Videodaten sehr gut funktioniert. Der Rauschfilter erreicht eine wesentliche Verbesserung der Bildqualität. Merkmalsextraktion auf der Basis von PCA kann die relevante Information in subtrahierten Bildern extrahieren. Das Ergebnis der Klassifizierung zeigt, dass die Leckage mit angemessener Genauigkeit erkannt und lokalisiert werden kann. Die Filteralgorithmen müssen jedoch bei neuen Datensätzen mit unterschiedlichem Rauschverhalten überarbeitet werden. Die weitere Forschung in diesem Bereich wird sich auf die zeitliche Komplexität der vorgeschlagenen Methode konzentrieren und sie für die Anwendung in Echtzeit erweitern.

5.5 Danksagung

Die Autoren bedanken sich beim BMWi für die Förderung des Projekts SIDAP (Förderkennzeichen 01MD15009F) und bei den Kooperationspartnern des SIDAP-Konsortiums für die Unterstützung.

Literatur

[NE161] NAMUR – Interessensgemeinschaft Automatisierungstechnik der Prozessindustrie: „NAMUR-Empfehlung NE 161: Grundlagen der Remote Operations“, 2016.

- [N82] M.D. Nellis, "Application of thermal infrared imagery to canal leakage detection," *Remote Sensing of Environment*, vol. 12, no. 3, S. 229–234, 1982.
- [AY+15] K. Adefila, Y. Yan, and T. Wang, "Leakage detection of gaseous CO₂ through thermal imaging," in *2015 IEEE International Instrumentation and Measurement Technology Conference (I2MTC) Proceedings, Pisa, Italy, 2015*, S. 261–265.
- [AZ+16] A. Atef, T. Zayed, A. Hawari, M. Khader, and O. Moselhi, "Multi-tier method using infrared photography and GPR to detect and locate water leaks," *Automation in Construction*, vol. 61, S. 162–170, 2016.
- [DJ+06] Z. David, X. Jing, and J. Yang. "Principle Component Analysis," *Biometric Image Discrimination Technologies: Computational Intelligence and its Applications Series*. IGI Global, 2006. S. 21-40.
- [PD07] C. Padraig, and S. Delany. "k-Nearest neighbor classifiers," *Multiple Classifier Systems 34.8 (2007)*: S. 1-17.

6 Smart Data in klein- und mittelständischen Unternehmen der Fertigungstechnik

Dr. D. Schütz, M.R. Lopez

GEFASOFT GmbH

{daniel.schuetz, monica.romero.lopez}@gefasoft.de

6.1 Motivation und Einleitung

In Zeiten eines immer stärker werdenden globalen Wettbewerbs sehen sich produzierende Unternehmen in der Verfahrenstechnik wie auch in der Fertigungstechnik mit der Herausforderung konfrontiert, ihre Produkte möglichst kostengünstig und effizient zu produzieren. Um die Effizienz der Produktion zu überwachen, sind spezielle Kennzahlen, wie bspw. die OEE (Overall Equipment Effectiveness), für produzierende Unternehmen bereits jetzt ein wichtiges Maß für die Wirtschaftlichkeit und Effizienz der Produktion.

Über solche, bereits weit verbreitete einfache Kennzahlen hinaus, stellt die Anwendung neuartiger Konzepte zur Datenauswertung einen vielversprechenden Ansatz dar, bspw. Stillstände an Maschinen zu erkennen, bevor sie auftreten oder Möglichkeiten zur Optimierung des Produktionsablaufs zu identifizieren und so die Effizienz der eigenen Produktion weiter zu steigern. Ziel des Forschungsprojekts SIDAP¹³, das vom Bundesministerium für Wirtschaft und Energie gefördert wurde, war daher Untersuchung und Adaption von Big Data und Smart Data Technologien für solche wettbewerbsrelevanten Nutzungsszenarien mit Fokus auf die verfahrenstechnische Domäne.

Im Vergleich zur Verfahrenstechnik ist die Fertigungstechnik in Deutschland von einer größeren Heterogenität der Unternehmen geprägt. Neben den großen Automobilherstellern und Automobilzulieferern existiert eine sehr hohe Anzahl an kleinen und mittelständischen Unternehmen (KMU), welche einen sehr großen Anteil zu der Wirtschaftsleistung in Deutschland beitragen. Die Produktion dieser Unternehmen zeichnet sich einerseits durch Anteile an vollautomatisierter Fertigung, aber andererseits ebenfalls durch einen hohen Anteil an teilautomatisierter Fertigung oder Werkstattfertigung mit hohem Personaleinsatz aus. So liegt bspw. der Bereich von Food & Beverage genau in der Mitte zwischen der Verfahrenstechnik und der Fertigungstechnik.

¹³ Skalierbares Integrationskonzept zur Datenaggregation, -analyse, -aufbereitung von großen Datenmengen in der Prozessindustrie; <http://www.sidap.de>, aufgerufen am 18.07.2018.

GEFASOFT besitzt langjährige Expertise in diesem Bereich und übernahm daher innerhalb des Projekts SIDAP die Aufgabe der Untersuchung und Vorbereitung des Transfers von Smart Data Konzepten in die Fertigungstechnik sowie die Aufarbeitung der erarbeiteten Lösungen für kleine und mittelständische Unternehmen. Da die Schwerpunkte im Gesamtprojekt ansonsten überwiegend auf Untersuchungen von Smart Data Konzepten für verfahrenstechnische Applikationen lagen, wurde durch die in diesem Kapitel beschriebenen Arbeiten auch die Fertigungstechnik mit einbezogen und damit ein umfassenderer Ansatz erarbeitet. Ein weiteres Ziel des hier beschriebenen Teilprojektes war es, die erarbeiteten Ansätze skalierbar und damit auch für kleinere Unternehmen wirtschaftlich einsetzbar zu halten.

Dieser Beitrag stellt die gesetzten Ziele und erreichten Ergebnisse der GEFASOFT GmbH aus dem Rahmen des Projekts SIDAP vor. Die weiteren Kapitel dieses Beitrags sind gegliedert wie folgt: im nächsten Kapitel wird der Projektpartner und dessen Produkt, das Manufacturing Execution System (MES) Legato Sapient, kurz vorgestellt, sowie die Potenziale für eine Integration von Smart Data Konzepten aufgezeigt. In den anschließenden Kapiteln werden die Ergebnisse der GEFASOFT GmbH, die an diesen Stand der Technik anknüpfen, vorgestellt und die konkreten Möglichkeiten zur Integration. Der Beitrag endet mit einer Zusammenfassung und einem Ausblick auf weitere wissenschaftliche und technische Zielsetzungen und nächste Schritte.

6.2 Das Manufacturing Execution System Legato Sapient

Die GEFASOFT GmbH mit Sitz in München entwickelt und implementiert als Innovationsführer für Online-Datenaustausch und transparente Informationsdarstellung zur Steigerung der Effizienz von Prozessen seit mittlerweile mehr als 25 Jahren Lösungen für Prozessvisualisierungen, Produktionsleitsysteme und MES für produzierende Unternehmen. Unter dem Motto intelligent produzieren ist sie mit Produkten und Dienstleistungen ein starker Partner in Ihren Projekten zur Effizienzsteigerung.

GEFASOFT ist in vielen Anwendungen und unterschiedlichen Branchen zu Hause. Ein besonderer Fokus liegt in der diskreten und hochautomatisierten Serienfertigung im Bereich Automotive. Die Produkte des Unternehmens sind aber auch in anderen Branchen wie z.B. Elektrogeräte, Baustoffe, Pharma and Food, Energy Technology oder Building Management erfolgreich im Einsatz. Insbesondere die maßgeschneiderte Konfiguration und Entwicklung von Automatisierungs- und IT-Lösungen für diese verschiedenen

Branchen, deren Prozesse und spezifischen Anforderungen für den Einsatz in Großunternehmen, aber auch im Mittelstand, zeichnen das Unternehmen aus.

Aufgrund der Vielzahl an bearbeiteten Kundenprojekten verfügt das Unternehmen über detailliertes Know-How was die Anforderungen und Besonderheiten in Bezug auf die Steuerung von Produktionsabläufen und das zugehörige Informationsmanagement in verschiedensten Branchen anbetrifft.



Abbildung 6.1: Das MES Legato Sapiens im Produktionskontext.

Das Produkt Legato Sapiens ist ein flexibles und skalierbares MES / Leitsystem, das vom Monitoringsystem in der hochautomatisierten Fertigung bis zum kompletten MES variabel eingesetzt werden kann. Bei jeder Applikation von Legato Sapiens steht das Erzeugen von Transparenz über alle Unternehmensbereiche im Vordergrund. Legato Sapiens bietet verschiedene Bausteine zur Steigerung der Effizienz in der Produktion und deckt dafür ein breites Spektrum von Anwendungen ab.

Die weltweit installierten Applikationen reichen von einfachen Störmeldesystemen über klassische MDE-/BDE-Lösungen bis hin zu kompletten Produktionsmanagementsystemen. Legato Sapiens ist modular aufgebaut. Für alle wesentlichen MES Funktionen sind eigenständige Funktionsmodule vorhanden. Zusätzliche Bausteine können zu einer bestehenden Installation auch später freigeschaltet werden – Legato Sapiens wächst mit den Anforderungen des Kunden. Durch die vertikale Integration aller Produktionsdaten trägt das MES entscheidend zur Optimierung einer Fertigung bei. So lassen sich beispielsweise Anlagenzustände transparent darstellen, Qualitätsparameter zuverlässig überwachen oder Störmeldungen sofort an die Instandhaltung weiterleiten.

6.3 Ziele des Projekts SIDAP-sMES

Hauptziel des Projekts SIDAP – sMES (smartMES@KMU) war es kleine und mittelständische Unternehmen zu befähigen, die Ideen von Smart Data effektiv und ohne den Einsatz hoher finanzieller Ressourcen für Infrastruktur- und Softwarelizenzkosten zu nutzen. Im Projekt war es daher zunächst notwendig das Verständnis für diese Thematik zu schaffen und Softwarelösungen zu konzipieren, mit denen es möglich ist schrittweise die nötigen Strukturen einzuführen ohne dabei zu große finanzielle oder strukturelle Risiken eingehen zu müssen. Hierfür ist das Erreichen unterschiedlicher Teilziele und Ergebnisse angestrebt. Der erarbeitete Lösungsansatz besteht dabei aus vier unterschiedlichen Lösungskomponenten, die in den folgenden Kapiteln kurz beschrieben werden.

6.3.1 Leitfaden für Smart Data Konzepte

Für kleine und mittelständische Unternehmen sollte – eingebettet in den Kontext der weiteren Lösungskomponenten – ein Leitfaden gefunden werden, mit dem zielgerichtet die Einführung und der Einsatz von im Projekt SIDAP untersuchten Ansätzen möglich wird. Dieser Leitfaden sollte außerdem den Nutzen für die Unternehmen aufzeigen und eine modulares Vorgehen vorgeben.

Das modulare Vorgehen soll den Einstieg in die Thematik mit unterschiedlichen Startpunkten ermöglichen. Ist bspw. bereits eine Betriebsdatenerfassung im Unternehmen vorhanden oder werden die Prozesswerte bereits in der Steuerungsebene verworfen? Möglicherweise besitzt ein Unternehmen bereits einfache Auswertelgorithmen, wohingegen ein anderes nur den Output seiner Produktion betrachtet.

6.3.2 Modularer Softwarebaukasten

Um den Einstieg in die Thematik Smart Data für KMUs zu vereinfachen (oder überhaupt erst zu ermöglichen), sollte ein modularer Softwarebaukasten entwickelt werden. Ziel dieses Werkzeugs ist es, einen skalierbaren und schrittweisen Einstieg in die Datenanalyse mittels Smart Data Algorithmen für kleine und mittelständische Unternehmen zu ermöglichen. Der Softwarebaukasten sollte dabei ebenfalls prototypisch implementiert werden und erste unterschiedliche Module für die (Prozess-)Datenerfassung, Auswertung, Aufbereitung sowie die Visualisierung der Ergebnisse zur Ableitung von Handlungsempfehlungen bereitstellen. Sowohl die Datenerfassung auf der einen Seite, wie auch die Visualisierung der Ergebnisse, soll dabei an Legato Sapi-ent als MES angebunden werden können.

Für das enthaltene Modul zur Auswertung der Daten war vorgesehen, dass es wiederum aus weiteren Submodulen besteht. Diese Submodule kapseln unterschiedlich komplexe Methoden und Algorithmen in unterschiedlichen Programmiersprachen und (Rechen-)Umgebungen und besitzen dadurch unterschiedliche Voraussetzungen an Hard- und Software. Die (Sub-)Module zur Berechnung sollen dabei beliebig miteinander kombiniert (d.h. bspw. aneinandergereiht ausgeführt) werden können und so, zusammen mit dem Leitfaden, die Möglichkeit bieten, skalierbar stufenweise eingesetzt zu werden. Damit sind die finanziellen und strukturellen Risiken für KMUs überschaubar. Der modulare Softwarebaukasten soll – integriert in ein MES (bspw. Legato Sapient) – damit die Schnittstelle zwischen KMUs sowie komplexen Smart Data Algorithmen und Berechnungsumgebungen darstellen. Dies ermöglicht den schrittweisen Ausbau.

6.3.3 Adaption der Algorithmen

Für die Domäne der Verfahrenstechnik lag der Fokus der Ansätze des Projekts SIDAP auf einzelnen Geräten und der Korrelation von Prozesswerten zwischen diesen. In fertigungstechnischen Applikationen stehen dagegen ganze Anlagen, Anlagenteile und einzelne Maschinen im Vordergrund. Zusätzlich unterscheidet sich die Betrachtung des Produkts. Findet in der Verfahrenstechnik meist ein kontinuierlicher Prozess statt, wodurch das Produkt in Chargen zerlegt ist, wird in der Fertigungstechnik meist in Einzelstücken unterschieden. Prozesswerte benötigen damit immer einen Bezug zum Stück. Messwerte, welche zwischen zwei Einzelstücken aufgezeichnet werden, haben somit nicht direkt einen Einfluss und könnten die Auswertung verfälschen.

Die Ansätze aus SIDAP mussten somit für den Einsatz in der Fertigungstechnik evaluiert und angepasst werden. Dies umfasste insbesondere die Evaluation und Auswahl von im Gesamtprojekt betrachteten Algorithmen hinsichtlich der Anwendbarkeit in fertigungstechnischen Applikationen.

6.3.4 Schnittstellen für die Analyse

Für kleine und mittelständische Anlagenhersteller sollte die Möglichkeit geschaffen werden, Prozesswerte, welche Rückschlüsse auf den Ausfallgrund ihrer Anlagen zulassen, im eigenen Unternehmen auswerten und analysieren zu können. Die ausgelieferten Anlagen und Maschinen sind meist nahezu baugleich und die entwickelten Algorithmen lassen sich hierdurch sehr gut auf mehrere Anlagen und Maschinen anwenden. Damit steigt die Anzahl zur

Verfügung stehender Daten stark an, wodurch statistische Analysen zuverlässigere Ergebnisse liefern können. Die von den anderen Projektpartnern entwickelten und bereits existierenden Ansätze sollten skalierbar als Module in die Lösung des Projekts SIDAP-sMES eingebunden werden können. Diese Skalierung ist für KMUs entscheidend, da diese keine großen Software- und Architekturprojekte realisieren können.

Legato Sapient bietet als MES bereits die Möglichkeit Messwerte von Maschinen in der Cloud zu archivieren. Über die Lösung des modularen Softwarebaukastens (vgl. Abschnitt 6.3.2), und dessen Kopplungsmöglichkeit mit Legato Sapient, sollen Schnittstellen zu komplexeren Algorithmen geschaffen werden, sodass für die KMUs die Möglichkeit besteht das Gesamtsystem langsam auszubauen. Außerdem benötigen so die Unternehmen, durch die Kapselung der Algorithmen innerhalb der (Berechnungs-)Module nur geringeres Wissen über die Funktionsweise und Ausführung der Algorithmen.

6.4 Lösungen des Projekts SIDAP-sMES

Die folgenden Unterkapitel stellen Lösungsansätze und Konzepte für die im Projekt SIDAP-sMES gesetzten Zielstellungen vor. Dazu wird zunächst auf die Identifikation und Adaption eines Einstiegs- und Nutzungsleitfadens (vgl. Abschnitt 6.3.1) und auf den Standard "Cross Industry Standard Process for Data Mining (CRISP-DM)" eingegangen. Das anschließende Abschnitt 6.4.2 stellt den Prototypen eines modularen Data Mining Frameworks vor, der im Rahmen des Projekts bei GEFASOFT zur Begegnung der Herausforderungen eines modularen Softwarebaukastens (vgl. Abschnitt 6.3.2) mit entsprechenden Schnittstellen zur Skalierung und Adaption der eingesetzten Algorithmen-Auswahl (vgl. Abschnitt 6.3.3) und Schnittstellen für die Analyse (vgl. Abschnitt 6.3.4) entwickelt wurde.

6.4.1 Cross Industry Standard Process for Data Mining

Die hohe Komplexität des Themas Data Mining macht es notwendig, dass verständliche Standards für das Vorgehen und Handlungsleitfäden zur Verfügung gestellt werden. Das Vermeiden von wiederkehrenden Fehlern, das Befolgen definierter Schritte sowie das Dokumentieren des gesamten Prozesses sind Elemente, die einen Einstieg und ein tieferes Verständnis für Data Mining erleichtern.

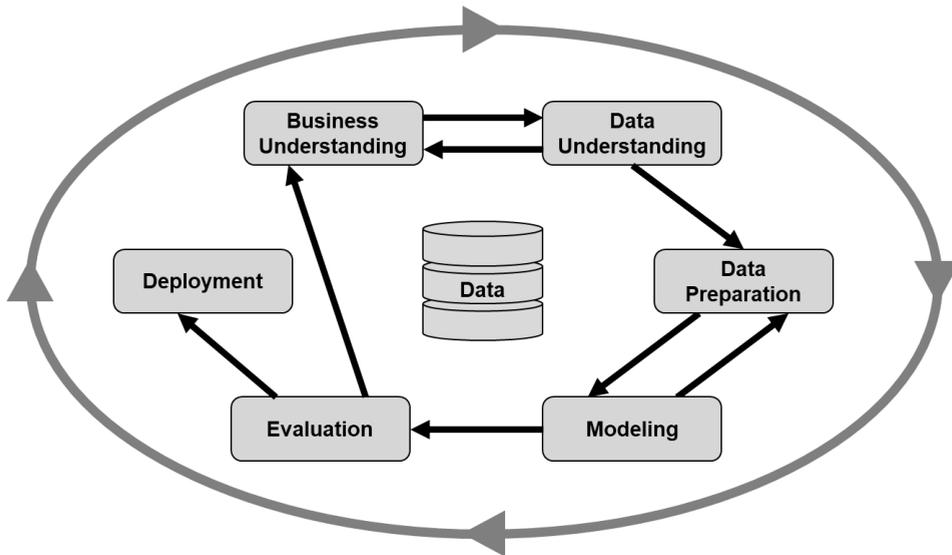


Abbildung 6.2: Cross Industry Standard Process for Data Mining (nach [PJ+00]).

Als Standard für die prozessorientierten Herangehensweisen für Data Mining, und als Ausgangsbasis für den Leitfaden, wurde im Rahmen des Projekts SIDAP-sMES der Standard "Cross-Industry Standard Process for Data Mining (CRISP-DM)" [PJ+00] herangezogen. Hauptargument für die Verwendung dieses Prozessmodells ist, dass es sich um eine der im industriellen Umfeld am weitesten verbreiteten Methoden handelt. In der Datenbank des MES eines kleinen oder mittleren Unternehmens können verschiedene Daten mit unterschiedlichen Informationsgehalten zur Verfügung stehen: von einfachen Prozesswerten, Meldungen und Stückzählern, bis hin zu (einfachen) aggregierten Werten und berechneten Key-Performance Indicators (KPI).

Das Vorgehensmodell nach CRISP-DM (vgl. Abbildung 6.2) startet mit den zwei iterativ ausgeführten Phasen des *Business Understanding* (Welche Fragestellungen sind für den Betrieb relevant zu untersuchen?) und des *Data Understanding* (Welche Datenbasis liegt für diesen Zweck vor / muss für diesen Zweck vorliegen?). Ein Ergebnis dieser beiden Phasen sind konkrete Zielstellungen (bzw. Hypothesen) der nachfolgenden Analyse, die auf den bestehenden oder noch zu erhebenden Daten untersucht werden können, bspw.:

- Wurde der Stromverbrauch in den letzten Wochen erhöht? Warum?
- Gibt es bei der Fertigung eines Produkttypen längere Stillstände?
- Wann wird die nächste Störung vorkommen?

Mithilfe der Phase des *Business Understanding* wird dabei sichergestellt, dass durch die Beantwortung dieser Fragen betrieblich relevante Maßnahmen abgeleitet werden können. Beispielsweise kann das Ergebnis der Analyse dazu führen, dass Wartungsarbeiten an einer Maschine besser entsprechend des gefertigten Produkttyps geplant werden. Da die betrieblich relevanten Fragestellungen nicht immer per se bewertbar sind (Datenqualität, Inkonsistenzen oder fehlende Werte können große Probleme darstellen), spielt auch der Schritt des *Data Understandings* an dieser Stelle eine wichtige Rolle.

In der anschließenden Phase der *Data Preparation* findet die Vorbereitung der zur Verfügung stehenden Daten auf der Grundlage der Informationen statt, die in der *Data Understanding* Phase gesammelt wurden. Ziel ist es dabei, die Daten für eine automatische Analyse mittels Data Mining Algorithmen zugreifbar zu machen (z.B. durch einen spezifizierten Zugriff auf die Datenbank eines MES) und aufzubereiten, d.h. die Rohdaten so zu überführen, dass sie nachfolgend automatisiert ausgewertet werden können. Wesentliche Teilschritte sind dabei die Auswahl der zu verwendenden Daten sowie die Erhöhung der Datenqualität, bspw. durch die Aussortierung fehlerhafter Datensätze, die direkt als Filter in den Zugriff auf die Datenbank eingebaut werden können.

Im Schritt des *Modeling* werden, basierend auf den Erkenntnissen aus den Schritten *Data Understanding* und *Data Preparation*, konkrete Data Mining-Algorithmen für die letztliche Analyse der Daten ausgewählt und konfiguriert. Mit der Ausführung der Algorithmen findet in diesem Schritt das eigentliche Data Mining statt. Um Struktur und Inhalt der Eingabedaten auf Gültigkeit und Konformität mit den selektierten Algorithmen zu überprüfen bzw. Inkonsistenzen frühzeitig zu erkennen, sowie bereits erste Teilergebnisse zu erhalten, werden zunächst sogenannte Testdesigns umgesetzt und beispielhaft durchgeführt. Sobald die Eingangsdaten, die Algorithmen und deren Parametrisierung positiv evaluiert und vollständig definiert sind, folgt abschließend die abschließende Analyse, in der eine vollständige Auswertung der Eingangsdaten durchgeführt wird.

Auf den Schritt des *Modeling* folgt im Schritt der *Evaluation* die Auswertung und Interpretation der Ergebnisse des Berechnungsprozesses. Darüber hinaus ist in diesem Schritt auch eine Überprüfung des generellen Data Mining Prozesses vorgesehen, in dem evaluiert und nachvollziehbar dokumentiert wird, unter welchen Randbedingungen und auf welche Art die Ergebnisse erzielt wurden. Als wesentliches Ergebnis dieses Schrittes ist eine Entscheidung

über das weitere Verfahren mit den dokumentierten Ergebnissen und Herangehensweisen.

Nach dem Schritt der *Evaluation* liegen die Ergebnisse des Data Mining Prozesses detailliert vor. Im anschließenden Schritt des *Deployment* müssen diese einem Zweck zugeführt werden. Dafür ist die Darstellung der Ergebnisse in einer für den Nutzer leicht verständlichen Form notwendig, bzw. die Rückführung der Ergebnisse in eine Schnittstelle für den Benutzer. Ein Beispiel, das im Konzept des Projekts SIDAP-sMES hierfür vorgeschlagen wird, ist bspw. die Darstellung von Berechnungsergebnissen in der Leitwarte der Maschinenüberwachung. Den Abschluss des Gesamtprojektes bildet das Verfassen eines Abschlussberichtes, in dem alle Prozessschritte, Ziele und Erkenntnisse nachvollziehbar dokumentiert werden.

6.4.2 Modulares Data Mining Framework

Das modulare Data Mining Framework, welches im Rahmen des Projekts SIDAP-sMES beim Projektpartner GEFASOFT entwickelt wurde, basiert, wie auch das MES-Produkt Legato Sapiens selbst, auf der Programmiersprache Java. Dadurch wird eine Integration der mittels des Frameworks konfigurierten Berechnungsalgorithmen in das MES konzeptionell ermöglicht. Entsprechend der Zielsetzung für den modularen Werkzeugbaukasten (vgl. Abschnitt 6.3.2), soll das Framework Möglichkeiten zu (Prozess-)Datenerfassung, Auswertung, Aufbereitung sowie die Visualisierung und Analyse der Ergebnisse bereitstellen.

Die entwickelte Lösung sieht für die (Prozess-)Datenerfassung den Zugriff auf die Datenbank (vgl. Abbildung 6.3, A) des MES vor. Hierfür wurden zum einen der Zugriff mittels anpassbarer SQL-Abfragen vorgesehen, wie auch zum anderen die Nutzung von REST-Webservices (vgl. Abbildung 6.3, B). Letztere Schnittstelle bietet auch das Back-End von Legato Sapiens, sodass ein Datenaustausch zwischen MES und Data Mining weiter vereinfacht wird.

Um möglichst flexibel verschiedene Berechnungen und Algorithmen zur Aufbereitung und Auswertung der Daten verwenden zu können, kapselt das Framework diese innerhalb von Berechnungsmodulen (vgl. Abbildung 6.3, C). Die Module fungieren dabei als Container, in denen unterschiedlichste Berechnungsalgorithmen ausgeführt werden können, und damit das Framework auch auf komplexere Algorithmen skaliert werden kann. Als erste Beispiele für prototypische Berechnungsmodulen wurden zunächst Algorithmen aus der freien WEKA-Umgebung (Waikato Environment for Knowledge Analysis) [HF+09], sowie aus der R-Umgebung [Tip14] umgesetzt.

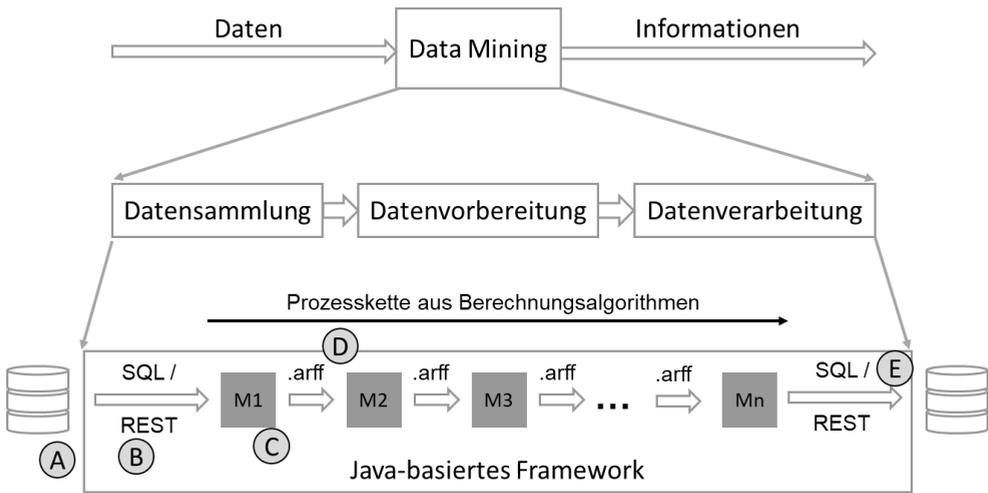


Abbildung 6.3: Architektur des modularen Frameworks.

Der Einsatz mächtiger kommerzieller Umgebungen und Bibliotheken für Berechnungsalgorithmen ist oft mit hohen Lizenzkosten verbunden, was deren Einsatz in kleinen und mittleren Unternehmen mit begrenzten finanziellen Ressourcen erschweren bzw. sogar unmöglich machen kann. Die beiden hier gewählten Umgebungen (R und WEKA) sind demgegenüber jedoch open-source und damit bestens für die Einbindung im Einsatz in kleinen und mittleren Unternehmen geeignet.

Die Weitergabe der Daten bzw. (Zwischen-)Ergebnisse der Berechnungsmodule wird das ebenfalls freie Datenaustauschformat "Attribute-Relation File Format (ARFF)" [HF+09] verwendet (vgl. Abbildung 6.3, D). Um die Ergebnisse der Kette von Berechnungsmodulen für den Bediener visualisieren zu können, sieht das Framework eine weitere Schnittstelle zum MES Legato Sapient vor (vgl. Abbildung 6.3, E). Diese basiert, wie die Schnittstelle für die Erfassung der Daten aus dem MES, eine Übertragung der Daten mittels SQL bzw. den REST-Webservices vor, die von Sapient bereitgestellt werden.

Für die Visualisierung der Ergebnisse einer derart gestalteten und an das MES Legato Sapient angebotenen Kette von Berechnungsalgorithmen, sieht das Konzept die Verwendung von verschiedenen grafischen Repräsentationen der Daten (wie bspw. Scatterplots, Bar-Charts, etc.) vor (vgl. Abbildung 6.4), die in der web-basierten Oberfläche dargestellt werden können.

Mit der ermöglichten Einbettung des prototypischen Data Mining Frameworks in Legato Sapiens konnte für kleine und mittlere Unternehmen ein einfacher und kostengünstiger Zugang zu Data Mining Methoden geschaffen werden. Das Framework beruht auf open-source Umgebungen und verursacht dadurch keinerlei Lizenzkosten. Dennoch lässt es das Konzept zu, dass auch komplexere, kommerzielle Algorithmen in das Framework eingebunden werden, wenn dies notwendig wird.

Um darüber hinaus die Parametrierung der Berechnungsketten weiter zu vereinfachen wurde für das Framework ebenfalls eine grafische Oberfläche implementiert (Abbildung 6.5). Dabei wurde als Hauptziel gesetzt, den Benutzer interaktiv zu unterstützen und die Notwendigkeit der Nutzung von Programmierumgebungen und –werkzeugen (wie bspw. Java oder R) zu vermeiden. Hierbei deckt das prototypische Tool die verschiedenen Phasen von CRISP-DM (vgl. Abschnitt 6.4.1) ab. Die entwickelte Oberfläche erfüllt die wichtigsten Anforderungen des Benutzers und versucht den Data Mining Prozess zu vereinfachen, insbesondere bei der Vorbereitung der Daten (*Data Preparation*) und der Modellierung (*Modeling*). Dafür wurden zwei verschiedene Rollen als Nutzer des Tools berücksichtigt: der Data Mining End-User des Tools, der – ohne Programmierkenntnisse – Daten untersuchen möchte und die Ergebnisse analysieren (bzw. die Berechnungsketten für die Ausführung und Visualisierung im MES parametrieren möchte), und der Entwickler, der neue Berechnungsmodule programmieren kann.

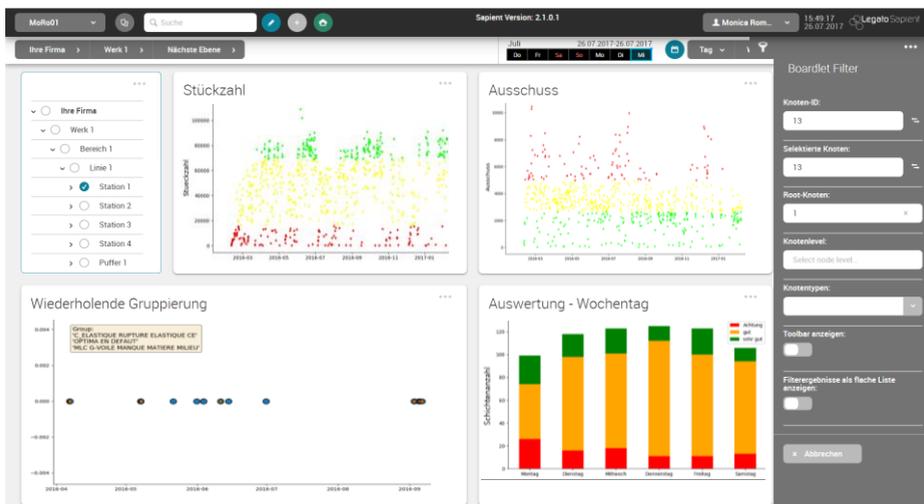
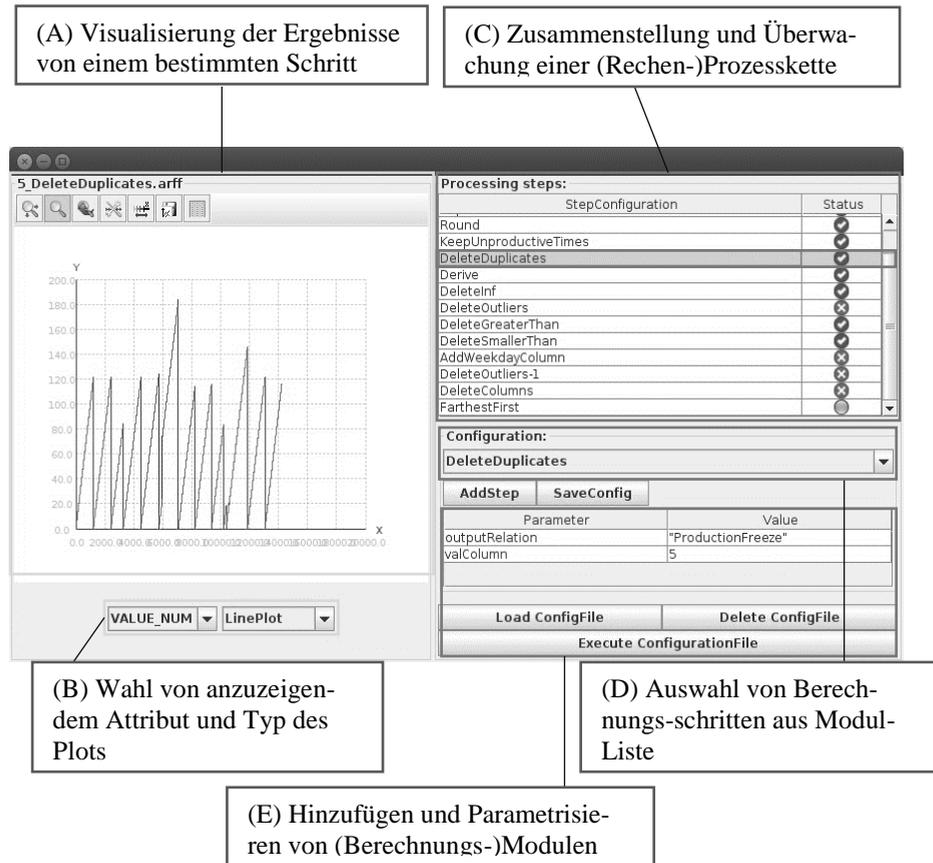


Abbildung 6.4: Beispiel für die Visualisierung von Berechnungsergebnissen.



(A) Visualisierung der Ergebnisse von einem bestimmten Schritt

(C) Zusammenstellung und Überwachung einer (Rechen-)Prozesskette

(B) Wahl von anzuzeigendem Attribut und Typ des Plots

(D) Auswahl von Berechnungs-schritten aus Modul-Liste

(E) Hinzufügen und Parametrisieren von (Berechnungs-)Modulen

Abbildung 6.5: Grafische Oberfläche des Data Mining Frameworks.

Die prototypisch entwickelte Oberfläche bietet die Möglichkeit, die Ketten der Berechnungsmodule, die durch das Framework ausgeführt werden (vgl. Abbildung 6.3, C), mittels eines grafischen Benutzerinterfaces (vgl. Abbildung 6.5, C) hinzuzufügen, zu parametrisieren und in die gewünschte Reihenfolge zu bringen. Die Parametrisierung eines Moduls funktioniert dabei über eine Formularmaske (vgl. Abbildung 6.5, E), die bei Auswahl des Moduls in der Berechnungskette angezeigt wird.

Die Konfigurationen der Module kann gespeichert bzw. geladen werden, um spätere, notwendig gewordene Anpassungen oder Erweiterungen vorzunehmen. Nach der Erstellung einer Berechnungskette und der Festlegung der Parametrisierung kann, mithilfe des hinter liegenden Java-basierten Frameworks, die Berechnungskette ausgeführt werden. Als wichtiger Punkt wurde hier berücksichtigt mit dem Satus der Module (vgl. Abbildung 6.5, C) eine

visuelle Information über die Durchführung der Berechnungskette anzubieten: Welche Module sind schon erfolgreich durchgeführt? Welche hatten Fehler und welche sind noch durchzuführen?

Als zusätzliche unterstützende Funktionalität für den Entwickler von Berechnungsketten (Data Mining End-User) wurde auch eine grafische Schnittstelle zur Visualisierung der Berechnungs(-zwischen-)ergebnisse in die grafische Oberfläche integriert. So können verschiedene Arten von Plots und Darstellungen von Einzelergebnissen (bspw. Line-Chart oder Bar-Chart) ausgewählt werden (vgl. Abbildung 6.5, B). Mit dieser Visualisierung können bei der Entwicklung einer Berechnungskette (Phase des Modeling von CRISP-DM) einzelne Module vorab getestet werden

6.5 Zusammenfassung und Ausblick

Die Anwendung moderner Data Mining Technologien bietet ein hohes Potenzial für die Verbesserung der Effizienz der Produktion in industriellen Unternehmen. Dennoch ist zwar das gezielte Aufnehmen von Daten und die Bestimmung von einfachen Produktionskennzahlen, bspw. unter Verwendung moderner Manufacturing Execution Systeme (MES), bereits weit verbreitet, darüber hinaus findet jedoch keine regelmäßige Anwendung komplexerer Data Mining Methoden statt. Insbesondere in kleinen und mittleren Unternehmen (KMUs) fehlen dazu häufig die finanziellen und organisatorischen Mittel, die nötig wären, um Data Mining Systeme erfolgreich zu integrieren.

Im Forschungsprojekt SIDAP-sMES wurden daher im Rahmen des übergeordneten Projekts "Skalierbares Integrationskonzept zur Datenaggregation, -analyse und -aufbereitung von großen Datenmengen in der Prozessindustrie (SIDAP)" Konzepte aus dem Bereich Big Data und Smart Data hinsichtlich einer kostengünstigen und aufwandsarmen Integration in KMU aus der Fertigungstechnik untersucht und prototypisch entwickelt.

So wurde mit CRISP-DM zunächst ein geeignetes Prozessmodell als Leitfaden für die Einführung und den Einsatz von Data Mining identifiziert. Darüber hinaus wurde ein modulares Data Mining Framework prototypisch implementiert, das die Phasen und das Vorgehen dieses Leitfadens unterstützt.

Das Framework basiert auf open-source Umgebungen und Bibliotheken zur Ausführung von Data Mining Algorithmen, wodurch keine hohen Lizenzkosten wie bei kommerziellen Umgebungen entstehen. Für die einfache Paramet-

rierung von durchzuführenden Algorithmen besitzt das Werkzeug eine grafische Oberfläche und eine Einbindung der Ausführung der resultierenden Berechnungen in das MES Legato Sapient ist durch das Konzept gegeben.

6.6 Danksagung

Die Autoren bedanken sich beim Bundesministerium für Wirtschaft und Energie für die Förderung des Projektes „Skalierbares Integrationskonzept zur Datenaggregation, -analyse und –aufbereitung von großen Datenmengen in der Prozessindustrie (SIDAP, Förderkennzeichen 01MD15009C)“, in dessen Rahmen die hier vorgestellten Arbeiten entstanden sind.

Literatur

- [HF+09] M. Hall, E. Frank, G. Holmes, B. Pfahringer, P. Reutemann, I. Witten: “The WEKA data mining software: an update,” ACM SIGKDD Explorations Newsletter, Vol. 11, Nr. 1, S. 10-18, 2009.
- [PJ+00] C. Pete, C. Julian, K. Randy, K. Thomas, R. Thomas, S. Colin, R. Wirth, “CRISP-DM 1.0”. Cris. Consort., 2000.
- [Tip14] S. Tippmann. “Programming tools: Adventures with R. A guide to the popular, free statistics and visualization software that gives scientists control of their own data analysis,” Nature, Vol. 517, Nr. 1, S. 109-110, 2014.

7 ThingWorx – Plattform zur Integration herausfordernder Anforderungen auf dem Shopfloor

Dr.-Ing. A. Gallasch
Software Factory GmbH
gallasch@sf.com

7.1 Herausfordernde Anforderungen an IT Lösungen in der Operational Technology

Neue IT-technische Ansätze eröffnen neue Geschäftsmodelle und Potentiale zur Serviceverbesserung und Kostenreduktion. Industrie 4.0 ist dazu die Umsetzung in der produzierenden Industrie. Kern ist der schnelle und agile Aufbau von Regelkreisen. Die Basis ist die leichte und schnelle Nutzung von Daten. Die angewendeten Methoden sind moderne Verfahren der IT, die heute auf Grund von niedrigen Speicherpreisen und exponentiell gestiegener Rechenleistung für viele Unternehmen anwendbar sind. In der Produktion ist somit mehr und mehr der Einsatz dieser modernen Methoden gefragt.

Die Operational Technology (OT) ist zunehmend gefordert Daten und Informationen in der Welt der klassischen IT zur Analyse und Regelkreisbildung zur Verfügung zu stellen [AK+12]. Sie war bisher auf Produktions- und Industrieanlagen konzentriert, um in erster Linie die Verfügbarkeit der Anlagen zu gewährleisten. Diese waren meist geschlossene Systeme, ohne Anbindung an das Internet. Das gesamte Spektrum an Technologien zur Datenverarbeitung, wie Software, Hardware, Kommunikationstechnologien und damit verbundene Services, und das Thema Cyber-Security waren bisher in der IT angesiedelt. Dort ist auch weit mehr Erfahrung mit dem Internet und der Cloud vorhanden.

Dieser Beitrag beschreibt, wie der Einsatz der durchgängigen Innovationsplattform ThingWorx die Umsetzung moderner Verfahren der IT sicherer und schneller, auch bei begrenzter Kapazität, ermöglicht. Dies erlaubt es der OT die Methoden der IT schneller und sicherer anzuwenden. Es wird auf den Zugriff, die Vorverarbeitung und den Transport der Daten eingegangen. Des Weiteren wird die agile Applikationsentwicklung betrachtet und der Einsatz von künstlicher Intelligenz und Augmented Reality beleuchtet.

7.2 Konnektivität

Die OT ist mit einer sehr heterogenen Automatisierungs- und Applikationsinfrastruktur konfrontiert. Das bedeutet, dass heute viele Punkt-zu-Punkt Datenzugriffe individuell und mit hohem Engineering-Aufwand umgesetzt werden müssen (siehe Abbildung 7.1), um über die bestehende Automatisierung hinaus Anwendungen zu schaffen.

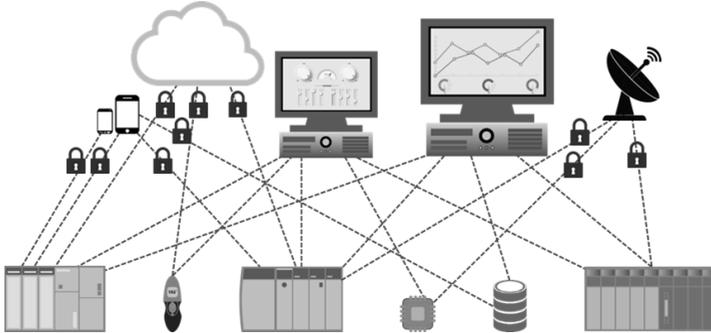


Abbildung 7.1: Notwendige Verbindungen in der Produktion (Quelle: PTC).

Der Einsatz des ThingWorx-Moduls für industrielle Kommunikation, *Kepware* [Ke20], ermöglicht die Erfassung, Aggregation und den sicheren Zugriff auf industrielle Betriebsdaten. Das Plattformdesign ermöglicht die Anbindung, Verwaltung, Überwachung und Steuerung unterschiedlicher Automatisierungsgeräte und Softwareanwendungen – von der Anlagensteuerung bis hin zu Unternehmensinformationssystemen (siehe Abbildung 7.2).

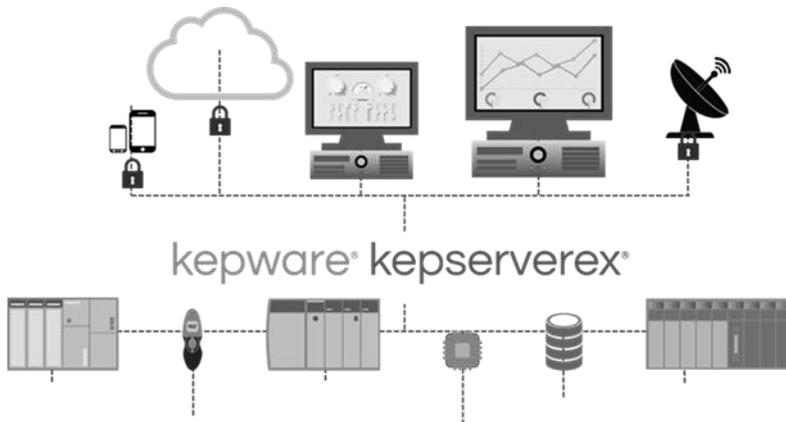


Abbildung 7.2: Kepware als zentraler Zugriffspunkt für Daten (Quelle: PTC).

Kepware bietet eine Bibliothek mit mehr als 150 Gerätetreibern, Client-Treibern und erweiterten Plug-Ins für die Anbindung an. Dies beinhaltet proprietäre Protokolle von Hardwareanbietern wie Siemens, Allen-Bradley, GE, Omron und Schneider. Auch Brancheninitiativen wie MTConnect, DNP3, IEC 61850/60870 und BACnet werden unterstützt. Darüber hinaus bietet es Zugriff auf Client-Anwendungen wie ERP, MES, HMI und SCADA über OPC und proprietäre Protokolle sowie auf neue Arten von IoT-Visualisierungs- und Analyseprodukte, einschließlich MQTT, REST, ODBC und SNMP oder AlwaysOn. Kepware ist von der OPC Foundation als OPC-konformer OPC/UA-Server zertifiziert.

Kepware bietet Erweiterungen zur Vorverarbeitung von Daten an. Um beispielsweise SPS-Daten zur Analyse in ODBC-konforme Datenbanken einzulesen, wird ein Modul *DataLogger* genutzt. Zur Durchführung von Berechnungen bzw. zum Aufbau von sog. Smart Sensors wird *AdvancedTags* verwendet. Auch können Ereignisse und Alarmer definiert und überwacht werden. Die Nutzung von *LocalHistorian* verschiebt Datenerfassung, -speicherung und -zugriff näher an die Datenquelle und verringert die Abhängigkeit von der Netzwerkverbindung und vermeidet so Datenverluste. Das *IoT-Gateway* überträgt industrielle Steuerungsdaten in Echtzeit in IT- oder IoT-Anwendungen für Business Intelligence und Operational Excellence Auswertungen. Ein Scheduler verschiebt die Planung von Datenanfragen vom Client zum Server, um die Gerätekommunikation über Netzwerke mit begrenzter Bandbreite zu optimieren. Der *SNMP-Agent* ermöglicht die Kommunikation der meisten Netzwerkmanagementsysteme (NMS) mit Automatisierungsgeräten und -systemen.

7.3 Agile Applikationsentwicklung

Stehen die Daten bzw. die Datenströme durch den Einsatz von Kepware bereit, müssen schnell, agil und dennoch sicher Visualisierungs- und Regelkreisapplikationen entwickelt werden. In der OT ist heute oft nicht die notwendige Kapazität an Softwareentwicklern vorhanden. Eine modellbasierte Applikationsentwicklung vereinfacht die Entwicklung und den Umgang mit Digitalen Zwillingen.

ThingWorx [PTC18] bietet ein Meta-Modell zur Bereitstellung einer einfachen semantischen Schicht in natürlicher Sprache auf Daten, die in Thing-

Worx und anderen Systemen gespeichert sind. Es bietet eine konsistente Darstellung für die zu erstellenden Anwendungen wie OEE- oder Analytics-Auswertung (siehe auch Abschnitt 7.4) (siehe Abbildung 7.3)

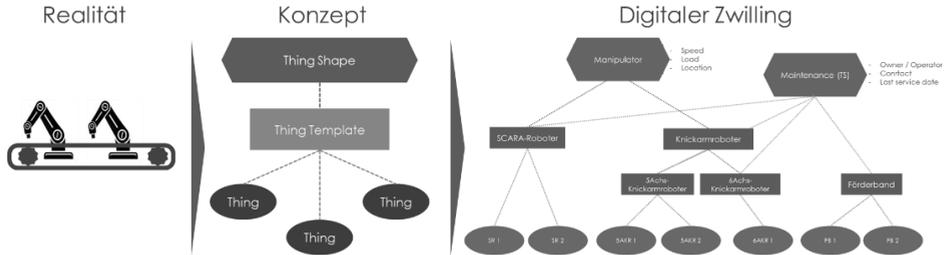


Abbildung 7.3: Das Thing-Konzept zum Aufbau Digitaler Zwillinge.

Diese Anwendungen können durch Modellierung entwickelt werden. Die Modellierung geschieht in einer sogenannten Anwendungs-Enablement-Plattform (AEP). Diese ist eine Design- und Runtime-Umgebung für IoT-Anwendungen, die die Erstellung von Anwendungen und die bidirektionale Konnektivität zu "Dingen" erlaubt. Dabei wird das *ThingModel* erstellt. Es ist eine digitale Entität (Digitaler Zwilling), die eine physische Anlage, eine Person, ein Organisationselement oder einen Arbeitsvorgang repräsentiert. Ein Thing ist über Properties, Services, Events und Subscriptions gekennzeichnet (siehe Abbildung 7.4). Ein Thing wird über ein *ThingTemplate* instanziiert, das mit Hilfe von *ThingShapes* definiert wird. Als Oberfläche zur Modellierung dient der Composer.

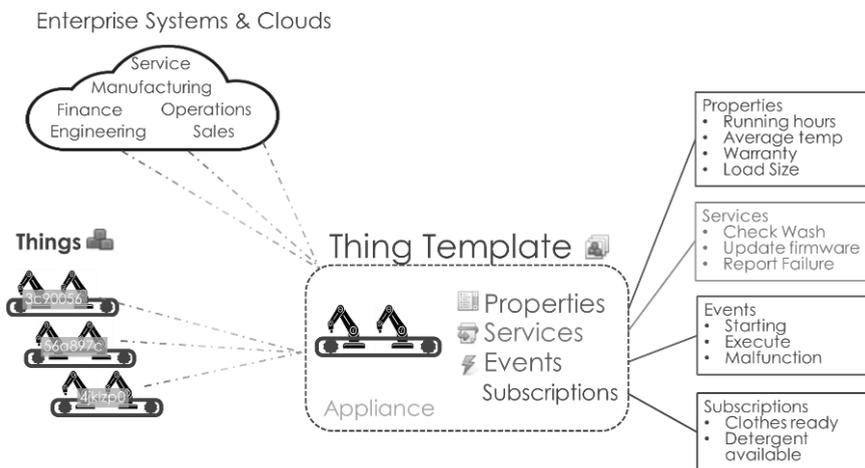


Abbildung 7.4: Das Thing als Repräsentant der Realität.

Die Entwicklung der eigentlichen Applikationen basierend auf den Digitalen Zwillingen geschieht im Mashup-Builder. Er ermöglicht es nicht nur Entwicklern, sondern auch Fachanwendern aus der OT über eine Drag-and-Drop-Lösung interaktive Anwendungen, Dashboards, kollaborative Workspaces und mobile Schnittstellen ohne programmieren zu müssen zu erstellen. Dabei wird automatisch eine REST-API für den Zugriff auf das Modell generiert, so dass auch aus der IT auf den Digitalen Zwilling zugegriffen werden kann.

7.4 Künstliche Intelligenz

Vom Einsatz von Künstlicher Intelligenz verspricht man sich in der Produktion insbesondere in den Bereichen viel, in denen es noch keine expliziten Prozessmodelle gibt. Dies ist der Fall, wenn die Daten in der Produktion bezüglich Volumen, Geschwindigkeit und Vielzahl eine Herausforderung darstellen [Ga16]. Die Zusammenhänge der Daten sind dann nicht immer klar ersichtlich und eine Modellbildung ist aufwändig. Der Einsatz von Statistischen Methoden und Methoden der Künstlichen Intelligenz versprechen hier Erfolg. In die ThingWorx Plattform ist dazu ThingWorx Analytics eingebettet. Es automatisiert komplexe Analyseprozesse, da in Fachbereichen wie der OT selten Kapazität in Form von Data Scientists oder Programmierern mit Know-how im Bereich statistischer Algorithmen bereitsteht (siehe Abbildung 7.5).

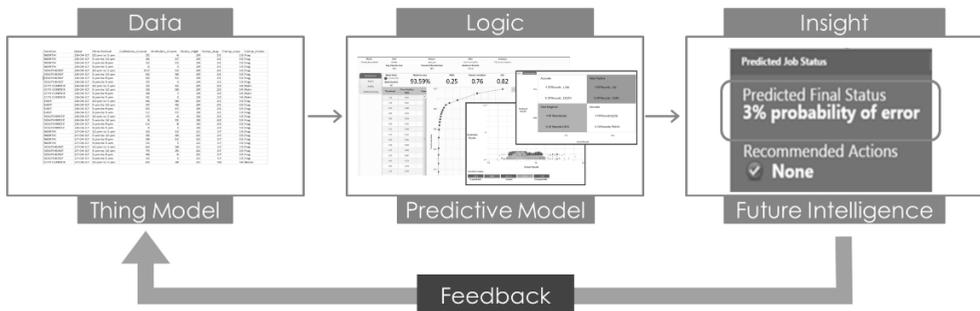


Abbildung 7.5: Bildung von Aussagen über generierte Modelle.

So nutzt ThingWorx Analytics Server eine Vielzahl von bewährten Methoden der Statistik und der Künstlichen Intelligenz, um in Form eines Maschinellen Lernens Modelle bzgl. der Abhängigkeit von Daten zu erstellen, zu operationalisieren und zu pflegen.

Wenn der ThingWorx Analytics Server mit dem *ThingModel* verbunden ist oder Daten hochgeladen werden, wird der Datensatz in zwei Teile zerlegt;

einen Trainingsdatensatz (normalerweise 80% des Datensatzes) und einen Validierungsdatensatz (normalerweise 20% des Datensatzes) (siehe Abbildung 7.6).

Der Server beginnt dann, von einem Ergebnis zu lernen, das er innerhalb des Datensatzes kennzeichnet – es wird ein sogenannter "supervised machine learning"-Ansatz angewendet. Es werden mehrere 1.000 prädiktive und/oder simulative Modelle parallel erstellt und ständig mit dem Validierungssatz verglichen, der aus dem ursprünglichen Datensatz zurückgehalten wurde. Um das Modell zu testen, versucht die KI-Technologie aufgetretene Daten richtig gewichtet vorherzusagen. Ist ein valides Modell identifiziert, wird es weiter optimiert. Dabei ist ThingWorx Analytics Server keine Blackbox. Es beschreibt die Erstellung des Modells, die Bewertungen gegen den Validierungssatz und die Fehlerraten für die von ihm erstellten Modelle (siehe Abbildung 7.7). Das Modell, das mit dem beschriebenen Vorgehen am besten abschneidet, ist dann bereit für die Produktion und über REST-APIs oder ThingWorx und den Mash-Up-Builder zugänglich.

Eine noch einfachere Nutzung von Maschinellern Lernen erlaubt ThingWorx direkt im Mashup-Builder ohne den Einsatz des Analytics Servers. Eine automatisierte Anomalie-Erkennung kann zur Überwachung von Datenströmen im Mashup-Builder eingeschaltet werden. Dabei erkennen die bereits erwähnten Algorithmen automatisch Anomalien im Verlauf von Datenwerten (siehe Abbildung 7.8).

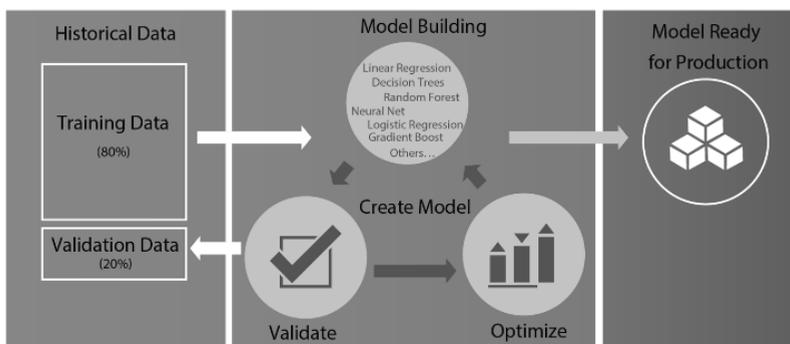


Abbildung 7.6: Ablauf der automatisierten Modellbildung.



Abbildung 7.7: Fehlerraten eines validierten Prozessmodells einer Werkzeugmaschine

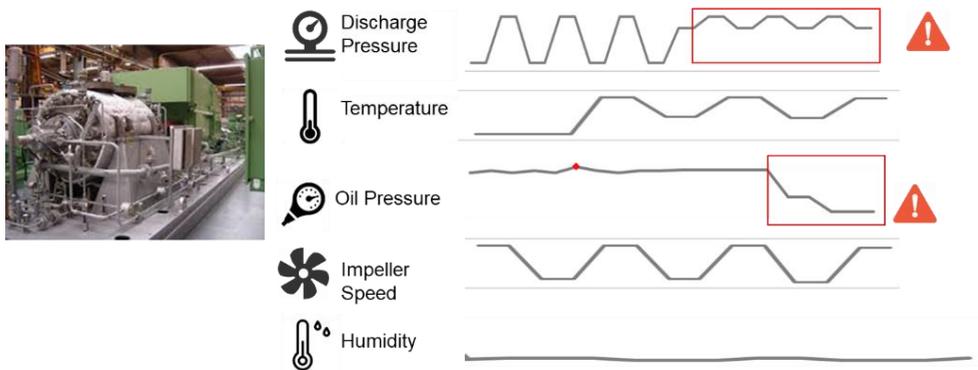


Abbildung 7.8: Erkennung von Anomalien in Datenströmen.

7.5 Augmented Reality

Augmented Reality (AR) wird zum Bilden von Regelkreisen mit menschlicher Unterstützung immer wichtiger, da es Verständnis und Zuordnung von Daten unterstützt. Bisher mussten anspruchsvollere AR-Anwendungen programmiert werden oder waren nur auf proprietären Geräten, wie der Hololens von Microsoft, verfügbar. Über ThingWorx zusammen mit Vuforia Studio kann schnell eine AR-Anwendung gebaut werden [St16]. Grundlage ist wieder das Thing-Model, das im Studio mit AR-Elementen verknüpft wird. Damit können die Digitalen Zwillinge sehr einfach um AR-Komponenten ergänzt werden. Zudem ermöglicht es Vuforia Studio, bestehende 3D-Objekte sowohl aus PTC Creo als auch aus anderen gängigen 3D-Modellierungswerkzeugen zu verwenden und den Digitalen Zwilling mit geometrischer Information noch plakativer zu machen (siehe Abbildung 7.9).

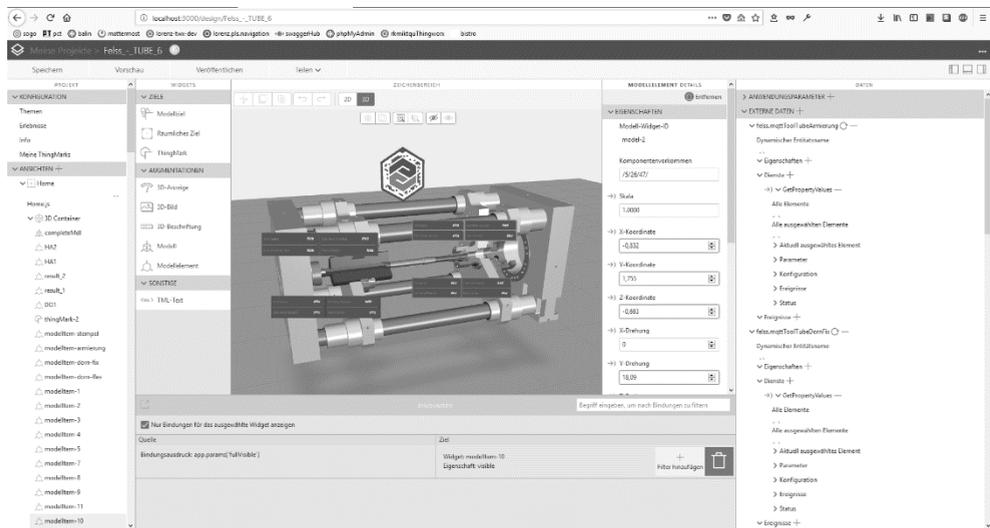


Abbildung 7.9: Bau einer AR-Experience in Vuforia Studio.

Weiterhin erlaubt es die Entwicklungsumgebung, Daten mit Animationen und Sequenzen zu kombinieren. Objekte und Produkte werden mit einer individuellen ThingMark versehen, über die sie später eindeutig erkannt werden können. Auch der Zugriff auf die AR-Anwendung (AR-Experience) erfolgt ohne Programmierung über die generische mobile App Vuforia View Enterprise. Sie ist eine einzelne Applikation, die die ThingMarks einscann und den Nutzer auffordert, das zugeordnete Erlebnis auszuwählen. Im Anschluss wird dieses heruntergeladen und gestartet (siehe Abbildung 7.10)

Komponenten zum maschinellen Lernen, die vom Fachanwender einfach, sicher und iterativ eingesetzt werden können. Und schließlich bietet die Augmented Reality Komponente Vuforia eine neue Art auf Informationen zuzugreifen. Die Verbindung von allen „Things“ zu anderen Systemen erlaubt es weitere Lösungen schnell und einfach aufzubauen.

Literatur

- [AK+12] A. Chemudupati, S. Kaulen, M. Mertens, S.M. Mohan, P. Reynaud, F. Robin, S. Zimmermann: The convergence of IT and Operational Technology. White Paper. Atos. 2012.
- [Ga16] A. Gallasch: 1Big Data smart nutzen – Strategien und Lösungen mit der IoT Plattform ThingWorx. In: Vogel-Heuser, B. (Hrsg.): Automation Symposium 2016: Analyse, Integration und Visualisierung großer Datenmengen, Sierke Verlag, Deutschland, 2016.
- [Ke20] Kepware: Industrielle Konnektivität. In www.kepware.com. URL: <https://www.kepware.com/de-de/> (Stand: 08.08.2018).
- [PTC18] PTC: Modeling: Why do I have ThingShapes and ThingTemplates? In: Welcome to ThingWorx. URL: https://support.ptc.com/cs/help/thingworx_hc/thingworx_7.0_hc/index.jsp?id=ThingShapes&action=show (Stand: 08.08.2018)
- [St16] R. Steck: PTC stellt Vuforia Studio vor: AR ohne Programmieren (2016). In: www.EngineeringSpot.de. URL: <https://www.engineering-spot.de/2016/07/ptc-stellt-vuforia-studio-vor-ar-ohne-programmieren/> (Stand: 08.08.2018).

8 Das SIDAP-Cloud-Konzept für Smart Data-Anwendungen in der Prozessindustrie

P. Schleinitz

IBM Deutschland GmbH, Erfurt

jens-peter.schleinitz@de.ibm.com

Dr. M. Steffen

Bayer AG, Leverkusen

dr.matthias.steffen@bayer.com

8.1 Einleitung

Um international wettbewerbsfähig zu bleiben, suchen Unternehmen der Branchen Chemie, Petroleum, Maschinen- und Anlagenbau nach Möglichkeiten, effizienter und profitabler zu werden. Die Integration und Aggregation von Daten und das Cloud-Computing versprechen bislang noch nicht gehobene Potenziale der Effizienzsteigerung, aber auch die Möglichkeit neue Geschäftsmodelle entwickeln.

Eine systematische Erhebung von Anforderungen und die Evaluierung von Analyse- und Aggregationsmethoden für die Prozessindustrie ist bislang nicht ausreichend erfolgt. Auch fehlen Standards zur IT-Systemarchitektur und zur Integration von IT-Systemen über Unternehmensgrenzen hinweg. Die Einbindung von klein- und mittelständische Unternehmen (KMU) ist nicht adäquat möglich, wobei gerade der Austausch zwischen Betreibern und Komponentenzulieferern hohe Effizienzpotenziale für den Gesamtprozess verspricht. Somit erfolgt die Datenanalyse in der Regel in Datensilos mit isolierten Tools und Verfahren, wodurch die Wirksamkeit der Ergebnisse relativ begrenzt ist. Daten werden oft nicht im passenden Kontext gewonnen, sind unvollständig, fehlerhaft und benötigen einen hohen Aufbereitungsaufwand zur weiteren Analyse. Unterschiedliche Abtastrate, Datenformate, Anlagentypen und Einbausituationen erschweren die Datenzusammenführung und -nutzung weiter. Eine weitergehende effiziente und unternehmensübergreifende Zusammenarbeit beispielsweise zwischen einem Betreiber und Komponentenanbieter ist somit heute kaum möglich. Genau hier setzt das SIDAP-Projekt an und hat die Erforschung von unternehmensübergreifenden Tools und Verfahren zum Ziel. Dabei wurden Daten in einer Private Cloud-Umgebung der TU München analysiert. Außerdem wurde auf Basis der im

SIDAP¹⁴- und anderen Projekten gesammelten Erfahrungen dieses Cloud-Konzept erstellt, das folgende Themen näher behandelt:

- Eine Einführung in das Thema Cloud und seine Vorteile
- Das eigentliche Cloud-Konzept
- Eine einleitende Betrachtung, was bei der Realisierung des Konzepts zu beachten ist

8.2 Der Nutzen der Cloud

Unternehmen werden mit immer dynamischeren Märkten konfrontiert, in denen technische Neuerungen insbesondere von kurzen Innovationszyklen geprägt werden. Aus den derzeitigen Cloud-Computing-Angeboten ergeben sich für Unternehmen aus prozessintensiven Branchen vielerlei Chancen. Einer der Hauptargumente für einen Umstieg auf Cloud-Computing liegt im Potential der Flexibilitätssteigerung zu überschaubaren Kosten. Mit Hilfe von Cloud-Diensten wie z.B. Natural Language Processing oder Machine Learning lassen sich aus Unternehmenssicht neue Anwendungen schneller entwickeln.

Je nach Ausgangssituation und Präferenzen können Unternehmen aus unterschiedlichen Cloud-Varianten eine geeignete Cloud-Infrastruktur wählen, um weitere Potentiale des Cloud-Computings auszuschöpfen. Dabei lassen sich Cloud-Umgebungen nach bestimmten Merkmalen klassifizieren, die für die Auswahl der geeigneten Cloud-Variante relevant sind. Merkmale sind z.B. das Servicemodell einer Cloud-Lösung (siehe XaaS in Abschnitt 8.6 Definitionen), deren Lokation (Off-Premise, On-Premise) und die Ressourcenzuteilung der Cloud. Diese können einem Unternehmen exklusiv zur Verfügung stehen oder mit anderen Unternehmen geteilt werden. Weiterhin ist zu beachten, dass die Übertragung von großen Datenmengen in eine Off-Premise Cloud-Umgebung nicht immer sinnvoll ist. Neben der technischen Betrachtung erfordert die Einführung von Cloud-Lösungen Analysen des geschäftlichen Nutzens und der rechtlichen Rahmenbedingungen.

8.3 SIDAP Cloud-Konzept

Vor diesem Hintergrund wurde für die unternehmensübergreifende Zusammenarbeit bei SIDAP ein Cloud-Konzept entwickelt, das insbesondere KMUs

¹⁴ Skalierbares Integrationskonzept zur Datenaggregation, -analyse, -aufbereitung von großen Datenmengen in der Prozessindustrie; <http://www.sidap.de>, aufgerufen am 18.07.2018.

den Einstieg in Smart-Data-Lösungen erleichtern soll. Der Fokus lag dabei auf der Analyse der Daten mit möglichst minimalem Aufwand (basierend auf einer VMware-Instanz/IaaS im RZ der TU München). In einer produktiven Umgebung kommen andere Anforderungen hinzu, weshalb andere Produkte ebenfalls eingesetzt werden können (PaaS).

Smart Data ist definiert aus der Summe von Big Data, Nutzen, Semantik, Datenqualität, Sicherheit und Datenschutz, oder kurz nutzbringende, hochwertige und abgesicherte Daten. Mit dem Technologieprogramm "Smart Data - Innovationen aus Daten" fördert das Bundesministerium für Wirtschaft und Energie (BMWi) 13 ausgewählte Leuchtturmprojekte, die innovative Dienste und Dienstleistungen entwickeln. Ziel ist es, den zukünftigen Markt für Smart Data-Technologien am Standort Deutschland zu erschließen. Von diesen Technologien sollen aufgrund der einfachen Handhabbarkeit - insbesondere bei Datensicherheit und Datenqualität - vor allem kleine und mittelständische Unternehmen (KMU) profitieren. Dabei werden Anbieter und Anwender gleichermaßen angesprochen: Sie sollen dazu beitragen, technische, strukturelle, organisatorische und rechtliche Hemmnisse beim Einsatz von Smart Data-Technologien aus dem Weg zu räumen. Zum Smart Data-Programm gehört auch das SIDAP-Projekt „Skalierbares Integrationskonzept zur Datenaggregation, -analyse, -aufbereitung von großen Datenmengen in der Prozessindustrie“. Im Projekt wurden unternehmensübergreifende, sichere und skalierbare Daten-Integrationsarchitekturen zur Datenaggregation und zur Unterstützung der Entscheidungsfindung im Betrieb entworfen.

8.3.1 Anforderungen

Im Rahmen des SIDAP-Projektes wurden eine Reihe von Anwendungsfällen diskutiert, insbesondere unter den Gesichtspunkten der Geschäftsrelevanz und der Machbarkeit der Datenbeschaffung. Da sich die Bereitstellung von Daten als kritisch herausstellte, wurde z.B. auf die Echtzeitdatenverarbeitung verzichtet. Typische Anwendungsfälle sind:

- Datenvorbereitung für die vorrausschauende Wartung
- Erkennung von Anomalien
- Änderung von Anlagenobjekten
- Inspektion und Wartung
- Integration von Algorithmen
- Integration von Daten (ERP, MES, SCADA, Daten-Historian)

In einem zukünftigen Implementierungsprojekt müssen die notwendigen Anwendungsfälle ermittelt werden. Durch die modulare Konzeption der Architektur kann dies zu einem späteren Zeitpunkt erfolgen, siehe auch [WM].

Nicht-funktionale Anforderungen, wie z.B. Skalierbarkeit, spielen vorwiegend für den produktiven Einsatz eine Rolle und müssen im jeweiligen Projekt bewertet werden. Sie können z.T. erhebliche Auswirkung auf die physische Architektur (verwendete Produkte, Netzwerk usw.) haben. In diesem Sinn kann das hier vorgestellte Cloud-Konzept nur eine erste Annäherung sein. Die Autoren sind jedoch davon ausgegangen, dass insbesondere die Bereitstellung von Erkenntnissen nicht zeitkritisch ist und somit nur geringe Verfügbarkeits-Anforderungen an die SIDAP-Cloud-Umgebung (siehe Abschnitt 8.3.2 Technische Lösung) bestehen - im Gegensatz zur Umgebung Betreiber/Produktion, in der die Erkenntnisse im laufenden Prozess verwendet werden. Durch diesen Ansatz sollen die Kosten minimiert werden.

Während funktionale Anforderungen je nach Projekt unterschiedlich geordnet werden, gibt es für nicht-funktionale Anforderungen typische Gliederungen. Nicht-funktionale Anforderungen können dabei in zwei Hauptkategorien unterteilt werden:

1. **Ausführungsqualität.** Dies ist während des Betriebs (zur Laufzeit) beobachtbar und beinhaltet Zuverlässigkeit, Aussehen und Handhabung, Benutzbarkeit, Leistung und Effizienz, Sicherheitsanforderungen und Korrektheit.
2. **Weiterentwicklungsqualität / Evolutionsqualität.** Dies ist in der statischen Struktur des Systems verkörpert und beinhaltet Betrieb und Umgebungsbedingungen, Wartbarkeit/Änderbarkeit, Portierbarkeit und Übertragbarkeit, Flexibilität/Unterstützung von Standards, Skalierbarkeit und Randbedingungen.

8.3.2 Technische Lösung

Abbildung 8.1 stellt die Teilumgebungen dar (nicht betrachtet wurden Umgebungen für Test und Entwicklung). Neben der eigentlichen SIDAP-Cloud gibt es beim Betreiber der Anlagen bereits weitere zwei Ziel-Umgebungen, die maßgeblich betroffen sind: Produktion und Exploration.

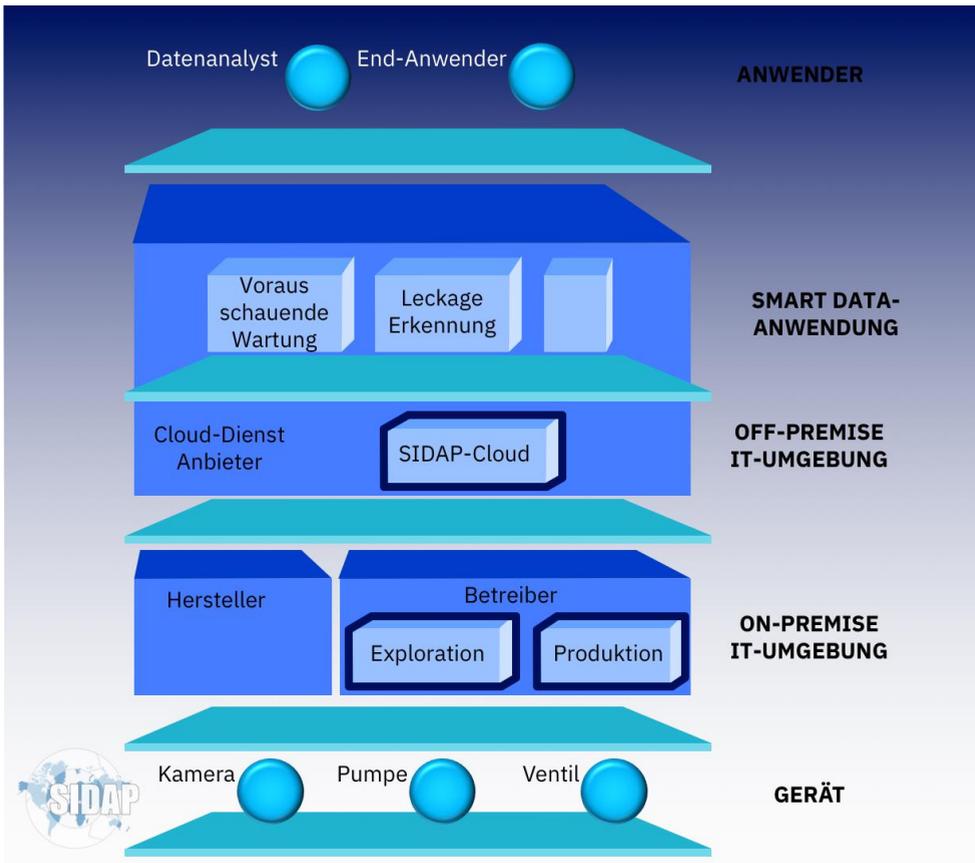


Abbildung 8.1: Ebenen und Ziel-Umgebungen der SIDAP-Architektur.

Die Detail-Architektur kann durch Architektursichten beschrieben werden (Information, Infrastruktur, Integration, Betrieb, Anwendung, Sicherheit). Der SIDAP-Schwerpunkt lag auf der Bereitstellung und Analyse der Daten (beschrieben in Abbildung 8.2 der Informationssicht), die in einem nächsten Schritt durch Smart Data-Anwendungen genutzt werden.

Das **Geteilte Modellentwicklung und Benchmark-Analyse** ist die Kernkomponente der SIDAP-Cloud und dient der gemeinsamen Modellierung, Analyse und Visualisierung. Im SIDAP-Projekt werden IBM SPSS (Modellierung von Datenflüssen), MATLAB und R verwendet. IBM SPSS enthält alle wichtigen und benötigten Aggregationsmöglichkeiten (z.B. Mittelwertaggregation und Machine Learning Algorithmen). Zur Entwicklung und Bestimmung von Diagnosemethoden wurden auch Klassifikationsmodelle aus dem Gebiet der künstlichen Intelligenz angewendet. Verschiedene Algo-

rithmen sind Teil des SIDAP-Demonstrators und können als Teil eines Diagnose-Flows eingesetzt werden. **Speicher**-Komponenten dienen der Speicherung der Daten während Integrationskomponenten für die Übertragung zwischen den Umgebungen verantwortlich sind. Die Daten der SIDAP-Cloud können durch Smart Data-Anwendungen und andere Dienste (z.B. Auslösen von Alarmen) genutzt werden. Mit einer zu entwickelnden Access-Control-Komponente erfolgt der sicherere Zugriff auf die Daten (siehe 8.3.3 Sicherheitskonzept). Ferner können mit Hilfe eines Marktplatzes unterschiedlichste Informationen bzw. Modelle angeboten und verkauft werden.

Die Umgebung **Betreiber/Produktion** besteht aus folgenden Komponenten:

Datenquellen

Datenquellen sind hier die Daten-Historian und MES-Systeme der Fertigung, sowie Planungssysteme des Engineerings. Aber auch Wartungs- und Abrechnungssysteme können als Quelle dienen. Da nicht alle Systeme über einfach erreichbare Interfaces verfügen, kommen hier teilweise dateibasierte Austauschformate als Transferformat zum Einsatz.

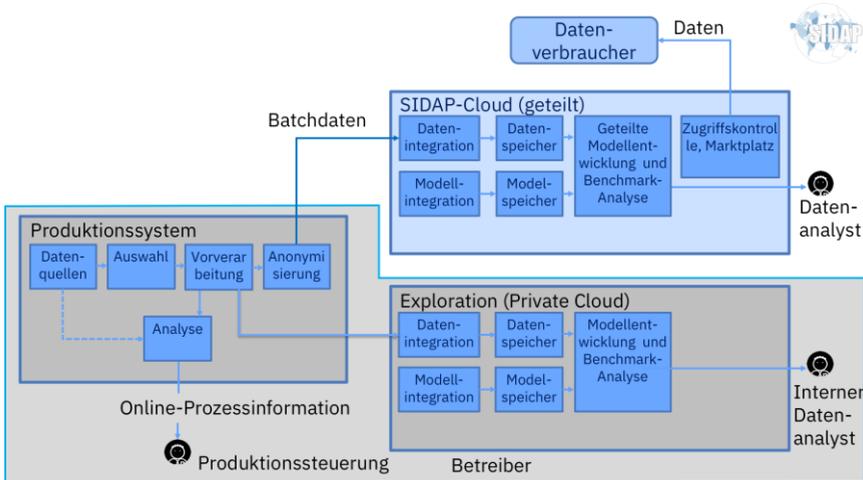


Abbildung 8.2: Datenflussdiagramm der SIDAP-Cloudarchitektur.

Auswahl

In diesem Schritt wird zunächst entschieden, welche Daten aus den Quellsystemen extrahiert werden sollen. Hierfür wird zunächst eine XML Meta-Beschreibung der Assets eingelesen.

Diese definiert welche Assets es gibt und wo zu diesen Assets Informationen zu finden sind. Basierend auf dieser Konfiguration werden die einzelnen Quellen abgefragt und die relevanten Daten extrahiert.

Vorverarbeitung

Zusätzlich zur Quellendefinition ist beschrieben, wie die extrahierten Daten transformiert werden sollen, damit sie für andere verständlich sind. Hierzu zählt insbesondere eine Vereinheitlichung der Einheiten und Datentypen, sowie eine Anpassung der zeitlichen Auflösung von Messreihen. Zukünftig können hier auch automatische Konvertierungen der Semantik durchgeführt werden. Beides findet im Schritt Vorverarbeitung statt.

Anonymisierung

Da die Daten z.T. aus sensiblen Bereichen der Fertigung kommen, muss verhindert werden, dass die Daten Rückschlüsse auf Betriebsgeheimnisse erlauben. Hierfür gibt es im Prinzip unterschiedliche Ansätze, die alle im Schritt Anonymisierung zusammengefasst sind:

1. Pseudonymisierung

Bei der Pseudonymisierung wird insbesondere der Name eines Probanden, oder im Fall SIDAP die technische Kennung eines Ventils, durch eine zufällig gewählte Nummer ersetzt, so dass ein Rückschluss von betroffenen Werten auf das jeweilige Asset bzw. den jeweiligen Patienten ohne Zusatzinformation unmöglich wird.

2. Anonymisierung & Differential Privacy

Bei der Anonymisierung werden die Daten der Individuen bzw. der individuellen Ventile so weit verfremdet, dass sie nicht mehr dem jeweiligen Ventil zugeordnet werden können. Hierzu kann ggf. das Verfahren der Differential Privacy zum Einsatz kommen.

Bei Differential Privacy werden die Daten soweit verrauscht, dass sich innerhalb der Daten Gruppen bilden, die sich in ihren Werten nicht mehr unterscheiden. Dadurch verschwinden das Individuum bzw. die

individuelle Information in der Gruppe und die einzelnen Mitglieder der Gruppen werden durch die Gruppe anonym.

Analyse

Parallel zu den Analysen der SIDAP-Cloud soll es zukünftig auch die Möglichkeit geben einfache Analysen auch direkt am Standort des Betreibers bereitzustellen. Hierzu sollen die entwickelten Algorithmen in vereinfachter Form im Block **Analyse** durchgeführt werden.

Die Umgebung **Betreiber/Exploration** dient der betreiber-internen Analyse und ist oftmals bereits in verschiedenen Formen vorhanden. Es können die gleichen Algorithmen wie in der SIDAP-Cloud verwendet werden, jedoch brauchen die Daten (Betriebsgeheimnisse) nicht pseudonymisiert und anonymisiert zu sein, wodurch auch eine Rückverfolgbarkeit zu den Anlagen möglich wird.

8.3.3 Sicherheitskonzept

Das Thema Sicherheit ist essentiell, da Betriebsgeheimnisse betroffen sind. Um das Thema „Sicherheit“ greifbar zu machen, soll hier ein gleichermaßen abstrakter wie profaner Einstieg gewählt werden, der Sicherheits-Maßnahmen wie folgt zusammenfasst:

Sicherheits-Maßnahmen sind technische Maßnahmen, die das Eintreten von verbotenen oder gefährlichen Situationen verhindern sollen.

Beziehen wir diese Aussage auf die Daten des SIDAP-Projektes, so ist das Lesen, Erzeugen, Verändern oder Löschen von Daten (Create, Read, Update, Delete := CRUD) durch eine unbefugte Person das zentrale unerwünschte Ereignis, das Sicherheitsmaßnahmen verhindern sollen.

Diese Problemstellung lässt sich in zwei unterschiedliche Aspekte aufteilen: Die Autorisierung befugter Zugriffe (für *Data-at-Rest*) und eine technische Zugriffsbeschränkung (für *Data-in-Motion*).

Bei der Definition der Befugnisse (Data-at-Rest) möchte man möglichst flexibel bleiben und ohne dass es zu komplex wird. An dieser Stelle können z.B. spezielle Verfahren, wie das Attribute-Based Access Control (ABAC, vgl. Abbildung 8.3), zum Einsatz kommen. Hierbei werden sowohl den Objekten (Daten), auf die zugegriffen werden soll, sowie den Benutzern Attribute zugeordnet. Zusätzlich werden diese Attribute mit Regeln verknüpft, so dass bei

jedem Zugriff geprüft werden kann, ob die Kombination aus Benutzer und Objekt den jeweiligen Zugriff erlaubt.

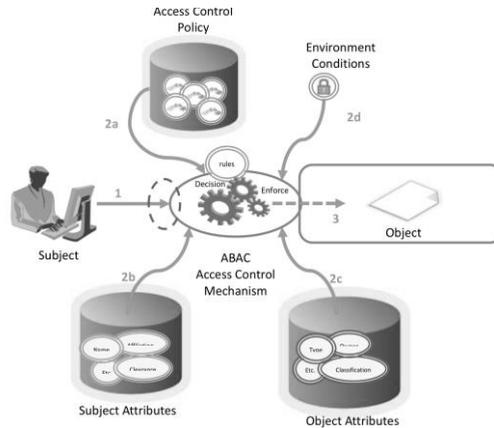


Abbildung 8.3: Funktionsweise Attribute-Based Access Control (ABAC) [HF+14].

Wenn man die Zugriffsarten Lesen, Erstellen, Verändern und Löschen mit der Menge der bekannten Benutzer kombiniert ergeben sich jedoch eine enorme Menge an Permutationen, so dass weder die Vergabe der Attribute an jeden einzelnen Benutzer, noch an jedes einzelne Objekt sinnvoll erscheint. Deshalb werden zweckmäßigerweise sowohl auf der Seite der Daten-Objekte, als auch auf der Seite der Anwender Gruppen gebildet, welche jeweils die gleichen Rechte erhalten.

Die **technische Zugriffsbeschränkung** (für Data-in-Motion) kann durch unterschiedliche Verfahren der Verschlüsselung erreicht werden. Zusätzlich sollen die jeweils Daten haltenden Systeme über Firewalls / Gateways und Zoning-Konzepte geschützt werden.

8.4 Umsetzung des Cloud-Konzepts

Um das hier vorgestellte Cloud-Konzept produktiv einsetzen zu können, sind noch einige weitere Aspekte näher zu beleuchten, die bislang im SIDAP-Projekt noch nicht oder nicht ausreichend bearbeitet werden konnten. Zu beachten ist, dass Änderungen der Architektur mit einem erhöhten Aufwand verbunden sein können.

- Die Skalierbarkeit ist im Wesentlichen durch die Komplexität der Algorithmen und Anzahl der Daten getrieben, die tatsächlich übertragen und verarbeitet werden.

- o Durch die Bereitstellung **zusätzlicher Hardware** (Prozessorleistung, Hauptspeicher, Festplattenspeicher, Netzwerkkapazität) kann eine Lösung ohne Änderung der Anwendung eine größere Last (Workload) verarbeiten.
- o Andere **Architekturen** und darin enthaltene Komponenten (Object Storage, In-memory/spaltenbasierte/NoSQL Datenbanken) können notwendig werden, z.B. wenn andere Datentypen verarbeitet werden sollen (unstrukturierte und Stream-/Echtzeit-Daten).

Weitere Optionen sind die Verwendung von gängigen Open Source-Tools (z.B. Spark, Hadoop), Tools zur Verbesserung der Datenqualität und Software-as-a-Service (z.B. IBM Watson Studio) zur unternehmensübergreifenden Zusammenarbeit.

- Abhängig von künftigen Anforderungen (Servicelevel) kann eine höhere **Verfügbarkeit** der Lösung notwendig werden, was sich auf die Anwendungsarchitektur insofern auswirkt, als zum Beispiel redundante Komponenten vorgesehen und *Single Points of Failure (SPOFs)* vermieden werden müssen.
- Ein übergreifendes **Datenmodell** mit einheitlicher Semantik wurde für SIDAP erzeugt, das noch weiter optimiert werden sollte, siehe Abschnitt 8.4.1 Semantik. Dabei wurde von den jeweiligen Quell-Datenmodellen abstrahiert, um eine Generalisierung zu erreichen und die Daten der jeweiligen SIDAP-Partner gleichermaßen abbilden zu können. Aber wichtiger als die technischen Aspekte ist die Vereinheitlichung von Definitionen bzw. der Semantik. Dies wird mit einem einheitlichen zentralen Datenmodell automatisch gefördert.
- Während im Demonstrator die **Datenintegration** auf MES-/Daten Historian-Ebene erfolgte, ist es prinzipiell auch möglich, dass – abhängig vom Anwendungsfall – auch Daten auf der Geräte- und Feldebene an die Cloud geschickt werden. Damit ist in produktiven Umgebungen mit wesentlich mehr Messwerten zu rechnen, deren Transport optimiert werden kann, um Übertragungszeiten zu reduzieren. Dies kann durch die Verwendung optimierter Übertragungsprotokolle (z.B. mit IBM Aspera) erfolgen.

- Für den laufenden **Betrieb** sind verschiedene Modelle denkbar. Es muss festgelegt werden, welche Organisation welche Teilbereiche (Dienste) verantwortet, welche Servicelevel es gibt, wie die Organisationen kommunizieren, wie die IT-Service (Überwachung, ggf. Neustart, Anpassungen HW/SW, Backup, Problem Management) abläuft, welche Tools verwendet werden. Dabei sind Kosten und bereits vorhandene Fähigkeiten abzuwägen.
- Die **Sicherheitsanforderungen** künftiger Nutzer und Kosten für zu implementierende Lösungen bestimmen eine zukünftige Architektur, wobei die zwei Teilbereiche *Data-at-Rest* und *Data-in-Motion* [ML16] berücksichtigt werden müssen. Basierend auf den o.g. Überlegungen wurde im SIDAP-Projekt ein einfaches Rechtekonzept umgesetzt (für *Data-at-Rest*), dass sich an dem Attribute-Based Access Control Ansatz orientiert. Dabei wurde zwischen „nicht vertraulichen“, „vertraulichen“ und „streng vertraulichen“ Informationen unterschieden. Bei den „streng vertraulichen“ Informationen wurde zusätzlich unterschieden, ob diese für die Analyse notwendig sind. Nicht notwendige Daten wurden vor dem Austausch entfernt. Notwendige Daten wurden pseudonymisiert, da bereits bei den Rohdaten Probleme der Datenqualität beobachtet werden konnten und diese nicht durch Anonymisierung negativ beeinflusst werden sollten. Die Informationen, welche zur De-Pseudonymisierung benötigt werden wurden in getrennten Systemen gespeichert. Außerdem wurde zwischen SIDAP-Mitgliedern und externen Personen unterschieden, wobei letztere nur „nicht vertrauliche“ Informationen erhalten dürfen.

Im Rahmen von SIDAP wurden für die externe Kommunikation nur verschlüsselte Verbindungen eingesetzt.

Weitere Sicherheitsoptionen sind:

- Authentifizierung (Nachweis der Nutzer-Identität)
- Audit-Lösung (Protokollierung von Ereignissen)
- virtuelle, private Netzwerke (VPNs) zwischen den Unternehmen und der Cloud.

8.4.1 Semantik

Ein zentrales Problem der digitalen Transformation stellt die Interpretierbarkeit von Daten dar, denn erst durch die richtige Interpretation werden Daten auch zu nützlichen Informationen. Dabei ist die Verwendung einer einheitlichen und präzisen Semantik eines der Schlüsselthemen.

Leider schleichen sich im realen Leben in den räumlich und zeitlich verteilten Systemen sehr leicht semantische Unterschiede ein.

Dies kann z.B. dazu führen, dass sich die Schreibweise von Anlagenkennziffern zwischen den Planungssystemen und den Daten-Historian-Systemen leicht unterscheiden. Häufig sind auch Hersteller-Bezeichnungen, Asset-Eigenschaften oder Maßeinheiten in den verschiedenen Systemen leicht unterschiedlich benannt.

Am Beispiel der Einheiten wurde ein Konzept entwickelt und umgesetzt, welches sowohl die einheitliche Definition als auch die automatische Umrechnung von Einheiten abbildet. Dabei werden intern nur die SI Basiseinheiten verwendet. Beim Anlegen eines „Einheiten-Objektes“ können allerdings auch unterschiedlichste vordefinierte abgeleitete Einheiten verwendet werden. Diese werden dann automatisch in die relevanten Basiseinheiten umgerechnet.

Bei dem Mapping der Anlagenkennziffern aus der jeweiligen P&ID Dokumentation mussten gleichzeitig zwei Transformationen durchgeführt werden. Zum einen mussten die minimal unterschiedlichen Schreibweisen der Anlagenkennziffer berücksichtigt werden, zum anderen musste den jeweiligen technischen Plätzen in der Anlage eine Bedeutung für das jeweilige Ventil zugewiesen werden.

Da insbesondere die letztere Aufgabe momentan noch händisch durchzuführen ist, wurde hier auch gleich die Korrektur der Schreibweise vorgenommen. Zukünftig ist geplant, dass diese Zuordnungen auf Basis der digitalen P&ID Information erfolgen können soll, wobei dann das DEXPI Format [TW17] zum Einsatz kommen würde.

Für das hier vorgestellte Forschungsprojekt und die betrachtete Menge an Assets sind leicht händische Verarbeitungen akzeptabel, diese skalieren aber nicht für den produktiven Einsatz. Hat man aber erstmal semantische Begriffe definiert und mehrere Übersetzungen umgesetzt, so können Techniken aus dem Bereich des Machine-Learning genutzt werden, um weiter Varianten von

Schreibweisen automatisch zuzuordnen. Hier lässt sich z.B. ein kNN-Verfahren nutzen, um noch unbekannte aber sehr ähnliche Schreibweisen einem bereits bekannten Begriff zuzuweisen.

Dabei sind sowohl die jeweiligen Begrifflichkeiten der Quellsysteme, als auch die als „Standard“ angesehene Informations-Semantik stark vom jeweiligen Anwendungsfall abhängig. Hat man einen Teilaspekt der Informationslandschaft in einer einheitlichen Semantik abgebildet, so ist es leicht möglich diese Darstellung in eine andere zu überführen.

8.5 Zusammenfassung

Dieser Beitrag beschreibt Cloud-Konzepte für Smart Data-Anwendungen auf Basis der Erfahrungen im SIDAP-Projekt. Die benötigten Funktionen befinden sich in der Cloud als auch bei den beteiligten Unternehmen, die die Daten entsprechend aufbereiten. Im SIDAP-Projekt wurden bereits einige Erfahrungen mit relevanten Werkzeugen und Verfahren gesammelt. In einem nachgelagerten Projekt muss unter Berücksichtigung zukünftiger Anwendungsfälle, nicht-funktionaler Anforderungen und weiterer Randbedingungen weitere konzeptionelle Vorarbeit geleistet werden (z.B. Sicherheit und Semantik) und eine Konkretisierung (z.B. benötigte Produkte) des Konzepts erfolgen.

8.6 Definitionen

Definition: Anlagenkennziffer

Eindeutige Identifikation einer technischen Funktion (z.B. Messstelle).

Definition: NLP

Natural Language Processing, Verarbeitung natürlicher Sprache.

Definition: NoSQL

Not only SQL, nichtrelationales Datenbanksystem (verwendet keine Spalten und Zeilen), wird von vielen Cloud-Anwendungen genutzt.

Definition: Object Storage

Üblicher Datenspeicher in Cloud-Umgebungen für große Datenmengen (insbesondere Bilder und Videos), die als Objekte ohne Hierarchie (wie in einem Dateisystem) gespeichert werden.

Definition: Off-premise cloud/on-premise cloud

Cloud befindet sich außerhalb (i.d.R. bei einem Cloud Service Provider) bzw. auf dem Gelände des Unternehmens.

Definition: Single Point of Truth

Zentrale Datenquelle, wo alle verfügbaren Daten abgelegt werden. Die wahre Information liegt nur hier und nirgendwo sonst.

Definition: Soft Sensor

Ein Softsensor ist ein Sensor der nicht den gemessenen Wert als Messgröße ausgibt, sondern meist mehrere gemessene Werte mit einander verrechnet und somit eine Messgröße schätzt, die so nicht gemessen wurde. Softsensoren werden insbesondere da eingesetzt, wo die gewünschten Messgrößen nicht direkt beobachtbar sind.

Beispiel: Energieverbrauch einer Heizung als Ergebnis aus Temperaturabfall am Heizkörper und dem Durchfluss.

Definition: XaaS (IaaS, PaaS, SaaS)

Servicemodelle des Cloud-Computings:

Infrastructure-as-a-Service/IaaS beinhaltet Bereitstellung der RZ-Infrastruktur (z.B. virtualisierte Betriebssysteme).

Platform-as-a-Service/PaaS stellt eine Plattform für Entwickler von Webanwendungen bereit. Kann beinhalten: Laufzeitumgebung, Entwicklungsumgebung. Nutzer können verschiedenste Services nutzen (z.B. Datenbanken, Integration), ohne sich um die Beschaffung von Hard- und Software kümmern zu müssen.

Software-as-a-Service/SaaS stellt komplette Softwarepakete zur Verfügung.

8.7 Danksagung

Die Autoren bedanken sich beim BMWi für die Förderung des Projekts SIDAP (Förderkennzeichen 01MD15009F) als auch bei den Kooperationspartnern des SIDAP-Konsortiums für die Unterstützung. Weiterhin bedanken sich die Autoren bei Emanuel Trunzer (TUM), Michael Metzenmacher (ehem. TUM), Dr. Christoph Leszinski (IBM) und Wilfried Hoge (IBM) für Ihren wertvollen Beitrag an der Erstellung des Konzepts.

Literatur

- [HF+14] V. C. Hu, D. Ferraiolo, R. Kuhn, A. Schnitzer, K. Sandlin, R. Miller, K. Scarfone: “Guide to Attribute Based Access Control (ABAC) Definition and Considerations“. NIST special publication, 800-162, 2013.
- [ML16] T. Messerschmidt, J. LeBlanc. “Identity and Data Security for Web Development“. O’Reilly, Sebastopol, 2016.
- [TW17] M. Theißen, M. Wiedau. „DEXPI P&ID Spezifikation“, online verfügbar auf <https://github.com/DEXPI/DEXPIdev/blob/master/specification/DEXPI%20Specification%201.2.pdf> (aufgerufen am 06.07.2018).
- [WM] W. Morr. „Smart Data im Anlagenbetrieb: Informationen aus Prozess und Anlagedaten generieren Mehrwert bei Betrieb und Wartung“, online verfügbar auf <http://www.tuev-sued.de/uploads/images/1435066395932680861018/01-morr.pdf> (aufgerufen am 06.07.2018).

9 Integration von Feldgerätedaten aus Bestandsanlagen Eine Security und Business Challenge

Dr. J.A. Nagel, B. Stracke
Neoception GmbH, Mannheim
{jnagel, bstracke}@neoception.com

C. Vermum, C. Kloh
Evonik Industries AG, Marl
{christian.vermum, christian.kloh}@evonik.com

9.1 Ausgangssituation

Aufgrund der hohen Investitionen werden nur wenige chemische Prozessanlagen von Grund auf neu entwickelt. Der wesentlich größere Teil unterliegt einer teilweisen, aber meist kontinuierlichen, Erneuerung. Bei Anlagenlaufzeiten von bis zu 50 Jahren ist die kontinuierliche Optimierung einer chemischen Produktionsanlage wesentlicher Bestandteil der Optimierungsstrategie von Betreibern. In den letzten Jahrzehnten haben durch Teilerneuerungen in die Anlagen Technologien Einzug erhalten, die es erlauben trotz der durch die Explosionsschutzbestimmungen beschränkten Leistungsverorgung der Feldgeräte zunehmend mehr Intelligenz in die Feldgeräte zu integrieren. Ein mögliches Potential steckt daher in der Verwendung der Daten, die bereits in nahezu jedem Feldgerät der Prozessautomation vorhanden sind.

Wenn Daten dazu genutzt werden, um Betriebsabläufe in chemischen Anlagen zu optimieren, die Prozesseffizienz zu steigern oder die Wartungsprozesse zu optimieren, ist dies meist getrieben von Konzepten der Industrie 4.0, die darauf basieren Daten aus den Anlagen zu analysieren und automatisiert fundierte und gesicherte Schlüsse aus der Historie und dem Anlagenzustand zu ziehen, sowie gegebenenfalls automatisiert korrekt darauf zu reagieren.

Welche Potentiale dies sind und wie sie zur Optimierung von Wartungsprozessen erschlossen werden können untersucht derzeit das Verbundprojekt SIDAP. Aufgrund des hohen Anteils an Bestandsanlagen gegenüber Neuanlagen gewinnt die Verarbeitung von Daten aus Bestandsanlagen zunehmend an Bedeutung. Erschwerend ist hier, dass bei der Konzipierung der Anlagen ein umfassender Zugriff auf die Daten in den Feldgeräten nicht vorgesehen

war. Meist führt dieser Umstand dazu, dass eine nachträgliche Datenextraktion erhebliche Kosten und Risiken birgt, da unter Umständen Eingriffe in das Prozessleitsystem benötigt werden.

Um die Potentiale in der Wartung von Ventilen realistisch analysieren zu können, wurden im Projekt SIDAP in einer produktiven Anlage Ventile mit digitalen Stellungsreglern um Zusatzsensorik in Form von Temperatur- und Drucksensorik erweitert. Die Daten der Stellungsregler sowie der Zusatzsensorik sollten mit minimalem Aufwand automatisiert extrahiert und zur Auswertung verfügbar gemacht werden. Hierzu wurde ein mehrstufiges Übertragungskonzept entwickelt, und umgesetzt, was im folgenden Beitrag beschrieben wird.

9.2 Konzept

Die größte Herausforderung bei der Entwicklung des Übertragungskonzepts war, mit möglichst geringem Implementierungsaufwand Daten aus Feldgeräten in einer produktiven Anlage einem externen Datenanalysten zur Verfügung zu stellen. Da sich die Ventile in einem Produktionssystem befinden, hat die Wahrung der IT-Security höchste Priorität. Zur Reduktion der Komplexität orientiert sich das Lösungskonzept stark an den bereits bestehenden Infrastrukturen des Betreibers.

Im Folgenden wird in zwei Teilkonzepte der Datenübertragung unterschieden.

- Zum einen die Extraktion der Daten aus den Feldgeräten und Aufbereitung der Daten zur Weiterverarbeitung in der IT,
- zum anderen die Weiterleitung der Daten durch die IT Landschaft bis zum externen Datenkonsumenten.

9.2.1 Anforderungen

Entscheidend für die Akzeptanz des Konzepts ist, einen parallelen Weg zur Kommunikation mit den Feldgeräten herzustellen, der unabhängig vom bestehenden Leitsystem existiert, da eine Änderung im Leitsystem für Testzwecke ein zu großes Risiko darstellt.

Eine weitere Anforderung ist, dass die Daten von allen Ventilen mit samt der Zusatzsensorik möglichst hochfrequent und zeitsynchron ausgelesen werden.

9.2.2 Integration von Daten in die IT Welt

Abbildung 9.1 zeigt den elektrischen Aufbau der Datenübertragung für ein exemplarisches Ventil. In der realen Implementierung wurden fünf Ventile ausgerüstet.

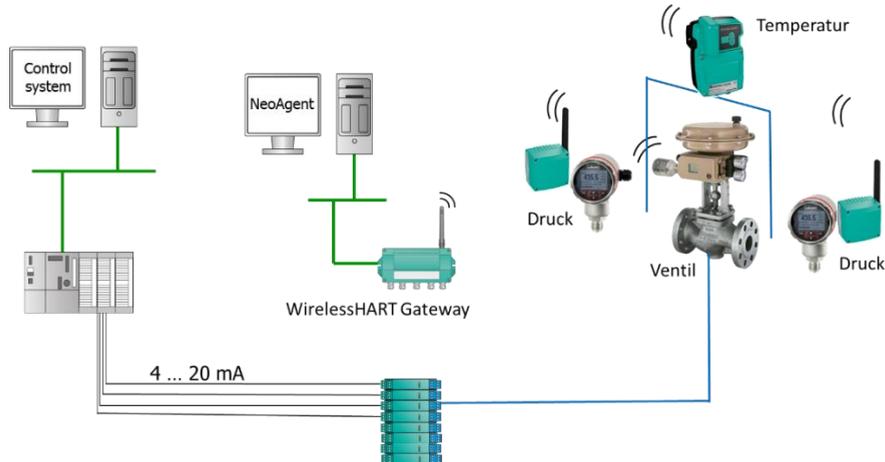


Abbildung 9.1: Elektrischer Aufbau und WirelessHART Netzwerk.

Zur Realisierung der Datenakquise wurde ein paralleler Zugriff auf die Feldgeräte via WirelessHART konzipiert. WirelessHART ist ein Funkstandard zur drahtlosen Übertragung von HART Befehlen an Feldgeräte. WirelessHART ist für die Kommunikation mit Feldgeräten gut geeignet, da es

- eigensichere Interfaces zur Anbindung von Feldgeräten gibt,
- durch die meshed Netzwerktopologie eine sehr gute Ausfallsicherheit gewährleistet und
- die Kommunikation per design verschlüsselt ist.

Die im Fokus stehende Anlage nutzt kein zentrales Assetmanagementsystem und das Leitsystem kommuniziert mit den Feldgeräten lediglich über 4-20 mA Analogsignale. Die HART Schnittstelle ist damit noch ungenutzt und kann ebenfalls für den dynamischen Datenzugriff genutzt werden.

Die Steuerung der Datenübertragung übernimmt ein Agent (bezeichnet als NeoAgent in Abbildung 9.1). Über definierte Regeln extrahiert der Agent zyklisch alle relevanten Daten aus den Feldgeräten. Dabei wird in zwei Kategorien von Daten unterschieden.

1. Zyklische Daten
2. Azyklische Daten

Die zyklischen Daten umfassen alle Prozessdaten wie Drücke, Temperaturen, Soll- und Ist-Werte des Ventils und verbleibende Restkapazität der batteriebetriebenen WirelessHART Adapter. Die zyklischen Daten werden über konfigurierte Bursts von den WirelessHART Adaptern automatisch an das WirelessHART Gateway gesendet. Die Daten werden auf dem WirelessHART Gateway gepuffert, bis sie durch einen weiteren Burst eines Feldgeräts überschrieben werden. Um keinen Wert zu verlieren, müssen die Daten vom Neo-Agent abgeholt werden, bevor das Gateway einen weiteren Burst vom jeweiligen Feldgerät empfängt.

Als azyklische Daten gelten alle Daten, die mit einer niedrigen Frequenz, beispielsweise einmal pro Tag, abgerufen werden. Hierzu zählen Histogrammdaten und andere bereits in den Feldgeräten vorverarbeitete Statistiken. Die azyklischen Daten werden nach einem Regelwerk immer zwischen den höher priorisierten zyklischen Daten aus den Feldgeräten ausgelesen. Der Zugriff auf die azyklischen Daten benötigt erheblich mehr Zeit, da sie nicht durch den Adapter ausgelesen werden, sondern vom Agent durch einen Befehl angefragt werden, der zunächst das Feldgerät erreichen, dort verarbeitet und in Form einer Antwort vom Feldgerät wieder an den Agenten zurückgesendet werden muss. Dauert dieser Prozess länger als die definierte Zeit zwischen zwei Bursts, wird die Anfrage abgebrochen, um die Bursts zu verarbeiten und danach wiederholt.

Im WirelessHART Standard wird ein TDMA Kanalzugriffsverfahren mit Zeitschlitzten von 10 ms genutzt [L11]. Damit ergibt sich eine theoretische Netzwerkkapazität von 100 Nachrichten pro Sekunde. Real ist die Netzkapazität für Nutzdaten wesentlich geringer, da sowohl das Netzwerkmanagement Zeitschlitzte benötigt als auch Wiederholungen bei Fehlübertragungen und Fehlrouting von Paketen durch die Mesh-Topologie des WirelessHART Netzwerks auftreten können. Die reale Netzkapazität hängt stark von der Netztopologie, der Anzahl der Teilnehmer und den physischen Umgebungsbedingungen ab und liegt realistisch bei ca. 30 Telegrammen pro Sekunde [L11].

9.3 Umsetzung

Das Konzept wurde im Projekt für fünf Armaturen umgesetzt. Jede Armatur umfasst einen Stellungsregler, zwei Drucksensoren und einen Temperaturtransmitter zur Übermittlung des Drucks und der Temperatur vor und nach dem Ventil. Insgesamt wurden damit 35 Feldgeräte über WirelessHART an-

gebunden, von denen im Betrieb zyklisch die Prozessdaten übertragen werden. Besonderes Augenmerk liegt im Projekt auf dem Stellungsregler. Vom Stellungsregler werden neben den zyklisch zu übertragenden Prozessdaten täglich Statistikdaten übertragen. Die Übertragung der Statistikdaten umfasst mehrere hundert Parameter und dauert mehrere Minuten. Hier kommt das oben beschriebene Konzept zum Tragen, das gewährleistet, dass durch die azyklische Übertragung der Statistikdaten die zyklische Übertragung der Prozessdaten nicht gefährdet wird.

Für den Betrieb der Stellungsregler wurden schleifengespeiste WirelessHART Adapter eingesetzt. Die Zusatzsensorik wurde zur Minimierung des Verdrahtungsaufwands mit batteriegespeisten WirelessHART Adaptern angebunden.

Die wesentlichen Schritte auf dem Weg zur erfolgreichen Implementierung einer in eine produktive IT Umgebung integrierte Übertragung der Daten in das Internet stellen die folgenden dar:

- Definition benötigter Prozesse
- Identifikation der bestehenden IT Architektur
- Ermitteln der möglichen Zonen, die von den Daten durchlaufen werden
- Identifikation bereits bestehender und vorqualifizierter IT-Komponenten
- Konzeption von neuen Komponenten in Zonen, in denen keine geeigneten Komponenten verfügbar sind
- Definition der Schnittstellen zwischen den Komponenten

Die zu konzipierende Lösung bildet im Wesentlichen einen Benutzerprozess ab. Die Daten sollen wie in Abschnitt 9.1 definiert aus den Feldgeräten nach vordefinierten Regeln automatisiert und lückenlos aggregiert und dem Datenanalysten in einem geeigneten Format außerhalb des Geländes des Betreibers online verfügbar gemacht werden.

Im vorliegenden Fall wurde die bereits beim Betreiber bestehende IT Architektur in Anlehnung an die Empfehlungen der Normen ISA95 [ISA95] und ISA99 [ISA99] konzipiert. Die gesamte IT Landschaft ist damit in Zonen unterteilt, die unterschiedlichen Sicherheitsniveaus zugeordnet sind. In den Übergängen zwischen den Zonen befinden sich Firewalls und die Zonen selbst können in verschiedene Netzsegmente unterteilt werden.

In Abbildung 9.2 stellt vereinfacht die vorhandene IT Architektur und die Integration der SIDAP Komponenten dar. Ein direkter Zugriff aus der Office IT oder dem Internet auf die Produktion wäre ein erhebliches Sicherheitsrisiko. In der Darstellung ist daher zu erkennen, dass die Daten auf dem Weg zum Internet mehrere Zwischeninstanzen durchlaufen. Die Daten entstehen in der Anlage in der Produktion. Die produktionsnahe IT hat sehr beschränkten Zugriff auf die Komponenten in der Produktion, nicht aber umgekehrt. Der SIDAP Applikationsserver ist damit in der Lage Daten aus der Produktion zu lesen und in eine höhere Ebene, die Office IT, zu schreiben. Aus diesem Grund wurde der NeoAgent auf dem SIDAP Applikationsserver in der produktionsnahen IT implementiert. Die Daten werden vom NeoAgent gemäß einem vordefinierten Rezept aus den Feldgeräten ausgelesen und in Datendateien abgelegt. Durch einen Systemservice werden die Datendateien zyklisch auf den Teamroom Server synchronisiert, von dem sie durch externe Verantwortliche unter bereits vom Betreiber etablierten Regularien abgeholt werden können. Der Eingriff in die bestehende IT Architektur bleibt damit minimal und die Lösung nahezu vollständig getrennt vom Produktionssystem.

Für die Übertragung ist es wesentlich, dass die Daten frühestmöglich einen eindeutigen Zeitstempel erhalten. Hierzu ist ein Zugriff auf ein Zeitnormal erforderlich. Eine entsprechende Zeitsynchronisation erfolgte über den bereits in der Infrastruktur vorhandenen NTP Server. Auch das bereits vorhandene Malware und Patchmanagement findet Anwendung.

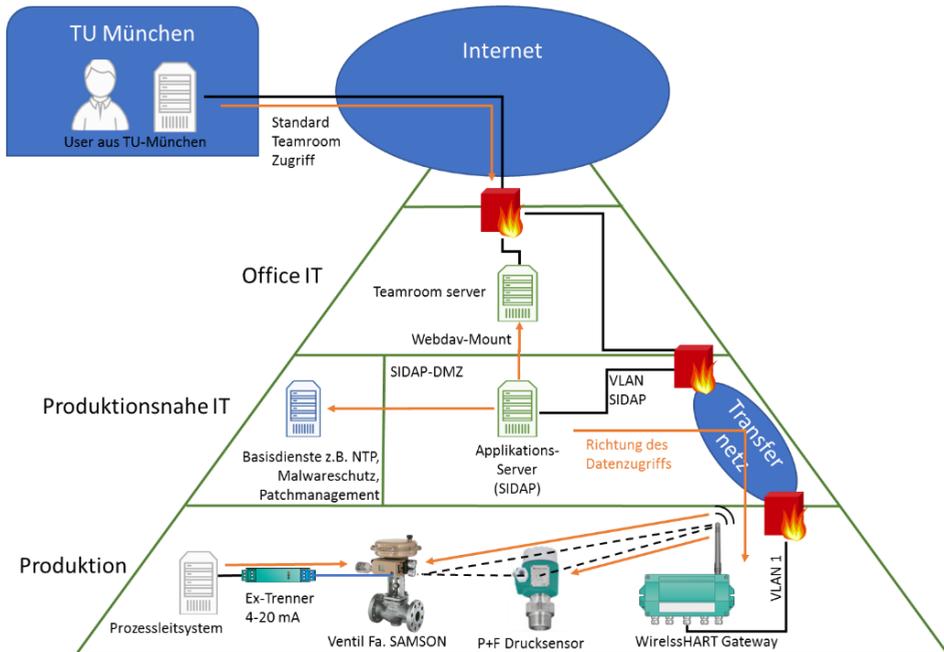


Abbildung 9.2: Vereinfachte schematische Darstellung der Gesamtarchitektur.

9.4 Erkenntnisse

Bei der Implementierung des NeoAgent wurde großer Wert auf eine hohe Datenqualität gelegt. Dazu müssen die zyklischen Prozessdaten möglichst mit geringem Jitter und ohne Datenverlust gespeichert werden. Durch die Netzwerktopologie des WirelessHART Netzwerks erreichen die regelmäßig vom Feldgerät durch den Adapter abgefragten und mit Burst-Mechanismen zum WirelessHART Gateway übertragenen Daten das Gateway mit einer gewissen Streuung. Abbildung 9.3 zeigt die Streuung der Ankunftszeiten bei definierter Burstzeit von 60 s. Es ist klar zu erkennen, dass die Daten erst nach ca. 70 Sekunden mit hoher Wahrscheinlichkeit im Speicher des Gateways vorliegen und damit schnell abgerufen werden können. Das Alter des Bursts eines Feldgerätes wird durch den NeoAgent mittels spezieller Mechanismen im WirelessHART Gateway korrigiert. Damit werden die Daten bereinigt auf den Entstehungszeitpunkt weiter verarbeitbar.

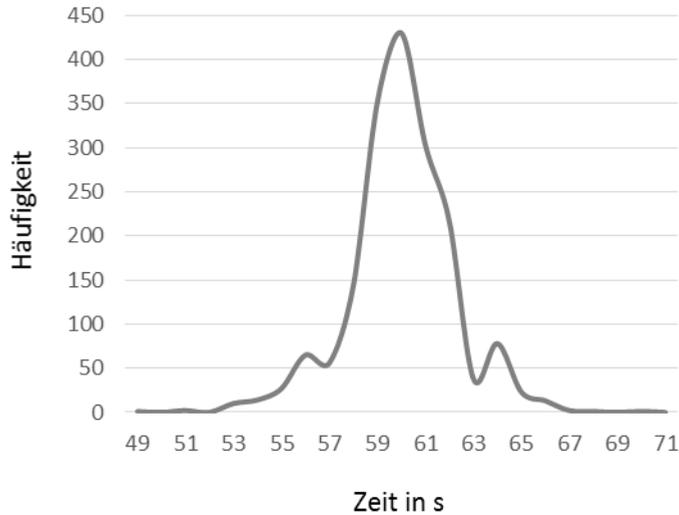


Abbildung 9.3: Ankunftszeit von Bursts am WirelessHART Gateway bei definierter Burstzeit von 60 s am Adapter.

Bei der Entwicklung des Konzepts wurden alle Funktionen mit Hilfe eines Testgeräts jedes Typs evaluiert. Im Labor mit wenigen Feldgeräten sind die auftretenden Antwortzeiten sehr kurz. Bei der Inbetriebnahme im realen Umfeld mit allen Feldgeräten zeigte sich, dass mit zunehmender Netzlast im WirelessHART Netz auch die Antwortzeiten der azyklischen Kommunikation mit den Feldgeräten anstiegen. Dies führte zunehmend dazu, dass die Kommunikation mit dem Feldgerät vor Erhalt der Antwort abgebrochen werden musste, um die zyklischen Daten aus dem Cache des WirelessHART Gateways auszulesen und keinen Burst-Zeitpunkt zu verpassen.

Bei der Installation der Ventile in die reale Anlage trat ein weiterer Effekt ein. Zur Veranschaulichung zeigt Abbildung 9.4 den zeitlichen Ablauf der Datenübertragung. Zunächst muss die Streuung (rot) der Ankunftszeiten der Bursts abgewartet werden, um sicher zu stellen, dass alle Bursts im Speicher des Gateways vorliegen. Die Zeit darf jedoch nicht zu lang sein, damit die Daten nicht durch den folgenden Burst überschrieben werden. Durch die Asynchronität der Bursts zum Timing des NeoAgents und um zu vermeiden, dass ein Burst verloren geht, wird ein Oversampling implementiert. Das bedeutet, dass innerhalb der konfigurierten Burst-Zeit die Burst-Daten zweimal vom Gateway abgefragt werden müssen. Zum einmaligen Auslesen der Burst-Daten aus dem Feldgerät durch den Agenten werden pro Feldgerät zwei, also insgesamt 70 Befehle, benötigt. Nach der Verarbeitung der Bursts werden die

azyklischen Daten ausgelesen. Dies erfolgt so lange, bis das vorgegebene Zeitfenster aufgebraucht ist und wieder Burstdaten gelesen werden müssen.

Während zu Beginn des Projekts für den Betrieb des Agenten ein Computer in physikalischer Nähe zum WirelessHART Gateway vorgesehen war, wurde der Agent final auf einem virtualisierten Rechner im Rechenzentrum des Betreibers installiert. Dies führt bei jeder Anfrage an das WirelessHART Gateway zu einer leicht erhöhten Latenz (gelb). Zusammen mit der sehr langen Ausführungsdauer der azyklischen Befehle von durchschnittlich 8 s und der erhöhten Netzlast im WirelessHART Netz war bei 16 s Burst-Dauer keine Zeit mehr, azyklische Befehle an die Feldgeräte abzusetzen. Aus diesen Gründen wurde die ursprünglich geplante Burst-Zeit von 16 s erhöht.

Das Konzept zur Unterteilung der Daten in zyklische und azyklische Daten hat sich im Betrieb bewährt. Trotz großer Streuung der Antwortzeiten bei azyklischen Befehlen an ein Feldgerät können die azyklischen Daten nach Erhöhung der Burst-Zeit wie gefordert zuverlässig einmal im Laufe des Tages ausgelesen werden, ohne die Übertragung der hochfrequenten zyklischen Prozessdaten zu gefährden.

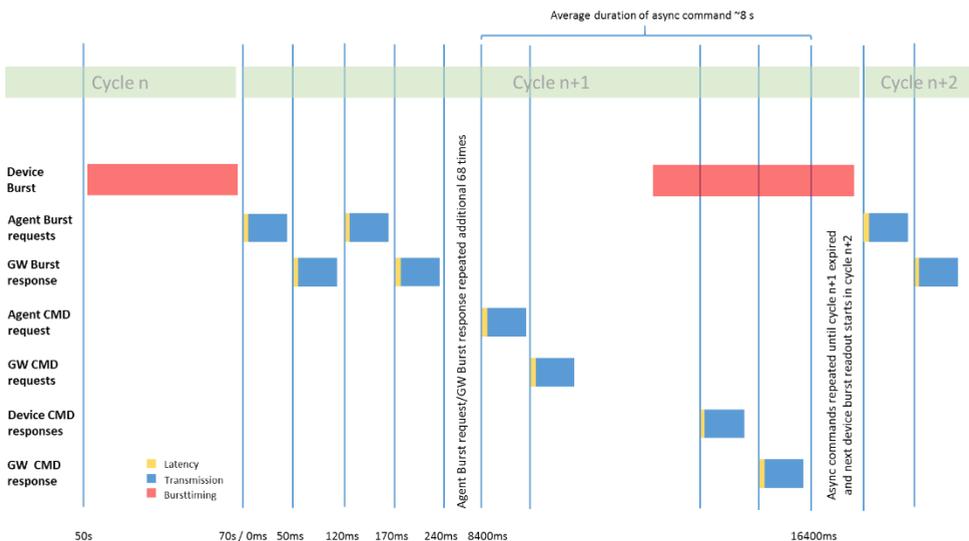


Abbildung 9.4: Veranschaulichung des Timings der Datenübertragung.

9.5 Zusammenfassung

Im Rahmen des Projekts konnte gezeigt werden, dass Daten aus Feldgeräten in Produktionsanlagen mit verhältnismäßig kleinem Aufwand ausgelesen werden können. Besonderes Augenmerk muss dabei auf die Aspekte IT Security, Rückwirkungsfreiheit zum Prozessleitsystem und Datenqualität gelegt werden.

9.6 Danksagung

Wir danken allen Partnern im Konsortium für die Chance unseren Beitrag zum Erfolg des Projekts SIDAP beisteuern zu dürfen sowie die stets offenen und konstruktiven Diskussionen.

Literatur

- [L11] G. Lohmann: Wireless Technology WirelessHART. Technical Whitepaper, 2011.
- [ISA95] International Society of Automation: ANSI/ISA-95.00.01-2000: Enterprise-Control System Integration – Part 1, 2013.
- [ISA99] International Society of Automation: ISA99, Industrial Automation and Control Systems Security, 2004.

10 Condition Monitoring Systeme als Datenlieferant für Big Data Anwendungen

Dr.-Ing. J. Folmer, Dr. rer. nat. E. Becker
PRÜFTECHNIK Condition Monitoring GmbH
{jens.folmer, edwin.becker}@pruftechnik.com

10.1 Einleitung und Motivation

In allen Branchen, von der Prozesstechnik über die Fertigungstechnik bis hin zu Windenergieanlagen (WEA), werden Daten aufgezeichnet. Bisher wurden Daten nur für Gewährleistungszwecke und/oder für eine Rückverfolgung systematisch genutzt / ausgewertet. Viele eingesetzte SCADA-Systeme (Supervisory Control and Data Acquisition) sind entkoppelt von anderen Systemen und speichern Daten in heterogener Weise ab (vgl. [PF+17]). Eine Datenintegration verschiedener Systeme findet kaum statt. Die Aggregation der verschiedenen Daten ist aufwändig, da bspw. die Zeitstempel verschiedener Systeme nicht exakt synchronisiert sind und somit die zeitrichtige Zuordnung manuell durchgeführt werden muss. Aktuell versucht man zwar, z.B. über Dashboards, mehreren Beteiligten einen Überblick zu den verfügbaren Daten zu schaffen, doch diese Darstellungen allein genügen nicht. Insbesondere Condition Monitoring Systeme (CMS) zeichnen Daten zu hochfrequent und zu diskontinuierlich auf. Zudem müssen die Daten in einer Art aufbereitet werden, die der Zielgruppe entsprechen. Abbildung 10.1 zeigt die Infrastruktur, die bei PRÜFTECHNIK im Rahmen des Condition Monitoring Prozesses nicht nur für Windenergieanlagen verwendet wird und auch dem Management ermöglicht, Zugriff zu Daten zu bekommen und im Ampelform den Zustand der Assets schnell zu überblicken.

Bezogen auf WEA werden CMS-Daten verwendet, um Rückschlüsse auf WEA-Zustände und die jeweiligen Komponentenzustände des Triebstrangs zu ziehen. Grundlage sind meist Schwingungen, welche von Schwingungsspezialisten diagnostisch bewertet werden.

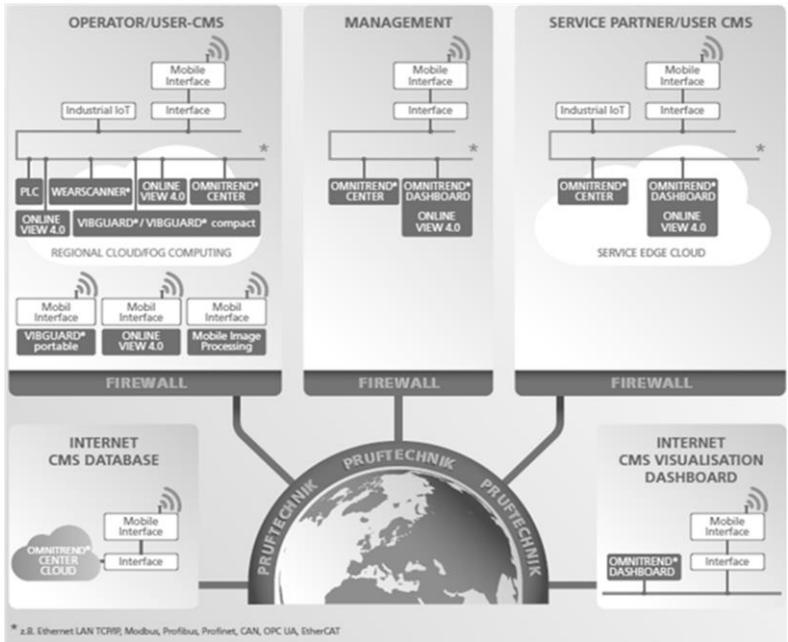


Abbildung 10.1: Systemarchitektur der PRÜFTECHNIK, um WEA-Daten umfassend zu benutzen und zu visualisieren.

Beim Condition Monitoring an Windenergieanlagen wird zwischen Bewegung, Maschinenschwingung und Körperschall mit deren Frequenzbereichen unterschieden, wie in Abbildung 10.2 dargestellt.

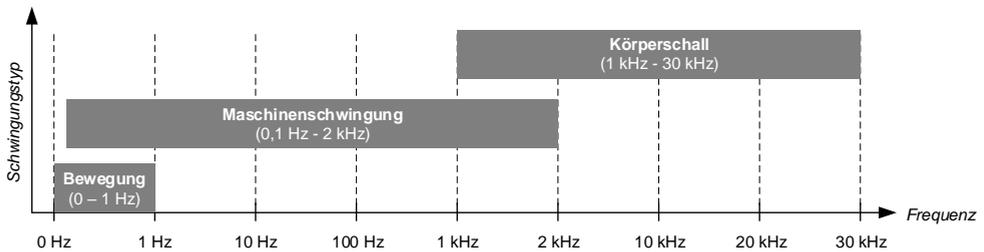


Abbildung 10.2: Schwingungstypen und deren Frequenzbereiche.

Diagnostiziert wird der Maschinenzustand klassischerweise über Frequenz- und Ordnungsspektren. Der Anstieg von individuellen Frequenzamplituden lässt auf einen sich anbahnenden Schaden schließen; d.h. der kontinuierliche Anstieg von Amplituden definierter Frequenzen im Laufe der Zeit zeigt einen möglichen Schaden an. Darüber hinaus sind weitere Methoden nützlich, die

jedoch eine solide Datenbasis mit hoch abgetasteten Werten und zuverlässige Messungen benötigen.

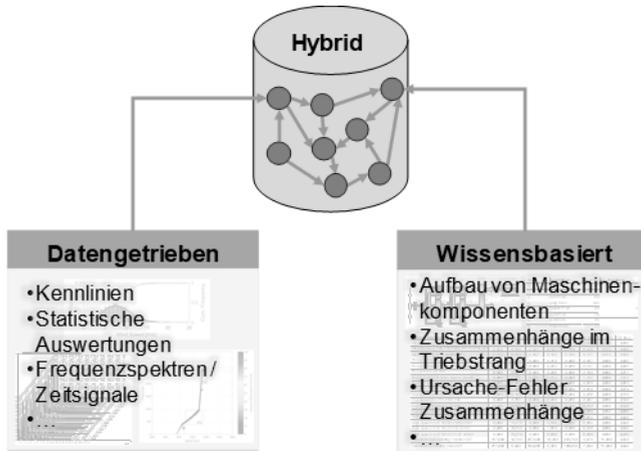


Abbildung 10.3: Moderne Auswertungsmethoden für die Maschinenüberwachung.

10.1.1 Hybride Datenauswertung

Grundlegend wird bei der Diagnostik zwischen datengetriebener und wissensgetriebener Auswertung von Daten unterschieden (vgl. Abbildung 10.3). Datengetriebene Auswertungen beinhalten die Aufzeichnung und automatische Analyse von Zeittrendsignalen, Kennlinien-basierte Auswertungen und statistische Auswertungen (vgl. [DB17]) etc. Hierbei werden Key-Performance Indicator (KPI) berechnet, die einen Hinweis auf den Komponenten-zustand bieten und weisen den Diagnostiker darauf hin, welche Komponenten – mit lokaler Verortung in der Anlage – einen kritischen Schaden aufweisen, der tiefendiagnostisch untersucht werden muss. Bei wissensbasierten Auswertungen muss anwendungsspezifisch diagnostiziert werden. Die verschiedenen Schwingungstypen (vgl. Abbildung 10.2) die es zu interpretieren gilt, sind häufig Symptome eines Schadens. Ursache- und Wirkbeziehungen von Schäden können nur mit Wissen über den Aufbau von Triebstrangkomponenten, die Zusammenhänge im Triebstrang und damit auch in Relation zu Amplitudenspektren und dynamischen Zeitsignalen gesetzt werden. Hochqualifizierte Diagnostiker oder auch ISO CAT zertifizierte Schwingungsspezialisten (nach ISO 18436-2 [ISO14]) haben dieses Detailwissen und können somit verschiedene Anwendungsfälle untersuchen und auch anwendungsfallspezifisch Schäden unterscheiden.

Hybride Auswertungen nutzen sowohl die Vorteile der datengetriebenen als auch wissensgetriebenen Auswertungen, was bevorzugt bei der PRÜFTECHNIK AG angewendet wird. Dadurch ist die Betrachtung von Ursache- und Wirkbeziehungen bei WEA besonders wichtig, da sich ein Schaden nicht nur lokal auf eine Komponente begrenzt, sondern sich häufig auch auf benachbarte Komponenten auswirkt. Schließlich sind WEA hochdynamische und sehr schwingungsfreudige Systeme, die auch den Naturgewalten unterworfen sind.

10.1.2 Zustandsdaten, technische Daten, zeitbezogene Daten

WEA unterliegen verschiedenen Schwingungseinflüssen (aerodynamisch bedingten Schwingungen, Strukturschwingungen, Körperschallschwingungen etc.). Diese Schwingungsarten sind in der Windbranche extrem wetter- und betriebsabhängig.

Um die oben genannten Phänomene und Abhängigkeiten umfassend zu erkennen, sollten CMS verwendet werden, die Zustandsdaten, technische Daten und zeitbezogene Daten in hoher Datenqualität liefern und verarbeiten können (vgl. Tabelle 10.1).

Tabelle 10.1: Datenkategorien und deren Nutzen für die Diagnostik.

Datenkategorie	Art der Messungen	Fehleridentifikation
Zustandsdaten	Schwingwerte	Ursachenidentifikation
Technische Daten	Technologischer Turbinenzustand	Identifikation von Fehlerauswirkungen
Zeitbezogene Daten	Komponenten- und Turbinenzustände über die Zeit	Fehlerauswirkungen

Zustandsdaten sind Schwingwerte von Triebstrangkomponenten, die verwendet werden, um *Fehlerursachen des Komponentenzustands* (z.B. an Wälzlager, Getriebe oder Generator) zu identifizieren.

Technische Daten dienen der technologischen Beurteilung des Turbinenzustands. Diese Daten werden bspw. zur Leistungscharakterisierung genutzt. Technische Daten dienen der Identifikation von *Fehlerauswirkungen*. Liegt ein Schaden auch in geringfügiger Weise vor, kann dieser Auswirkungen auf

die Leistung der WEA haben, was sich in den technischen Daten zur Charakterisierung der WEA-Leistung abzeichnet, so bspw. zur Beurteilung der Leistungsreduzierung im Fehlerfall.

Zeitbezogene Daten dienen dem zeitbezogenen Vergleich von Komponenten- und Turbinenzuständen, um ebenfalls *Fehlerauswirkungen* zu erkennen. Zeitbezogene Daten zeigen bspw. Trends über die Zeit an. Zeitbezogene Daten können sowohl aus Zustandsdaten errechnet werden (kontinuierlicher Anstieg von Amplituden bei Schadensfrequenzen) als auch für technische Daten (kontinuierlicher Abstieg der Leistungsausbringung).

Für alle drei Datenkategorien muss eine entsprechende Datenqualität vorliegen, damit korrekte Aussagen getroffen werden können. Eine hohe Datenqualität bedeutet für Zustandsdaten eine Abtastung von 0Hz bis zu 30kHz, um auch schnelle Änderungen im Zeitsignal, z.B. bei Stoßimpulsen vorgeschädigter Wälzlager, zu erkennen. Technische Daten und Zeittrendsignale sollten sekundlich abgetastet werden, um bspw. bei WEAs auch turbulenzbedingte Änderungen zu erfassen. In der Windbranche ist dies derzeit nicht der Fall und es wird meist nur mit 10-minütig erfassten Daten gearbeitet. Dadurch gehen jedoch viele Informationen verloren, die nutzbringend für die Diagnostik, aber auch für die Leistungssteigerung der WEA sind.

Im Folgenden werden Ergebnisse von Messungen gezeigt, bei dem das CMS VIBGUARD® [PT18] über mehrere Monate lang Daten von WEA im Sekundenbereich und mit den geforderten Frequenzen aufgezeichnet hat. Es zeigen sich interessante Phänomene, bspw. Wettereinflüsse auf die WEA oder Resonanzfrequenzen von Turm, Gondel und Triebstrangkomponenten bzw. deren Beeinflussungen untereinander, die mit vergleichbaren CMS und geringerer Datenqualität nicht erfasst werden können.

10.2 CMS kann mehr als nur Zustandsdaten zu liefern

Zur Leistungserzeugung bei WEAs dient der Wind, der aber konterkariierend dazu auch einer der größten Einfluss- und Störfaktoren auf das Lauf-, Betriebs- und Schwingungsverhalten der gesamten WEA ist. Er wirkt sich in allen Bereichen auf Zustandsdaten einer WEA aus, vor allem während Turbulenzen. Burton et al. [BJ+11] haben die Windgeschwindigkeit als spektrale Darstellung (vgl. Abbildung 10.4) ausgewertet. Windturbulenzen zeigen sich nicht im 10 Minuten Intervall, sondern kurzzeitiger im Bereich von 10 Sekunden bis 5 Minuten. Dies bedeutet zugleich, dass wenn die Windgeschwindigkeit wie üblich lediglich im 10-Minuten Takt aufgezeichnet wird sehr viele Informationen über den Wind verloren gehen.

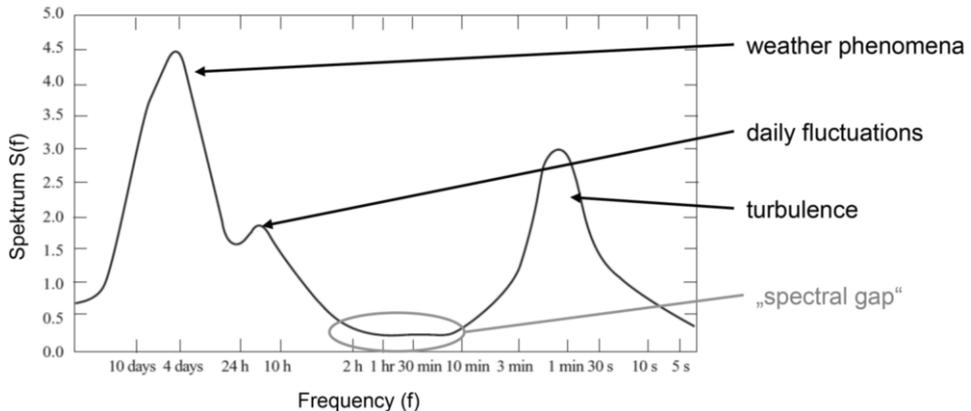


Abbildung 10.4: Spektrale Darstellung der Windgeschwindigkeitsänderungen [BJ+11].

Aus diesen kurzzeitigen Windgeschwindigkeitsänderungen resultieren aber aerodynamische Stöße, Eigenschwingungen am Triebstrang oder einfach mehr Schwingbeanspruchungen, die bisher infolge der 10-minütigen Erfassung von Daten unberücksichtigt bleiben. Ändert sich zusätzlich kurzzeitig die Windrichtung, werden die Rotorblätter quer angeströmt, was zu mehr Biegebelastungen und kurzzeitiger Unwucht am Triebstrang führen. Dadurch können Schwingungssensoren einen Alarm auslösen, der nicht auf kurzzeitige Schwankungen der Windgeschwindigkeit zurückzuführen ist.

Die systematische Erfassung von Turbulenzen und die Betrachtung der Auswirkungen von Turbulenzen auf die Triebstrangkomponenten und auch auf die WEA findet derzeit noch keine Betrachtung. Condition Monitoring Systeme (CMS) messen (nach DNV GL) lediglich in zwei Betriebszuständen (geringe und hohe Leistungsausbringung) und zeichnen innerhalb der Betriebszustände lediglich einen kurzen Zeitraum auf, um die Amplitudenspektren zu berechnen. Dies ist ein bewährtes Vorgehen, hat aber auch Nachteile. Wie in Abbildung 10.4 dargestellt treten Turbulenzen häufig kurzzeitig auf. Turbulente Effekte werden jedoch vom CMS nur erfasst, wenn:

1. das System sich in einem der beiden Betriebszustände befindet,
2. die Turbulenzen während des kurzen Aufzeichnungsintervalls auftreten,
3. die Drehzahl während der Aufzeichnung nicht zu stark schwankt, da sonst die Messung vom CMS abgebrochen wird und
4. die Windgeschwindigkeit mindestens zeitgleich im 10 Sekundentakt mit aufgezeichnet wird.

Überhaupt nicht erfasst und ausgewertet werden häufig dynamische Einflüsse von Windgeschwindigkeit und Windrichtung. Jedoch gilt, *was in den Daten nicht erfasst wurde, kann auch bei der Analyse nicht berücksichtigt werden.* Eine kontinuierliche hochfrequente Datenaufzeichnung ist aus diesem Grund empfohlen. Die kontinuierliche Datenaufzeichnung bringt einige Vorteile, die in den folgenden Unterkapiteln mit praktischen Beispielen gezeigt werden. Zugleich wird dargestellt, wie sich die hohen Datenmengen effizient auswerten lassen.

10.2.1 Kontinuierliche Datenaufzeichnung zur ganzheitlichen Anlagenbeurteilung

Im vorherigen Abschnitt wurde dargestellt, dass CMS klassischer Weise nur kurzzeitig Daten aufzeichnen, um Schwingungsspektren zu berechnen. Außerdem wurde gezeigt, wie sich Windgeschwindigkeit und -richtung auf Schwingungswerte von Triebstrangkomponenten und auch auf die WEA auswirken, jedoch durch die intervallbasierte Datenaufzeichnung häufig nicht erfasst werden. In diesen Abschnitt sollen die Vorteile einer kontinuierlichen Datenaufzeichnung gezeigt werden. Es werden Beispiele von Monitoringprojekten gezeigt, bei denen Daten kontinuierlich erfasst und aufbereitet wurden.

Im Abbildung 10.5 wird der „dynamische“ Zusammenhang zwischen Generatorleistung (Ordinate) und der Windgeschwindigkeit (Abszisse) mit sekundlicher Aufzeichnung der Parameter dargestellt. Die Daten wurden auf einer 2,3 MW WEA kontinuierlich mehrere Monate lang mit einem VIB-GUARD® aufgezeichnet. Zusätzlich ist in Abbildung 10.5 farblich kodiert, wie häufig ein Wert während der kontinuierlichen Aufzeichnung im jeweiligen Zeitintervall durchfahren wurde.

Bei 10-minütiger Erfassung (oder entsprechender Mittelwertbildung) würde diese Leistungs-Windgeschwindigkeits-Kennlinie mehr einer Linie ähneln [Me18].

Abbildung 10.5 zeigt dagegen Varianzen der Leistungsausbringung bezogen auf eine Windgeschwindigkeit. Derartige Analysen mittels xy-Darstellung zeigen auf einem Blick, dass Potential besteht, um mehr Effizienz aus der WEA zu holen. Es ist ebenso ersichtlich, dass die Anlage zeitweise nicht produziert hat. Des Weiteren kann der Einfluss von Turbulenzen im Detail analysiert werden. Rückschluss auf Turbulenzen geben die hohen Schwankungen der Windgeschwindigkeit. Hierbei werden die Daten vom CMS dynamisch

selektiert, die während Turbulenzen aufgezeichnet wurden. Eine Tiefendiagnose der Schwingwerte kann Aufschluss über die Zustandsdaten und die technologischen Daten liefern. Die aufgezeichnete Leistungskennlinie lässt also sehr gut grundlegende Rückschlüsse auf die Optimierungspotentiale der WEA zu.

Auch bei der Identifikation von Resonanzbereichen hilft die kontinuierliche Datenaufzeichnung. Eine Resonanz entsteht, wenn eine Erregerfrequenz eine Eigenfrequenz des Systems trifft. Wenn eine WEA in Resonanz betrieben wird, können frühzeitig Schäden an Triebstrangkomponenten entstehen. Für eine Lebensdauer verlängernde Betriebsweise von WEA müssen Resonanzbereiche bekannt sein. Das dauerhafte Betreiben von WEAs in Resonanzbereichen ist dann zu vermeiden bzw. Resonanzbereiche sollten schnell durchfahren werden.

Erschwerend kommt jedoch hinzu, dass jede Komponente und auch der Turm, die Gondel und die Rotorblätter etc. jeweils individuelle Resonanzbereiche haben, so dass Auswertungen hinsichtlich Resonanzen an mehreren Messpunkten stattfinden sollten.

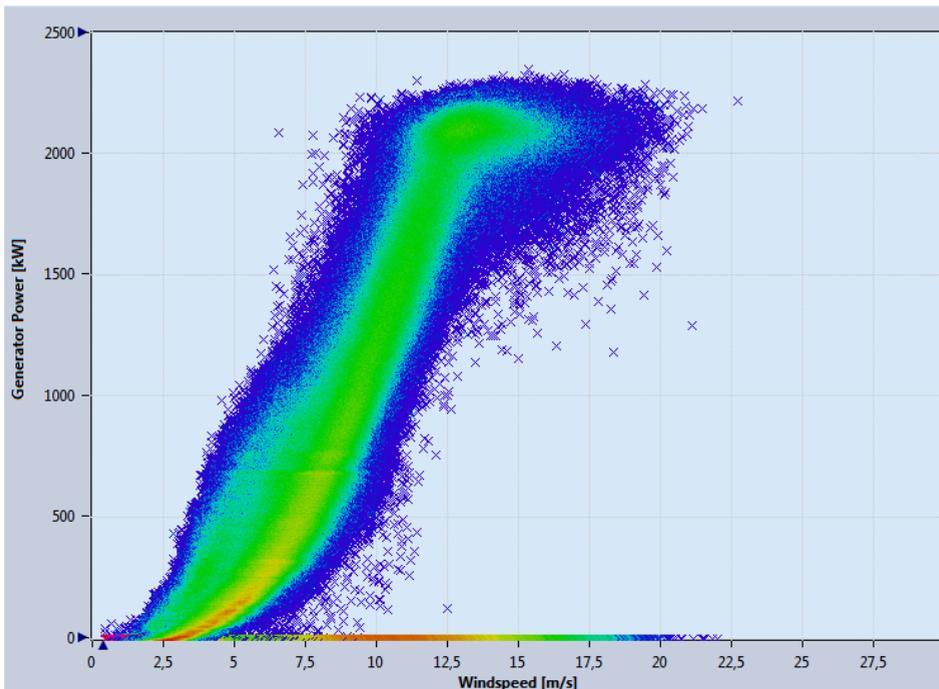


Abbildung 10.5: Darstellung der Generatorleistung zur jeweiligen Windgeschwindigkeit einer WEA mit Kodierung der Häufigkeit eines Wertes.

Bei der Identifikation aller Resonanzbereiche hilft eine kontinuierliche Datenaufzeichnung ebenso. In Abbildung 10.6 sind beispielhaft solch kontinuierlich aufgezeichneten Daten dargestellt. Die Daten sind Schwingwerte der Beschleunigung der angetriebenen Generatorseite (Ordinate) und werden der Generatorfrequenz (Abszisse) gegenübergestellt. Es zeigen sich bei höheren Drehzahlen gleich mehrere Resonanzen, die erregt werden, jedoch amplitudenmäßig im Vergleich zur VDI 3834 [VDI15] tolerierbar sind. Die größte Resonanz (bei etwa 1550 RPM) hat Amplituden von über 4 m/s^2 . Diese Amplitude liegt in einem Bereich, der tendenziell zu überwachen ist, was anhand solcher xy-Darstellungen relativ einfach kontrollierbar ist. Solche Resonanzbereiche könnten aber auch aus dem CMS extrahiert werden und bspw. für die Steuerungsprogrammierung verwendet werden, um die Regelung hinsichtlich der Resonanzbereiche anzupassen.

10.2.2 Generatordrehzahl und Generatorleistung

In der Windbranche hat sich zur Charakterisierung von WEA der gegenüberstellende Vergleich der Windgeschwindigkeit zur entsprechenden Anlagenleistung etabliert (vgl. Abbildung 10.5). Bei der Charakterisierung von WEA hat sich im Monitoring Center der PRÜFTECHNIK AG die xy-Darstellung der Generatordrehzahl zur Anlagenleistung bewährt (vgl. [DB17], Abbildung 10.7). Damit lässt sich das Verhalten der WEA selbst besser charakterisieren. Außerdem schwankt trägheitsbedingt die Drehzahl weniger häufig, wodurch sich bei kontinuierlicher Aufzeichnung eindeutige und klare Leistungs-Drehzahlkennlinien ergeben.

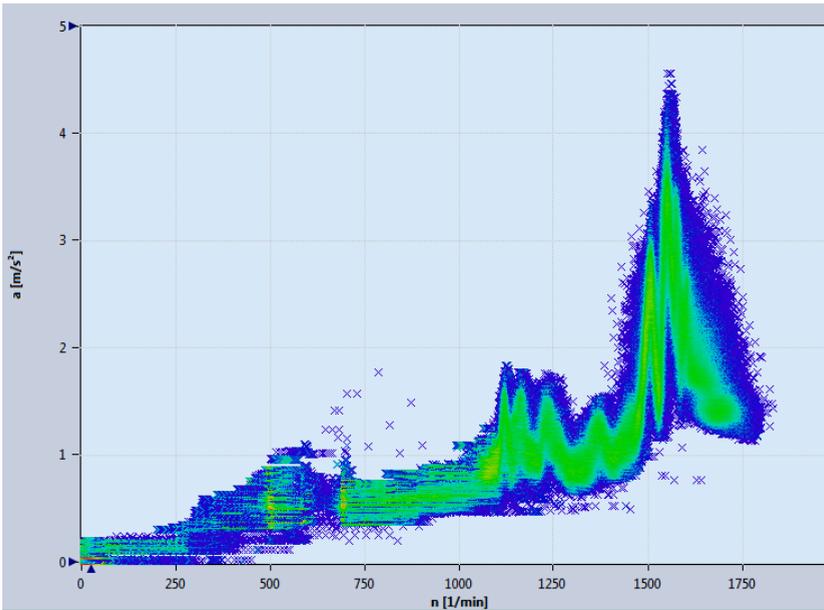


Abbildung 10.6: Darstellung der Generatorschwingung zur jeweiligen Generatordrehzahl einer WEA.

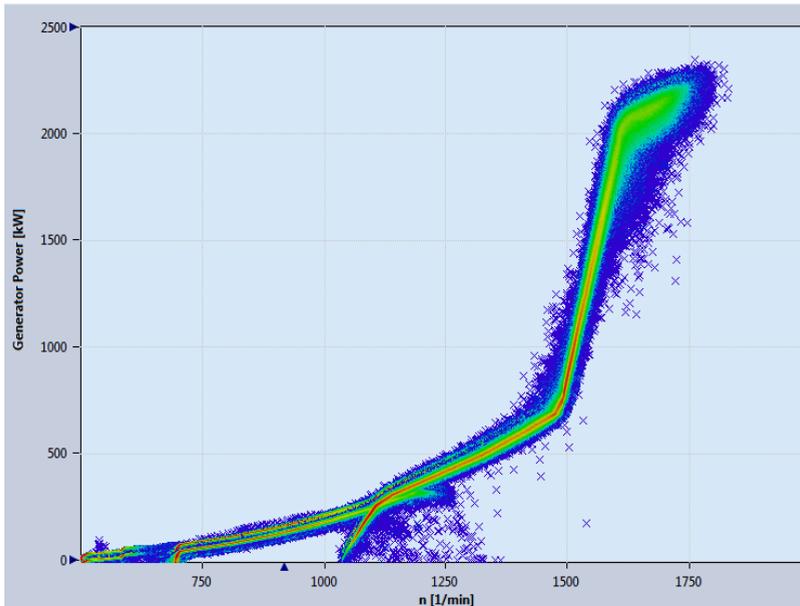


Abbildung 10.7: Darstellung der Generatorleistung zur jeweiligen Drehzahl einer WEA mit farblicher Kodierung der Häufigkeit eines Werte.

10.2.3 Quer- und Längsschwingungen liefern wertvolle Daten

Heutzutage werden WEA mit einer Nabenhöhe bis über 160 Metern errichtet. Gleichzeitig gibt es individuelle Quer- und Längsschwingungen und Eigenschwingungen der verschiedenen Turmtypen. Die Windgeschwindigkeiten sind je nach Höhe über Grund ebenfalls sehr unterschiedlich und es haben auch die verschiedenen Turmtypen verschiedene Effekte. Durch die unterschiedlichen Windgeschwindigkeiten, je nach Höhe über Grund, sind die auf den Turm und die Gondel wirkenden Kräfte ebenfalls sehr unterschiedlich, wodurch Querschwingungen von Turm und Gondel unangenehmen Effekten unterworfen werden. Somit ist es auch für Turm- und Gondelschwingungen empfehlenswert, durch kontinuierliche und hoch abgetastete Datenaufzeichnung kritische Drehzahlbereiche der WEA zu identifizieren und zu überwachen.

In Abbildung 10.8 wird eine kontinuierliche Datenaufzeichnung der Quer- (a) und Längsschwingungen (b) am Hauptlagermesspunkt dargestellt. Sekundlich wurden Datenpunkte abgetastet und das Gondelverhalten hinsichtlich der Bewegungen identifiziert. Da sich die Schwingungssensoren am Erdmittelpunkt orientieren ist in Windrichtung (Abbildung 10.8, b) sogar das Verkippen der Gondel in Abhängigkeit von der Rotordrehfrequenz erkennbar. Zugleich sind aus diesen Darstellungen auch die Turmbewegungen bei stehender WEA erkennbar (linker Rand der Abbildung 10.8 a und b).

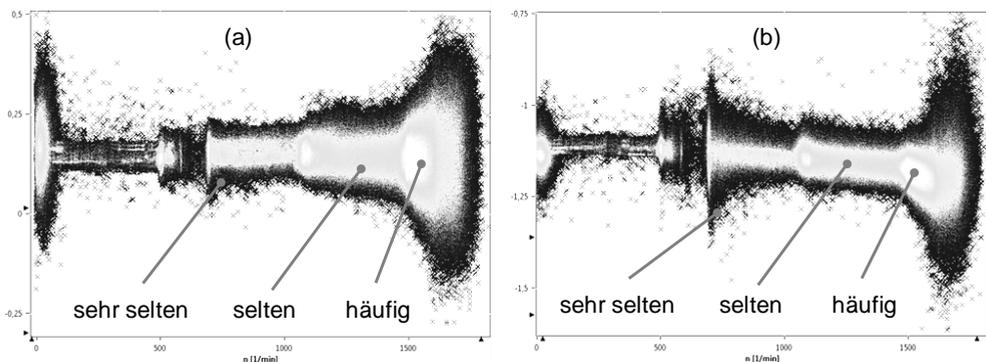


Abbildung 10.8: Quer- und Längsschwingungen der Gondel (mit Sensoroffset zum Erdmittelpunkt) in Abhängigkeit von der Generator-drehzahl (in Umdrehungen pro Minute).

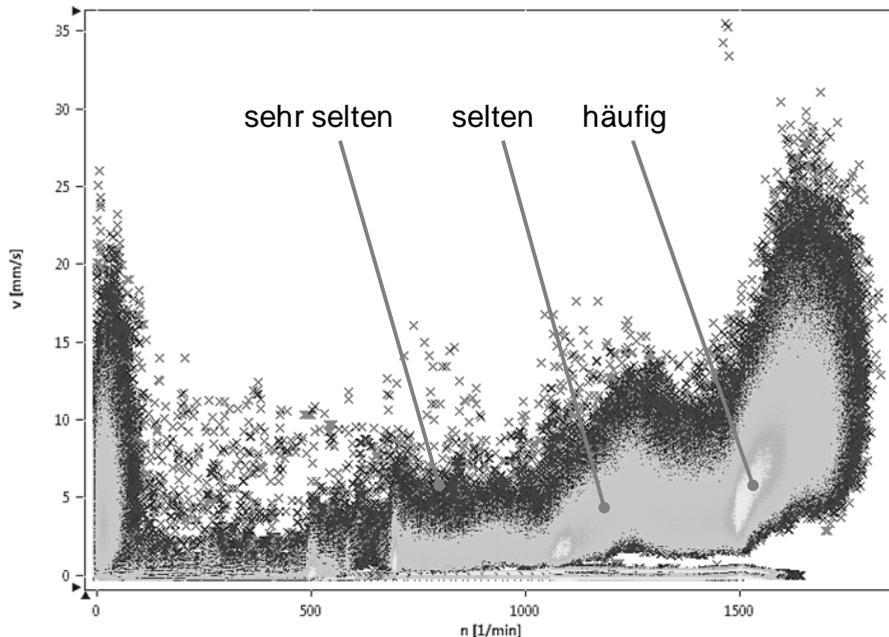


Abbildung 10.9: Schwinggeschwindigkeiten am Hauptlager zur Identifikation von Resonanzbereichen.

Um nun quantitativ die Schwingungen mittels Kennwerten [Me18, VDI15] in Bezug zu Richtlinien und Normen zu beurteilen, werden parallel im VIB-GUARD[®] auch die jeweiligen Schwinggeschwindigkeiten ermittelt und kontinuierlich aufgezeichnet. Eine beispielhafte xy-Darstellung ist als Abbildung 10.9 gezeigt. Auch hier lassen sich Resonanzbereiche identifizieren und die daraus resultierenden Schwinggeschwindigkeiten bewerten. Die Resonanzen sind laut VDI 3834 [VDI15] bzw. ISO 10816-21 [ISO15] für das Beispiel im zulässigen Bereich. Jedoch darf die WEA nicht lange in den Resonanzbereichen betrieben werden, da es sonst durch die höheren Belastungen die Lebensdauer der Komponenten reduziert wird. Bestenfalls müssen Resonanzbereiche schnell durchfahren werden.

10.3 Zusammenfassung

Daten einer Windenergieanlage (WEA) werden nicht nur zur Bewertung von Triebstrangzuständen aufgezeichnet, sondern sie lassen sich auch zur zeitnahen Ableitung von Optimierungsmaßnahmen in der WEA selbst nutzen. Schwierig ist es jedoch, die immensen Datenmengen von der WEA in eine Cloud zu übertragen und in eine gemeinsame Datenbasis zu integrieren. Edge-Computing bedeutet, eine dezentrale Datenverarbeitung, direkt auf der

WEA. Das Condition Monitoring System VIBGUARD® der PRÜFTECHNIK AG ist hierzu bereits imstande.

In diesem Beitrag wurden beispielhafte Ergebnisse von VIBGUARD®-Installationen gezeigt. Betriebs- und Schwingungsdaten wurden sekundlich aufgezeichnet. Es wurde gezeigt, dass die Wetterbedingungen und vor allem Turbulenzen starken Einfluss auf die charakteristische Leistungskennlinie und auch auf die Schwingungen haben.

Literatur

- [DB17] M. Dietl, E. Becker. „Systematisches Flotten-Monitoring auf Basis von Condition-Monitoring an Windenergieanlagen,“ in Fachtagung Schwingungen von Windenergieanlagen 2017.
- [PT18] <https://www.pruftechnik.com/products/condition-monitoring-systems/online-condition-monitoring-systems/vibguard.html>, aufgerufen am 19.03.2018.
- [BJ+11] T. Burton, N. Jenkins, D. Sharpe, E. Bossanyi. “Wind Energy Handbook”, 2nd Auflage; Wiley; 2011.
- [Me18] P.-H. Meier. „Effizienzschübe mit Apps und Co,“ in Erneuerbare Energien 02/2018, S. 50-51, 2018.
- [VDI15] Verein Deutscher Ingenieure (VDI). „Messung und Beurteilung der mechanischen Schwingungen von Windenergieanlagen und deren Komponenten - Windenergieanlagen mit Getriebe.“ VDI/VDR Richtlinie 3834, 2015.
- [ISO15] International Organization for Standardization (ISO). “Mechanical vibration - Evaluation of machine vibration by measurements on non-rotating parts - Part 21: Horizontal axis wind turbines with gearbox,” ISO Standard 10816-21, 2015.
- [ISO14] International Organization for Standardization (ISO). “Condition monitoring and diagnostics of machines -- Requirements for qualification and assessment of personnel - Part 2: Vibration condition monitoring and diagnostics.” ISO Standard 18436-2, 2014.
- [PF+17] T. Pötter, J. Folmer, B. Vogel-Heuser. „Enabling Industrie 4.0 – Chancen und Nutzen für die Prozessindustrie,“ in Handbuch Industrie 4.0 Bd. 4 (Hrsg. B. Vogel-Heuser, T. Bauernhansl, M. ten Hompel), S. 71-83, 2017.

11 Intelligente Interfaces zur effektiven Wartung

F. Loch, Prof. Dr.-Ing. B. Vogel-Heuser

*Lehrstuhl für Automatisierung und Informationssysteme,
Technische Universität München, Garching bei München
{loch, vogel-heuser}@tum.de*

11.1 Einführung und Motivation

Maschinenbediener bleiben ein wichtiger Bestandteil zukünftiger Automatisierungsumgebungen. Ihre Aufgabe ist es, im Zusammenspiel mit zunehmend intelligenten und autonomen Produktionsanlagen die optimale Produktionsstrategie festzulegen, zu überwachen und im Fehlerfall einzuschreiten. Es ist, unabhängig von der weiteren Entwicklung in der Automatisierungstechnik, absehbar, dass die Wartung von Produktionsmitteln sowie die Fehlerbehebung weiterhin eine Kernaufgabe der Mitarbeiter in der Produktion darstellen wird, da diese kaum automatisiert werden können. Es ist außerdem zu erwarten, dass die Komplexität dieser Prozesse zunehmen wird [BD+17]. Die Mitarbeiter in der Produktion benötigen also zunehmend intelligente und flexible Systeme, die sie bei der Durchführung dieser Prozeduren bedarfs- und situationsgerecht anleiten und unterstützen. Die Verfügbarkeit solcher Systeme sichert eine zügige und fehlerfreie Durchführung der Prozeduren und stellt so eine hohe Verfügbarkeit und Produktivität der Produktionsanlagen sicher.

Neben der steigenden Komplexität und Digitalisierung der Produktionsanlagen, beeinflusst auch der globale Trend des demographischen Wandels sowie die Globalisierung die produzierende Industrie. Das steigende Alter der Belegschaft ist bereits in heutigen Fertigungsumgebungen sichtbar. Eine Fallstudie beschreibt, wie sich das durchschnittliche Alter der Belegschaft einer Fabrik zur Herstellung von Fahrzeugen innerhalb von 8 Jahren von 40.3 auf 47.5 erhöht hat [SV09]. Die sich kontinuierlich erhöhende Lebensarbeitszeit, zum Beispiel durch das steigende Renteneintrittsalter [BK16], trägt ebenfalls zu diesen Veränderungen bei. Angepasste Systeme für das Training und die Unterstützung von älteren Mitarbeitern sind unverzichtbar, um die Wettbewerbsfähigkeit der produzierenden Industrie zu erhalten [RH09]. Zudem muss durch die globalisierte Produktion eine zunehmende Vielzahl von Mitarbeitern unterschiedlicher Fähigkeiten und Erfahrungen (z.B. Sprache, Schulbildung, Ausbildung) von Systemen zum Training und zur Assistenz unterstützt werden, um eine effiziente Produktion zu gewährleisten.

Eine Vielzahl unterschiedlicher Systeme zur Unterstützung von Mitarbeitern in der Produktion wurde bereits entwickelt und findet zunehmend Anwendung in der Industrie. Ein Schwerpunkt sind Systeme, die auf Augmented Reality (AR) basieren, und ein Bild der realen Arbeitsumgebung mit graphischen oder textuellen Arbeitsanweisungen überlagern. So können visuelle Anweisungen verständlich und direkt am Ort der Tätigkeit eingeblendet werden. Weitere Assistenzsysteme basieren auf sprach-basierten Anweisungen und ermöglichen es, Mitarbeiter mit minimaler Ablenkung bei den Tätigkeiten zu unterstützen.

Existierende Assistenzsysteme fokussieren sich für gewöhnlich auf eine spezifische Ausgabetechnik und sind somit wenig flexibel. Aber gerade die Kombination verschiedener Ausgabetechniken ermöglicht es erst, Mitarbeiter während unterschiedlicher Arbeitsaufgaben optimal zu unterstützen. Bei komplexen Montagetätigkeiten können mittels Augmented Reality detailierte Informationen eingeblendet werden, wohingegen sprach-basierte Interaktion bei der Durchführung einfacherer oder bekannterer Tätigkeiten eingesetzt werden kann. Zudem kann die Unterstützung an die Anforderungen des Mitarbeiters angepasst werden. So kann ein unerfahrener Mitarbeiter mit einer multimedialen Beschreibung, mit der er sich zunächst abseits des Arbeitsprozesses mit einer Tätigkeit vertraut machen kann, unterstützt werden, wohingegen einem erfahrenen Mitarbeiter eine reduziertere sprach-basierte Unterstützung angeboten werden kann. Dieser Beitrag beschreibt ein Konzept für ein solches Assistenzsystem. Das System kombiniert verschiedene Techniken, um eine situations- und nutzerangepasste Assistenz bereitzustellen.

Dieser Beitrag ist wie folgt aufgebaut: Zunächst wird der Stand der Technik von Assistenzsystemen für Wartungs- oder Montageprozeduren beschrieben. Dabei werden die Vor- und Nachteile sowie die Einsatzmöglichkeiten von AR-basierter, sprach-basierter und experten-basierter Assistenz beschrieben. Danach werden ein beispielhafter Anwendungsfall und der industrielle Nutzungskontext in dem das System zum Einsatz kommen soll beschrieben, um Anforderungen an ein Assistenzsystem für den industriellen Einsatz abzuleiten. Folgend wird ein Konzept eines Systems beschrieben, mit dem die Vorteile der einzelnen Systeme kombiniert und Schwächen kompensiert werden können. Die Beschreibung einer Beispielsapplikation und eine Zusammenfassung schließen diesen Beitrag.

11.2 Stand der Technik

Dieser Abschnitt beschreibt verfügbare Systeme für die Unterstützung von Mitarbeitern während manueller Wartungs- und Instandhaltungsprozeduren. Zunächst werden in Abschnitt 11.2.1 Systeme beschrieben, die Augmented Reality zur Darstellung von Anweisungen verwenden. Sprach-basierte Assistenzsysteme sind für erfahrene Bediener, oder während manueller Tätigkeiten gut einsetzbar (siehe Abschnitt 11.2.2). Hypermedia-basierte Ansätze liefern multimediale Unterstützung, zum Beispiel auf Basis von HTML-Systemen (siehe Abschnitt 11.2.3). Experten-basierte Systeme erlauben es, flexibel Unterstützung von Kollegen am Standort oder standortübergreifend zu erhalten (siehe Abschnitt 11.2.4).

11.2.1 Augmented Reality

AR wird zunehmend in der technischen Dokumentation und der Anleitung von Mitarbeitern in der Industrie eingesetzt. Die graphischen AR-Anleitungen ermöglichen eine Reduzierung der Sprachabhängigkeit und eine einfachere Verständlichkeit auch für unerfahrene Mitarbeiter durch die Anreicherung mit Animationen. Gerade AR ermöglicht es Informationen genauer dort darzustellen wo sie benötigt werden [MN+17]. Die Möglichkeiten von AR in der industriellen Anwendung wurden von Forschungsprojekten (z.B. AmbiWise [QL+17], Cyber System Connector [MN+17]) für Anwendungen in der Instandhaltung oder der Montage adressiert. Zunehmend finden sich auch industrielle Anwendungen und Fallstudien, zum Beispiel in der Wartung bei Volkswagen (siehe Abbildung 11.1) [VW18]. Evaluationen zeigen Vorteile für den Einsatz von AR im Vergleich zu traditionellen Methoden der Assistenz, zum Beispiel papier-basierten Ansätzen [QL+17].



Abbildung 11.1: Beispielhaftes AR-basiertes System von VW [VW18].

11.2.2 Sprach-basierte Assistenzsysteme

Sprach-basierte Assistenz ist insbesondere dann von Nutzen, wenn Mitarbeiter während manueller Prozeduren unterstützt werden sollen, da durch sprach-basierte Assistenz minimale visuelle Ablenkung von der eigentlichen Arbeitsaufgabe entsteht. Ein System zur Sprachassistenz, welches sich einfach an die Erfordernisse eines Anwendungsfalls und einer Benutzergruppe anpassen lässt, wird von Loch et al. [LM+18] beschreiben.

11.2.3 Hypermedia-basierte Assistenz

Hypermedia bezeichnet multimedialen Inhalt, der, im Gegensatz zu einem Buch, nicht sequenziell angeordnet ist, sondern es dem Leser ermöglicht selbst zu entscheiden in welcher Reihenfolge er die Inhalte konsumieren möchte [Ni96]. Diese Art der Anleitung findet nicht nur auf Internetseiten Anwendung, sondern kann auch zur Unterstützung von Mitarbeitern in der Produktion eingesetzt werden. Quint et al. [QL+16] beschreiben Ergebnisse aus dem Forschungsprojekt AmbiWise, bei dem Expertenwissen und Abläufe von Prozeduren als Hypermedia gespeichert wurden. Die geräteunabhängige Art der Darstellung ermöglicht zahlreiche Nutzungsszenarien, so kann das System auch auf dem Endgerät des Nutzers zur selbstgesteuerten Weiter- und Fortbildung verwendet werden.

11.2.4 Experten-basierte Assistenz

Nicht immer können technische Systeme allein den Benutzer optimal unterstützen. Gerade Fachwissen („Know-How“), das erfahrene Mitarbeiter über längere Zeit erwerben, lässt sich nur schwer formalisieren, da es an den jeweiligen Mitarbeiter als Wissensträger gebunden ist. Eine Reihe von Projekten beschäftigt sich mit Systemen, die es ermöglichen Expertenwissen einfacher zu speichern und Mitarbeitern zugänglich zu machen. Das Forschungsprojekt AmbiWise entwickelte ein System, mit dem Experten zum Beispiel Videos von Tätigkeiten aufnehmen und beschreiben können [QL+17]. Im Forschungsprojekt INCLUSIVE entsteht ein soziales Netzwerk, mit dem Mitarbeiter gezielt Unterstützung von Experten mit passendem Kompetenzprofil suchen und erhalten können [VS+18]. Im Projekt IMPORVE wurde eine Methode zur Erhebung und Darstellung von Expertenwissen in so genannten Ursachen-Wirkungs-Diagrammen entwickelt [VK+17].

11.3 Anwendungsfall

Im Folgenden sollen die Rahmenbedingungen eines exemplarischen Anwendungsfalles besprochen werden.

11.3.1 Beschreibung des Anwendungsfalles

Im Folgenden wird ein beispielhafter Anwendungsfall beschrieben, der im Rahmen eines Demonstrators umgesetzt wurde. Dieser Anwendungsfall soll sich möglichst an den Eigenschaften realistischer Wartungsprozeduren orientieren. Typische Wartungsprozesse, wie sie zum Beispiel im Rahmen des Projekts INCLUSIVE adressiert werden, zeichnen sich dadurch aus, dass Sie aus manuellen Tätigkeiten (z.B. dem Entfernen einer Komponente), Inspektionsaufgaben (z.B. dem Prüfen eines korrekten Sensorwertes), sowie aus Tätigkeiten, die an der Benutzungsoberfläche der Maschine durchgeführt werden, (z.B. zur Wiederaufnahme der Produktion) bestehen. Für einen Demonstrationsaufbau wurde eine Wartungsprozedur an einem Lego Mindstorms-Roboter (siehe Abbildung 11.2) ausgewählt und umgesetzt.

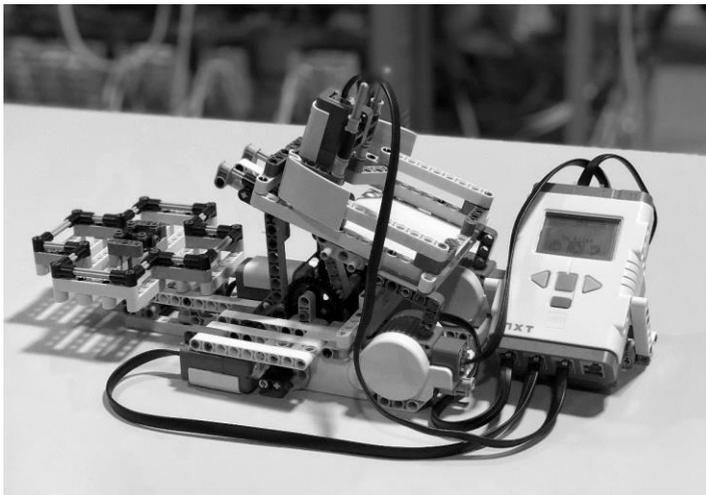


Abbildung 11.2 Verwendeter Lego-Roboter zur Demonstration.

Die Teilschritte der Beispielprozedur sind folgend beschrieben.

1. Demontieren Sie die zwei Buchsen.
2. Demontiere Sie den Farbsensor.
3. Starten Sie das Userinterface mit dem orangenen Knopf.
4. Wählen Sie das Untermenü ‚Views‘ aus.
5. Wählen Sie das Untermenü ‚Colors‘ aus.

6. Wählen Sie den Port aus mit dem der Farbsensor verbunden ist.
7. Halten Sie den Farbsensor 1cm über eine Farbe der Farbpalette.
8. Der Name der Farbe erscheint auf dem Display.
9. Montieren Sie den Farbsensor.
10. Montieren Sie die zwei Buchsen.

11.3.2 Anforderungen aus der Anwendungsumgebung

Die Betrachtung des späteren Nutzungskontexts ist unerlässlich, um eine gebrauchstaugliche Benutzungsoberfläche zu entwickeln. Dieser setzt sich zusammen aus den Eigenschaften der Benutzer (z.B. Konstitution, Qualifikation und Kompetenz) und seinem momentanen Zustand (z.B. Belastung). Zudem werden technische (z.B. eingesetzte Geräte) und physikalische Rahmenbedingungen (z.B. Bedingungen am Arbeitsplatz, notwendige Schutzausrüstung) mit einbezogen [Ma01]. Diese Herangehensweise stellt sicher, dass die entwickelten Assistenzsysteme in der späteren Anwendungsumgebung sicher und effizient eingesetzt werden können. In den folgenden Abschnitten werden relevante Aspekte des industriellen Nutzungskontexts beschrieben.

Benutzereigenschaften. Wartungsprozesse werden für gewöhnlich von angelernten Maschinenbedienern durchgeführt. Diese verfügen über fundierte Erfahrungen mit der Maschine, aber oft über keine technische Ausbildung. In diesem Berufsfeld werden Mitarbeiter mit unterschiedlicher Herkunft eingesetzt, so dass unterschiedliche Sprachkenntnisse vorhanden sind und unterstützt werden müssen. Maschinen werden zunehmend auch an global verteilten Standorten eingesetzt, so dass auch das geringere Bildungsniveau der Mitarbeiter in Entwicklungsländern von einem Assistenzsystem berücksichtigt werden muss.

Physikalische Rahmenbedingungen. Der Wartungsprozess wird in einer Umgebung durchgeführt, die den Einsatz anderer Assistenzsysteme nicht zulässt oder stark erschwert. Die vorliegenden Umwelteinflüsse, wie etwa Staub, Flüssigkeit oder der beengte Raum, schließe den Einsatz anderer Systeme zur Assistenz (z.B. Handbücher, oder touch-basierte Geräte) aus. Denn diese verschmutzen oder lenken von der Arbeitsaufgabe und der Beobachtung der industriellen Umgebung ab. Zudem können diese Assistenzsysteme nicht während der Arbeitsaufgabe eingesetzt werden, da sie die Unterbrechung der manuellen Tätigkeit verlangen. Zudem ist die Umgebung, in der das System eingesetzt wird sehr laut.

11.4 Entwicklung eines Systems zur Intelligenten Wartungsunterstützung

Im folgenden Abschnitt wird ein System zur intelligenten Unterstützung eines Mitarbeiters in einem Wartungsprozess beschrieben, das im Forschungsprojekt INCLUSIVE¹⁵ entwickelt und bei industriellen Anwendungspartnern erprobt wird. Die zu Grunde liegende Idee ist, dass nur eine Kombination unterschiedlicher Ein- und Ausgabetechniken eine effektive sowie situations- und nutzerangepasste Unterstützung ermöglicht. Abbildung 11.3 zeigt das Zusammenspiel der unterschiedlichen Unterstützungsmöglichkeiten.

Die angebotenen Techniken unterscheiden sich in der Detaillierung, die zur Unterstützung bereitgestellt wird. Dies kann zunächst *während des Arbeitsprozesses* an der Maschine geschehen. Hierfür ist eine unaufdringliche Art der Informationsdarstellung notwendig, die nicht von der eigentlichen Arbeitsaufgabe ablenkt (z.B. sprach- oder AR-basierte Assistenz). Weiterhin kann Assistenz *an der Maschine* aber außerhalb des Arbeitsprozesses angeboten werden, zum Beispiel durch Anleitungen, die auf der Benutzungsschnittstelle der Maschine angezeigt werden können. Weiterhin können Systeme das Wissen von Experten zugänglich machen (z.B. durch Fernwartung oder in soziales Netzwerk). Die Menge an Informationen die durch die Systeme transportiert und vom Benutzer aufgenommen werden kann, nimmt mit der Entfernung vom Prozess graduell zu.

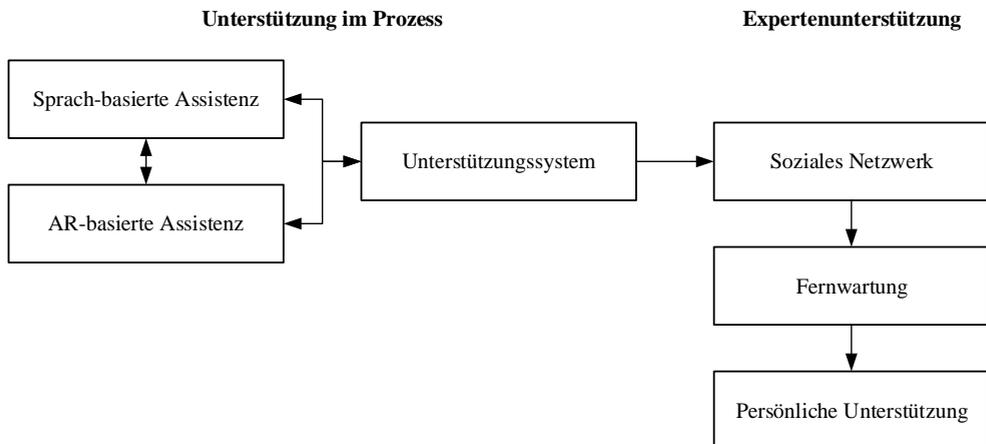


Abbildung 11.3: Zusammenspiel der Komponenten des Assistenzsystems.

¹⁵Smart and adaptive interfaces for INCLUSIVE work environment, <http://www.inclusive-project.eu/>, aufgerufen am 14.08.2018.

Die Wechsel zwischen den bereitgestellten Komponenten des Assistenzsystems kann je nach Bedarf durch den Nutzer der Applikation durchgeführt werden (siehe Abbildung 11.3). Alle Komponenten des Systems basieren auf Modellen der Prozedur, die von allen Systemkomponenten wiederverwendet werden können. Die folgenden Abschnitte charakterisieren und beschreiben die einzelnen Komponenten des Systems.

11.4.1 Sprach-basierte Assistenz

Sprach-basierte Interaktion ist, wie von Loch et al. [LM+18] beschrieben, eine Interaktionstechnik mit der die Anforderungen industrieller Anwendungsumgebung gut adressiert werden können. Dies ist der Fall, da keine Interaktion mit einer Benutzungsschnittstelle erforderlich ist und da nur eine minimale Ablenkung von der eigentlichen Arbeitsaufgabe erfolgt.

Ein solches System ermöglicht es, die Menge und die Detaillierung der bereitgestellten Assistenz an die Bedürfnisse des Bedieners und seine Kenntnisse anzupassen. Der Einsatz von abstrakten Modellen zur Beschreibung der Prozedur ermöglichen es, Anweisungen unterschiedlicher Detaillierung bereitzustellen. Ein Modell der Benutzereigenschaften erlaubt es, die Art der Sprachausgabe anzupassen, um zum Beispiel verringerte Hörfähigkeiten zu kompensieren. Für Aufgaben, die eine detailliertere Unterstützung erfordern kann die Verwendung von visueller, AR-basierter Assistenz erforderlich sein. Das Interface zur sprach-basierten Assistenz wurde mittels des .NET Frameworks von Microsoft umgesetzt.

11.4.2 AR-basierte Assistenz

AR-basierte Assistenzsysteme (vgl. Abbildung 11.4) ergänzen die Möglichkeit der visuellen Darstellung von Informationen. So kann, im Vergleich zu einem sprach-basierten System, eine größere Bandbreite von Informationen realisiert werden. Durch visuelle Darstellungen von Maschinen und der Verwendung von Animationen können Anweisungen verständlich, klar und sprachunabhängig transportiert werden. Der Nutzer kann über entsprechende Schaltflächen zwischen den Anweisungen navigieren. Für die Implementierung dieser Applikation wurde das Framework Vuforia und die 3D-Engine Unity verwendet. Für die Erkennung der Maschine und die Positionierung des zusätzlich eingeblendeten Inhaltes ist, im Gegensatz zu früheren Lösungen, die Verwendung eines zusätzlichen Markers nicht mehr notwendig. Das

Framework Vuforia bietet eine Applikation, mit der 3D-Scans der betreffenden Maschine erstellt werden können. Diese können dann von AR-Applikationen verwendet werden.

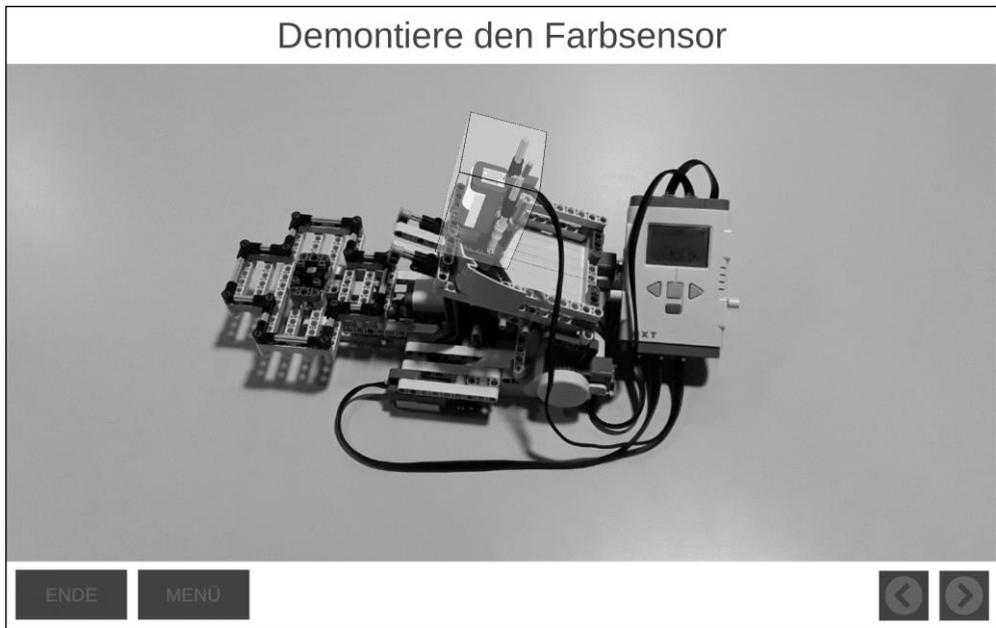


Abbildung 11.4: AR-basiertes Assistenzsystem.

11.4.3 Unterstützungssystem

Das Unterstützungssystem wird auf der HMI der Maschine ausgeführt und beschreibt die Prozedur in Form eines Handbuchs, das um multimediale Inhalte, zum Beispiel Videos, angereichert wird. Die Verwendung eines HTML-basierten Ansatzes ermöglicht es, das System auch auf anderen Endgeräten zur selbstständigen Fortbildung durch den Mitarbeiter außerhalb des eigentlichen Arbeitsprozesses einzusetzen. Abbildung 11.5 zeigt ein beispielhaftes System, das im Forschungsprojekt INCLUSIVE entwickelt wurde. Die Implementierung dieser Komponente erfolgte auf Basis von HTML, CSS, JavaScript und dem frei verfügbaren Web-Frameworks Bootstrap. Mittels spezieller CSS-Dateien lässt sich das System einfach an die Fähigkeiten der Nutzer anpassen. So kann zum Beispiel das Farbschema angepasst werden, um ältere Nutzer mit eingeschränkten Sehfähigkeiten zu unterstützen. Auf dieselbe Weise lassen sich die dargestellten Inhalte anpassen, so dass unerfahrenen Mitarbeiter mit detaillierteren Informationen, zum Beispiel in Form von Videos, versorgt werden können.



Abbildung 11.5: HTML-basiertes Unterstützungssystem.

11.4.4 Expertenunterstützung

Diese Komponente kommt zum Einsatz, wenn keines der vorherigen Systeme erfolgreich zur Problemlösung verwendet werden konnte. Durch ein soziales Netzwerk wird es dem Mitarbeiter ermöglicht, passende Kollegen, die das Problem lösen können, zu suchen und ihnen die Anfrage zu übermitteln [VS+18]. Weitere angebotene Techniken betreffen die Fernwartung, oder eine Unterstützung durch einen Techniker, der auf die bisher durchgeführten Ansätze zur Problemlösung zugreifen kann.

11.5 Zusammenfassung

In diesem Beitrag wurde ein Konzept für ein intelligentes System zur Unterstützung von Mitarbeitern in Wartungsprozessen vorgestellt. Der Grundgedanke des Systems ist die Kombination unterschiedlicher Darstellungstechniken, um Mitarbeiter aufgaben- und fähigkeitsgerecht unterstützen zu können. Es wurde dargestellt, wie Benutzer mit unterschiedlichen Eigenschaften durch die Auswahl der Systeme und deren Anpassung im industriellen Anwendungsumfeld unterstützt werden können. Als Rückfallebene ist eine Unterstützung durch erfahrene Kollegen, zum Beispiel über ein soziales Netz-

werk vorgesehen. So entsteht ein vielseitiges und flexibles System, um Maschinenbediener bei der Durchführung von Wartungsprozeduren optimal zu unterstützen.

11.6 Danksagung

Die beschriebenen Ergebnisse wurden im Projekt "Smart and adaptive interfaces for INCLUSIVE work environment" erarbeitet, das im Rahmen des Grant Agreements Nr. 723373 von der Europäischen Union im Programm "Horizon 2020" gefördert wird.

Literatur

- [BD+17] W. Bauer, B. Dworschak, H. Zaiser, H.: Weiterbildung und Kompetenzentwicklung für die Industrie 4.0. In: B. Vogel-Heuser (Hrsg.), T. Bauernhansl, M. ten Hompel: Handbuch Industrie 4.0 Bd. 1, Springer Vieweg, Deutschland, 2017.
- [BK16] G. Bäcker, L. Kistler: Die Entwicklung der Regelaltersgrenze und der vorgezogenen Altersgrenzen. Bundeszentrale für politische Bildung. <http://www.bpb.de/politik/innenpolitik/rentenpolitik/223218/die-entwicklung-der-altersgrenze>, 2016. (Abgerufen am 20. Mai 2018)
- [LM+18] F. Loch, S. Magerstedt, B. Vogel-Heuser: Nutzerspezifische Assistenz in manuellen Prozeduren mit Hilfe von Sprachinteraktion. In: VDI-Kongress Automation 2018, Baden-Baden, Deutschland, 2018.
- [MN+17] S. Magerstedt, W. Nuding, A. Barthelmey: Prozessanalyse und Design. In: S. Magerstedt (Hrsg.), S. Kuhlenkötter, J. Deuse: Technische Dokumentation: intelligent erstellen und nutzen (Berichte aus dem Maschinenbau), Shaker, Herzogenrath, 2017.
- [Ma01] M. Maguire: Context of Use within usability activities. *International Journal of Human-Computer Studies* 55 (2001) 4, S. 453–483.
- [Ni96] J. Nielsen: Multimedia, Hypertext und Internet. Vieweg, Braunschweig/Wiesbaden, Deutschland, 1996.
- [QL+16] F. Quint, F. Loch, J. Kreutel, P. Pollmanns, H. Weber, J. Venitz, J. Liedel, S. Drissi: Ein Kollaborationssystem zur verbesserten Zugänglichkeit von Wissensressourcen in Produktionsumgebungen. In: USEWARE 2016. Dresden, Deutschland, 2016.
- [QL+17] F. Quint, F. Loch, P. Bertram: The Challenge of Introducing AR in Industry - Results of a Participative Process Involving Maintenance Engineers.

- In: 27th International Conference on Flexible Automation and Intelligent Manufacturing (FAIM2017), Modena, Italien, 2017.
- [RH09] A. Reinberg, M. Hummel: Bildungspolitik: Steuert Deutschland langfristig auf einen Fachkräftemangel zu? IAB Kurzbericht, vol. 9, 2003.
- [VK+17] B. Vogel-Heuser, V. Karaseva, J. Folmer, I. Kirchen.: "Operator Knowledge Inclusion in Data-Mining Approaches for Product Quality Assurance using Cause-Effect Graphs," in 20th IFAC World Congress (IFAC), Jul. 2017, S. 1358-1365.
- [VS+18] V. Villani, L. Sabbatini, A. Levratti, C. Fantuzzi: An Industrial Social Network for Sharing Knowledge Among Operators. In: 16th IFAC Symposium on Information Control Problems in Manufacturing (INCOM). Bergamo, Italien, 2018. (in Druck)
- [SV09] C. K. Streb, S. C. Voelpel: Analyzing the Effectiveness of Contemporary Aging Workforce Management. *Organizational Dynamics*, vol. 38, no. 4, S. 305–311, 2009.
- [VW18] Volkswagen; Mobile Augmented Reality. <http://www.volkswagen.com/de/group/research/virtual-technologies.html> (Abgerufen am 21. Mai 2018).

12 Container basierte KI, ein Lösungsansatz

Dr. A. Binder
SAMSON Pilotentwicklung GmbH
abi@s-pe.eu.com

SMART IN FLOW CONTROL.



Container basierte KI Samson Pilotentwicklung or S-PE

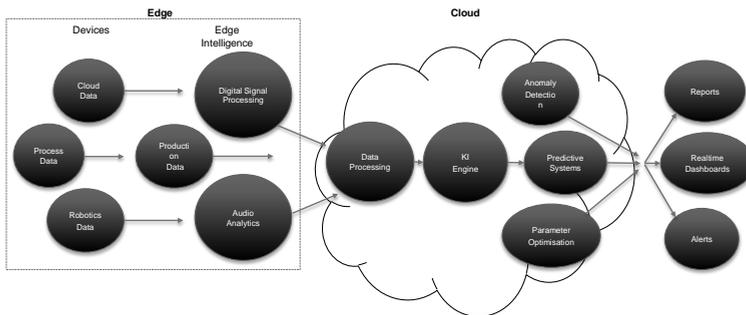
Dr. Andreas Binder

Public

2018-09-25/SPE/Dr.AB - SAMSON Pilotentwicklung

1

Container basierte KI-Architektur – „the big picture“

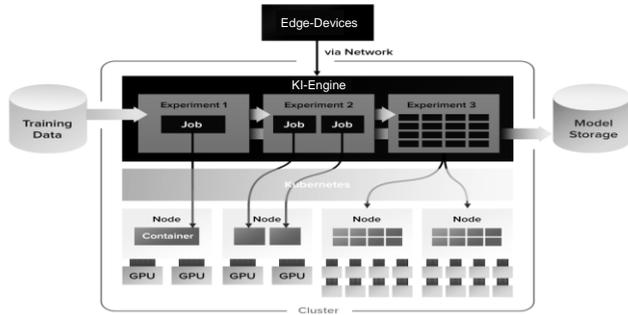


Public

2018-09-25/SPE/Dr.AB - SAMSON Pilotentwicklung

2

Container basierte KI-Architektur I



Container basierte KI-Architektur II

	Container	Container	Container	Security	
<ul style="list-style-type: none"> ■ Schnelles entwickeln und skalieren von "container basierten" Applikationen und Diensten 	Self Service				
	Middleware + Data Services		Service Catalog		
	Build Automation		Deployment Automation		
<ul style="list-style-type: none"> ■ Container Orchestrierung (basierend auf Kubernetes) ■ Monitoring (z.B. Prometheus) ■ VPN/VPC (je nach Bedarf) ■ Multi-Cloud fähig 	Application Lifecycle Management		Data/KI Framework		
	Container Orchestration		(Container) Cluster Services		
	Storage	Network	Registry		Telemetry
	Container Runtime and Packaging OS e.g. Linux				
Physical Infrastructure					

13 ZeroDownTime

R. Winkelmann
FANUC Deutschland GmbH
ralf.winkelmann@fanuc.eu

13.1 FANUC ZDT und FIELD System

Seit der Entwicklung des ersten vollautomatisierten Knickarmroboters im Jahr 1976 sind inzwischen mehr als 40 Jahre vergangen und im Sommer 2017 hat der 500.000 FANUC Roboter das Werk verlassen. Die Roboter von FANUC basieren auf der bewährten CNC- und Servotechnologie, die Bewegungstechnik, Softwarefunktionen und Mechanik miteinander verbindet und schon erfolgreich in CNC Maschinen eingesetzt wurden. Diese Roboter tragen zur Automatisierung von Produktionsstandorten weltweit bei.

Die Produktionssysteme werden immer intelligenter und komplexer. Jedes System besteht aus mehreren Aktoren und Sensoren unterschiedlicher Hersteller. Wenn auch nur ein Glied dieser Kette ausfällt, besteht ein hohes Risiko, dass die gesamte Produktion zum Stillstand kommt. Einige Fehler lassen sich leicht beheben, z. B. durch Austausch eines kleinen Sensors. Industrieroboter spielen aufgrund ihrer Größe, ihres Einsatzbereichs oder ihrer einzigartigen Fähigkeiten häufig eine Schlüsselrolle in einem System. Sie werden oft bei sich wiederholenden Aufgaben sowie in schmutzigen oder gefährlichen Umgebungen eingesetzt und sind im Schadensfall schwer auszutauschen.

Je größer die Produktionslinie desto eher kann ein Problem mit einem einzelnen Roboter auftreten, welches zu einem totalen Ausfall der Linie führen kann. Um einen solchen Linienausfall zu verhindern, ist eine „vorausschauende“ präventive Wartung wichtig, bei der die Bediener vor einem Alarmstopp über ungewöhnliche Situationen informiert oder aufgefordert werden, vor Auftreten eines Problems eine Wartung durchzuführen. FANUC hat für die „vorausschauende“ präventive Wartung die Zero Down Time Funktion (ZDT) (vergleiche Abbildung 13.1) entwickelt. Diese Funktion umfasst mehrere für die präventive Wartung nützliche Funktionen und verwaltet die Informationen zentral auf einem Server, um so die RoboterAusfallzeiten zu minimieren. Die Funktionen der Zero Down Time Funktion unterteilen sich in

vier Kategorien: „Statusüberwachung der mechanischen Einheiten“, „Überwachung des Prozessstatus“, „Überwachung des Systemstatus“ und „Wartungsplan-Benachrichtigung“.

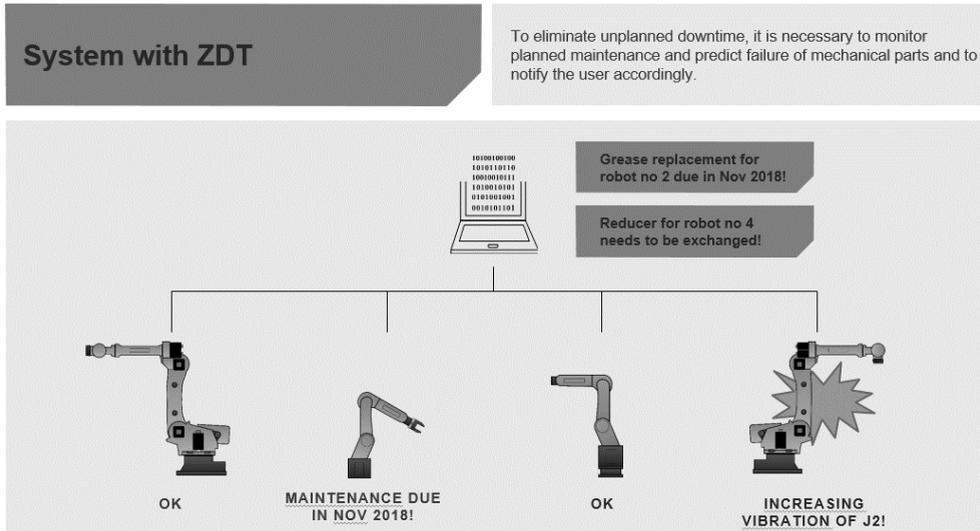


Abbildung 13.1: Grundlegende Übersicht über FANUC ZDT.

Ausfälle von Hochleistungs-Produktionssysteme sind schwer vorhersehbar und können nur mit den richtigen Werkzeugen und einer guten Instandhaltung minimiert werden. Mit FANUC Zero Down Time (ZDT) können Anwender dieses Risiko mit intelligenten Analysetools reduzieren.

ZDT erkennt abweichende Verhaltensweisen des Roboters. Der erste Schritt ist hier die Erfassung und Analyse aller Roboterdaten. Unterstützt werden alle Roboter mit einer R-30iB Steuerungen. Des Weiteren kann der Roboter über eine der beiden Ethernet-Anschlüsse an ein vorhandenes Netzwerk angeschlossen werden. Jeder Roboter sendet Daten an einen zentralen Server. Eine ZDT-Meldung ist eine XML-codierte Informationsdatei mit allen erforderlichen Informationen zu dem Vorfall, aber auch mit Metadaten zu dem Roboter und den Bedingungen, die dazu geführt haben. Diese Daten werden bei verschiedenen Gelegenheiten versandt, z. B. bei Programmänderungen, Fehlern oder während der Produktion, um die Bandbreite des Netzwerks zu verringern. Die ZDT Daten werden dann zur weiteren Verarbeitung und Analyse auf einem Datenbank-Server gespeichert. ZDT informiert über Änderungen im Produktionssystem und ermöglicht dem Nutzer Schlüsse aus den Prozess-

daten zu ziehen. Diese benutzerfreundliche Technologie benötigt einen geringen Konfigurationsaufwand und liefert einen Echtzeitüberblick über die Leistung des Roboters und den Systemstatus.

Der Process Logger ist eine weitere nützliche Option für Anwendungsprodukte. Er erfasst während der Ausführung des Anwendungsprozesses (SPOT, Weld Start to Weld End, Seal Start to Seal End, Gun ON to Gun OFF) prozessspezifische Daten. Er speichert einen Datensatz für jeden während des Programmlaufs durchgeführten Prozess und erstellt ein Verlaufsprotokoll. Die Anzeige und Analyse der protokollierten Daten können dabei helfen, den Prozess zu verstehen und Probleme zu vermeiden oder zu diagnostizieren. Für jeden Anwendungsprozess (Spot, Arc, Dispense, Paint, usw.) ist festgelegt, welche Daten als ein Datensatz erfasst werden sollen. Die Gesamtanzahl der Datensätze, die für jede Prozessanweisung gespeichert werden können, ist für jede Anwendung ebenfalls festgelegt. Der zur Speicherung der Prozessdaten erforderliche Speicherplatz ist begrenzt und konfigurierbar. Zur eindeutigen Kennzeichnung aller Schweißstellen (oder Schweißnähte) wird im Teach Pendant Programm des Benutzers eine Prozess-ID festgelegt. Die Prozess-ID und der Name des TP-Programms sind im Protokoll gespeichert und dienen zur eindeutigen Kennzeichnung der Daten.

Ein weiteres einfaches Beispiel für Prozessdaten ist die Laufzeit eines Roboters. ZDT überwacht, wann der Roboter läuft, stillsteht oder nicht funktioniert und stellt die Tools zur Problemerkennung bereit. ZDT hilft den Nutzern, sich mit Ihrem Systemdaten besser vertraut zu machen. Die letzten Alarme der einzelnen Roboter sind gut sichtbar. Außerdem können Änderungen in den TP-Programmen und Systemvariablen und sogar Systemdateien eingesehen werden, um die Speicherbelegung zu überwachen. Mit nur zwei Klicks kann der Anwender alle aufgezeichneten Alarme für jeden Roboter aufrufen, gleichgültig, ob sie 5 Sekunden oder mehrere Tage zurückliegen. Anhand dieser großen Datenmenge kann der Nutzer übliche Systemalarme leicht erkennen oder Kollegen in der Werkstatt vom Büro aus bei der Fehlerbehebung an den Robotern helfen. So können Probleme schneller behoben werden und die Produktionssysteme wieder zum Laufen gebracht werden.

Die geplante Wartung ist ein wichtiges Thema in Verbindung mit allen elektromechanischen Systemen. Hersteller testen die Ausrüstung mit großem Aufwand, um die Mindestinstandhaltungsintervalle für Motoren, Getriebe, Öle und Kabel festzulegen. Gleichgültig, wie intelligent Ihre vorausschauenden Instandhaltungsalgorithmen arbeiten, nichts ist besser als ein regelmäßiger Routinecheck der Roboter. Mithilfe intelligenter ZDT Funktionen werden

keine Wartung mehr vergessen und es wird vom System frühzeitig an die nächste Instandhaltung erinnert.

Aus dem FANUC Handbuch:

„Instandhaltungserinnerungen erinnern den Benutzer an die fällige Wartung des Roboters oder des Systems. Indem Sie den Benutzer mit Warnungen und digitale Meldungen über vorkonfigurierte Instandhaltungsanforderungen informieren, unterstützen sie ihn dabei, die Wartungsarbeiten in den richtigen Intervallen durchzuführen. Sie können die Wartungspunkte konfigurieren. In einigen Robotermodellen sind Instandhaltungserinnerungen standardmäßig konfiguriert (Erforderliche Instandhaltung). Diese Funktion erfordert die Software-Option Maintenance Reminder (J771). In Verbindung mit iR-Connect können die Instandhaltungserinnerungen auch über Mobilgeräte abgerufen werden.“

Auf dem ZDT-Webbrowser (siehe Abbildung 13.2) erkennen Nutzer schnell, welcher Roboter gewartet werden muss und können die entsprechenden Wartungsmaßnahmen rechtzeitig planen:

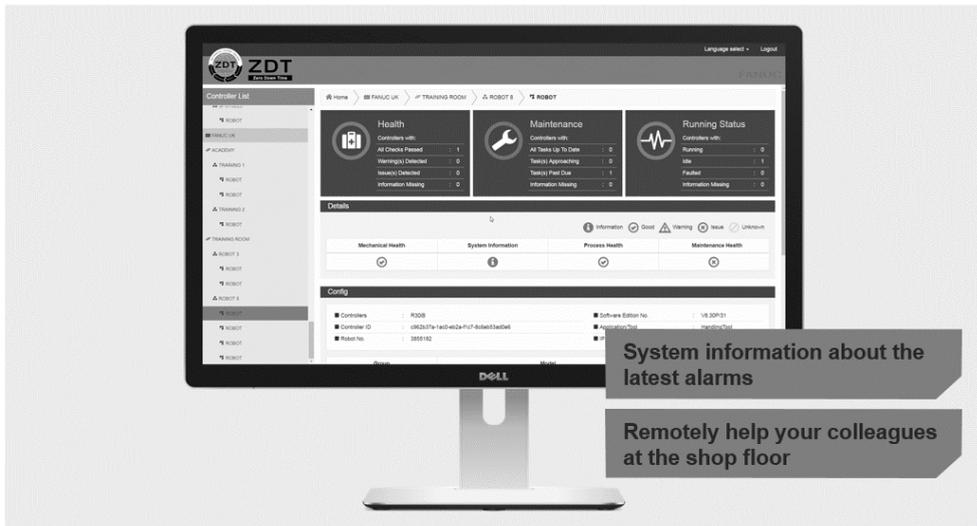


Abbildung 13.2: Weboberfläche von ZDT.

Als letztes erfasst ZDT Maschinendaten im Big Data-Pool. Mit iRDiagnosics lassen sich Fehler am Getriebe leicht erkennen. High Water Mark erkennt Veränderungen des Motorzustands. Servo-Ausschaltvorgänge unterteilen Notausschaltungen nach Schwere, Drehzahl und Drehmoment in unterschiedliche Gruppen und informieren den Anwender, wenn der Roboter in einer bestimmten Zeit einen festgelegten Grenzwert überschreitet.

Aus dem Handbuch:

- Diese Funktion erkennt Fehler an den Getrieben und hilft dem Benutzer, die Zeit für den präventiven Austausch festzulegen, um die Ausfallzeiten durch einen Fehler am Getriebe zu minimieren.
- Sie warnt den Benutzer bei Fehlern am Getriebe, die durch regelmäßige Analyse der Bewegungsdaten erkannt hat.
- Dazu muss ein Diagnoseprogramm erstellt, die Anfangsdaten registriert und das Diagnoseprogramm regelmäßig ausgeführt werden.
- Dem Diagnoseprogramm liegen eine Grundposition und ein zulässiger Bewegungsbereich zugrunde.
- Wenn kein ausreichender Bewegungsbereich festgelegt wird, können die Bewegungsdaten nicht analysiert werden.
- Bei einer antriebsbedingten schnellen Verschlechterung oder bei einem Fehler an bestimmten Teilen wird ein Fehler am Getriebe möglicherweise nicht im Voraus als Störung erkannt.
- Ein Fehler aufgrund von Alterung kann sich ebenfalls in nur wenigen Tagen vor dem Ausfall entwickeln. Führen Sie das Diagnoseprogramm regelmäßig oder einmal täglich durch.

Ein vereinfachtes Beispiel für Kundendaten zu einem Fehler am Getriebe. Der tägliche Selbsttest ergab keine besonderen Vorkommnisse. Die Werte liegen im Normalbereich und alles funktioniert einwandfrei (vergleiche Abbildung 13.3).

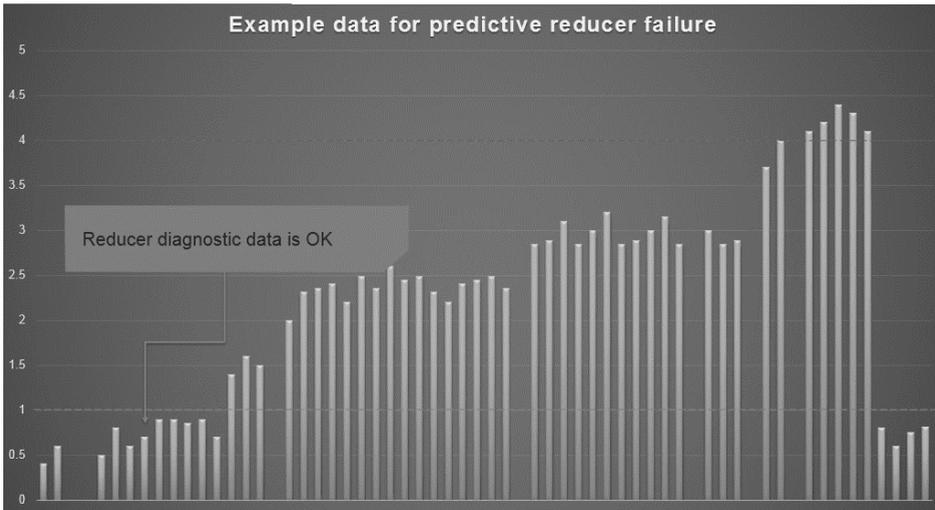


Abbildung 13.3: Ergebnisse des Selbsttests über die Zeit.
Phase 1: Selbsttest ergibt keine Fehler.

Erhöhte Werte weisen auf einen Fehler am Getriebe hin, möglicherweise liegt ein Problem vor, aber es wurden nicht ausreichend Daten erfasst oder es handelt sich um ein prozessspezifisches Problem. ZDT erkennt einen erhöhten Selbsttestwert (vergleiche Abbildung 13.4) für diese Achse und fordert den Benutzer auf, die entsprechenden Maßnahmen zu ergreifen. Nach Austausch des Getriebes ist die Grundlinie dieser Achse wieder normal

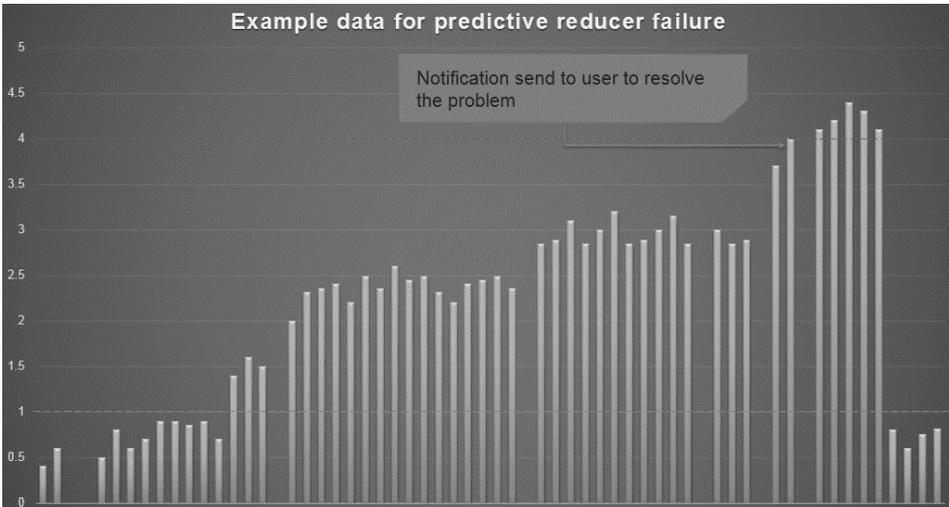


Abbildung 13.4: Ergebnisse des Selbsttests über die Zeit.
Phase 2: Selbsttest erkennt Fehler und informiert Benutzer.

Mithilfe von Algorithmen für eine vorausschauende Instandhaltung und der Erfassung von Smart Data kann der Kunde ungeplante Ausfallzeiten dieses Roboters reduzieren und so Zeit, Arbeit und Geld sparen.

13.2 FANUC FIELD System

Als Antwort auf Industrial IoT hat FANUC das FIELD System (FANUC Intelligent Edge Link & Drive System) entwickelt (vergleiche Abbildung 13.5). Mit dieser offenen Plattform lassen sich in einem Werk verschiedene Industrial IoT-Anwendungen ausführen. Durch den Aufbau eines interaktiven Netzes aus vernetzten Maschinen und Anlagen kann das FIELD System enorme Datenmenge auswerten, um eine Lösung zu bieten und diese schneller und effizienter zu analysieren.

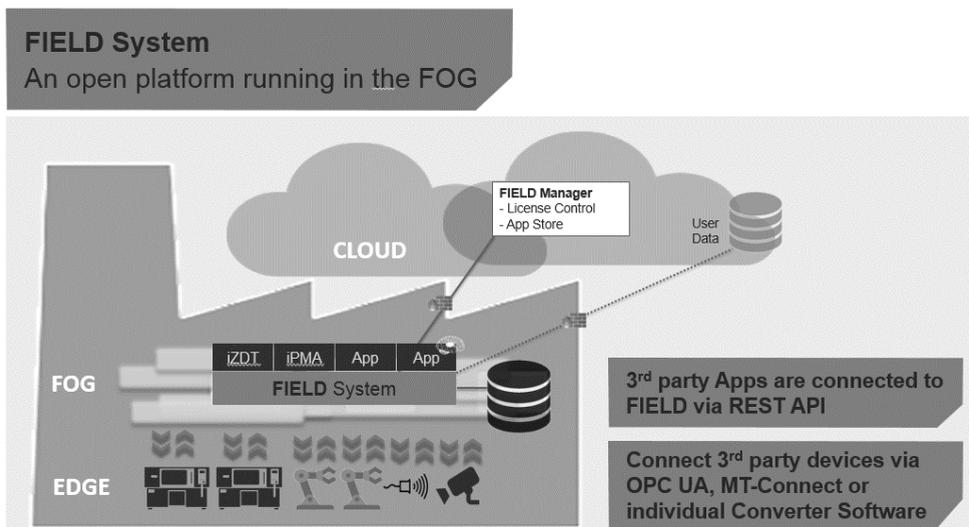


Abbildung 13.5: Übersicht über das FANUC FIELD System.

So können mit verschiedenen im FIELD-System ausgeführten Systemen intelligente Schlüsse aus den Daten gezogen und intelligentere Prozesse entwickelt werden, z. B. durch Vorhersagen zum Maschinenverhalten oder potenziellen Fehlern. FANUCs offenes Plattformsystem verschafft den Herstellern von Produktionsmaschinen, Robotern, Sensoren und Peripheriegeräten die Freiheit, eigene Anwendungen zu entwickeln. Ziel des FIELD-Systems ist die Verbindung aller Geräte im Werk. Es sorgt aber auch für die Flexibilität, sich mit Host-Systemen wie ERP (Enterprise Resource Planning), SCM (Supply Chain Management) und MES (Manufacturing Execution Systems) zu verbinden.

Nicht nur FANUC, auch andere Technologieunternehmen wie Software Anbieter können Treiber und Anwendungen für das FIELD System frei entwickeln. So können Geräte von Drittherstellern, wie Maschinen, Roboter, Sensoren und alle anderen Geräte bequem an das FIELD System angeschlossen werden, z. B. über OPC-UA, MT-Connect oder eine andere individuelle Converter-Software. Die gesamten Benutzerdaten werden „vor Ort“ auf einem der FIELD Server im Unternehmen gespeichert. FIELD Benutzer können entscheiden, ob ihre Daten auch in der Cloud gespeichert werden sollen oder nicht. FIELD bietet zahlreiche FANUC Anwendungen, wie iZDT, iPMA, u.v.m.

Je nach Verwendung und Zweck kann die Produktionsleistung durch sie erhöht werden. Anwender haben die Möglichkeit, Anwendungen direkt im FIELD App Store zu kaufen und danach in ihr FIELD System auf einen Linux Ubuntu Server-PC herunterzuladen. In den FANUC Produkten sind bereits Machine Learning-Funktionen implementiert, mit denen die Kunden die Leistung ihrer Maschinen durch die Datenerfassung und -analyse sowie die Bestimmung der Korrelationen innerhalb dieser Daten steigern können. Mithilfe von eng vernetzten Maschinen und den erfassten Daten können Fabriken ihre Produktion weiter optimieren; gestützt durch den Einsatz künstlicher Intelligenz basierter Schlussfolgerungen.

14 Industrieller Datenanalyseprozess für vorausschauende Wartung in der Cloud

Dr. C. Paulitsch
Siemens AG, Karlsruhe
christoph.paulitsch@siemens.com

14.1 Einleitung

Wenn Fehler in industriellen Anlagen rechtzeitig vorhergesagt werden, können wirkungsvolle Wartungsmaßnahmen zur Beseitigung der Fehlerursachen eingeleitet werden, um einen kostspieligen Anlagenausfall zu vermeiden [PL12]. Voraussetzung für vorausschauende Wartung sind ein aktuelles Vorhersagemodell und die Verfügbarkeit relevanter Maschinendaten. Innovative Cloud Plattformen wie MindSphere der Siemens AG bieten die Chance zur effizienten Ermittlung und kontinuierlichen Verbesserung von Vorhersagemodellen, da sie den sicheren Zugriff für Experten ermöglichen, Smart Data applikationsspezifisch zur Verfügung stellen, die notwendige Rechenleistung zur Erstellung komplexer, lernender Modelle bereitstellen und das ressourceneffiziente Deployen von Modellen lokal ermöglichen, ohne den Produktionsprozess zu stören. An aktuellen Beispielen aus der Industrie wird erklärt, wie plattformbasierte Datenanalyseverfahren in einem weitgehend skalier- und automatisierbaren Prozess effizient für die Vorhersage von Ausfällen genutzt werden können.

14.2 Datenanalyse in der Industrie

In einem iterativen für eine Clouddanwendung geeigneten Prozess wird ein Nutzer unter Anwendung von Standardalgorithmen [Er16, Pe+11] stufenweise zu mehr Einsichten bis zur Vorhersage von Fehlern und Optimierungsmöglichkeiten von Maschinen geführt.

14.2.1 Prozess

Auf der ersten Stufe des in Abbildung 14.1 gezeigten Datenanalyseprozesses werden aus Wartungsdaten mit Dauer und Anzahl von Fehlern mithilfe von Textanalysen wiederkehrende Fragestellungen identifiziert, die mithilfe einer Risikoabschätzung statistisch bewertet werden. Mit relevanten Wartungsfragestellungen verknüpfte Prozessdaten werden visualisiert und nach Normierung, Kalibrierung und zeitlicher Anpassung auf einen relevanten Kern reduziert, der auf redundante Korrelationen verzichtet.

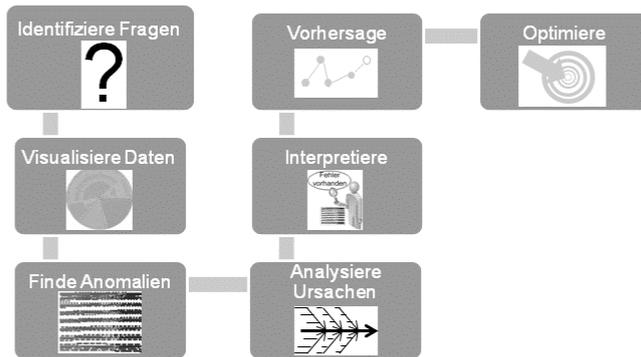


Abbildung 14.1: Übersicht über den Datenanalyseprozess.

Aus den Daten werden relevante Cluster gebildet und mithilfe von Modellen beschrieben. Abweichungen von und zwischen Modellen sind Anomalien, deren Ursachen einem Nutzer über eine Darstellung der zeitlichen Verteilung und Abfolge von Ereignisdaten präsentiert werden. Mithilfe einer Beschreibung der relevanten Unterscheidungsmerkmale und Zuordnung zu textuellen Ereignisbeschreibungen kann ein Anlagenfahrer Cluster und Anomalien bezüglich Fehler- oder Gutzustand interpretieren. Basierend auf den mit auf diese Art und Weise bezeichneten Daten lassen sich Modelle anlernen und für Fehlervorhersagen basierend auf Messdaten nutzen. Wenn diese Modelle genügend verifiziert sind, lassen sie sich zur Prozessoptimierung durch Bestimmung optimaler Eingangs- bzw. Ausgangsgrößen einsetzen.

14.2.2 Plattform

MindSphere ist das cloudbasierte, offene IoT-Betriebssystem der Siemens AG, das Produkte, Anlagen, Systeme und Maschinen verbindet und ermöglicht, die Fülle von Daten aus dem Internet der Dinge (IoT) mit umfangreichen Analysen zu nutzen [NN18]. Wie in Abbildung 14.2 gezeigt sammelt MindSphere Wartungsdaten (Dauer, Anzahl von Fehlern, textuelle Beschreibung), Prozessdaten (diskret, kontinuierlich), Ereignisdaten (Zeitstempel, Identifikation, textuelle Beschreibung), Anlagenstrukturdaten und Indikatoren (KPI, Anomalieindikator), die es Datenanalysten für Analysen, Domänenexperten zur Bewertung und Bedienern zur kontinuierlichen Überwachung zur Verfügung stellt. Der beschriebene Datenanalyseprozess ist in MindSphere kompatiblen Tools an einem Analysebeispiel umgesetzt. Vorteilhaft erweist sich neben der einheitlichen Verwaltung unterschiedlicher Datenarten für unterschiedliche Nutzer und Applikationen die skalierbare Be-

reitstellung von Rechenleistung in der Cloud, so dass abhängig vom Rechenaufwand der jeweiligen Prozessschritte Rechenleistung flexibel angepasst wird.

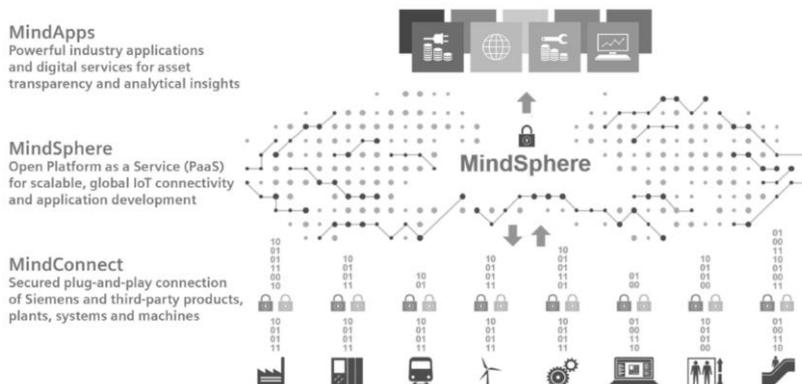


Abbildung 14.2: MindSphere IoT Plattform.

14.3 Problemstellungen identifizieren

In Produktionsanlagen werden Anlagenbücher geführt, die auftretende Ereignisse, durchgeführte Wartungen und Produktionsumstellungen dokumentieren. Meistens werden Uhrzeit, Dauer und das zugehörige Anlagenteil angegeben, teilweise werden Texte aus vorgefertigten Stichpunkten gewählt und immer ist eine Freitexteingabe vorgesehen. Mit natürlicher Sprachverarbeitung [LB02] können aus Freitextangaben häufig vorkommende Wörter identifiziert werden. Wie in Abbildung 14.3 gezeigt kommt es neben der Aussortierung von sprachspezifisch häufig vorkommenden Füllwörtern, Beseitigung von Rechtschreibfehlern und Erkennung gemeinsamer Wortstämme insbesondere auch auf die Identifikation von Wörtern gleicher Bedeutung an, die z.B. unterschiedlich abgekürzt werden.

```

werkzeugwechsel |
werkzeug        |
wechselposition |
wechselpos      |
verbogen        |
tooling         |
toleranz        |
teillage        |
teil            |
störung         |
schablonenwechsel |
    
```

Abbildung 14.3: Ergebnis einer Textanalyse von Wartungsdaten.

Für industrielle Domänen können so semantische Wortnetze aufgebaut werden. Anhand der relativen Häufigkeit einzelner Worte kann auf die Bedeutung eines Fehlerereignisses geschlossen werden.

Wenn Fehler Maschinenteilen zugeordnet werden und die Dauer des Fehlers bekannt ist, können Dauer und Häufigkeit zu einem Risikowert multiplikativ zusammengefasst werden. Liegen Daten zu Stillstandskosten vor, die z.B. aus Personalkosten, Investitionskosten oder entgangenem Gewinn berechnet werden, kann zudem der Nutzen einer verringerten Stillstanddauer je Fehler wie in Abbildung 14.4 beispielhaft gezeigt quantifiziert werden.

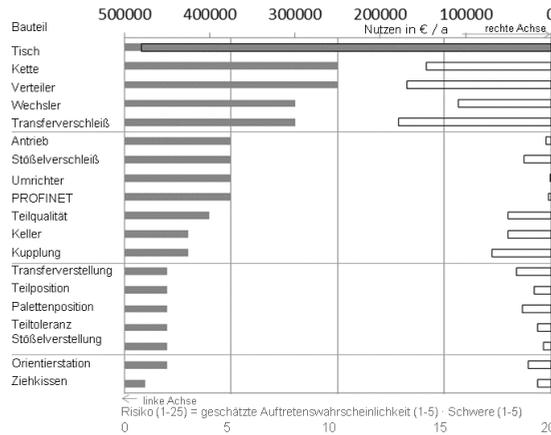


Abbildung 14.4: Bewertung genannter Teilefehler nach Häufigkeit und Dauer.

Ziel einer Datenanalyse muss es hier sein, das Auftreten des zu betrachtenden Fehlers vorauszusagen, so dass geeignete Gegenmaßnahmen eingeleitet werden können.

14.4 Visualisierung der Daten

Hierfür werden Prozessdaten identifiziert, die mit dem Maschinenteil des zu betrachtenden Fehlers verknüpft sind. Normen wie [VD14] geben Hinweise auf sinnvollerweise zu ergänzende Messaufnehmer. Diese Prozessdaten werden unter Beachtung des richtigen Formats, Codierung und Datentyps in die Cloud eingelesen und mittels Interpolation auf einen einheitlichen Zeitstempel gebracht. Mit entsprechenden *merge* Befehlen liegen diese Daten in einer Matrix vor und werden skaliert wie in Abbildung 14.5 gezeigt gegeneinander dargestellt. In diesem 5x5 Beispiel weisen 4 Größen einen korrelierten Verlauf auf, wie an der Winkelhalbierenden erkennbar ist. Die Größe *g5* weist einen diskreten Verlauf auf, was auf sich sprunghaft ändernde Betriebsbedingungen hinweisen könnte, während eine weitere Größe den gesamten Messbereich ausfüllt.

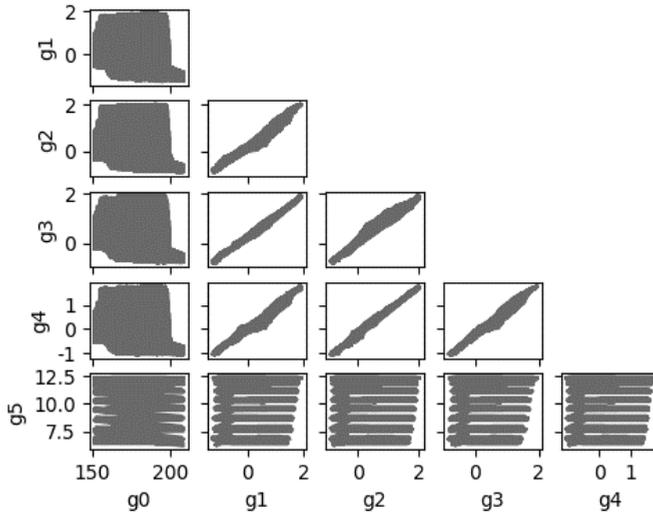


Abbildung 14.5: Scatterplot.

Eine Korrelationsmatrix nach Abbildung 14.6 bestätigt die Vermutung, dass eine starke Korrelation zwischen jeweils vier Größen und zwei wenig korrelierte Größen vorliegt.

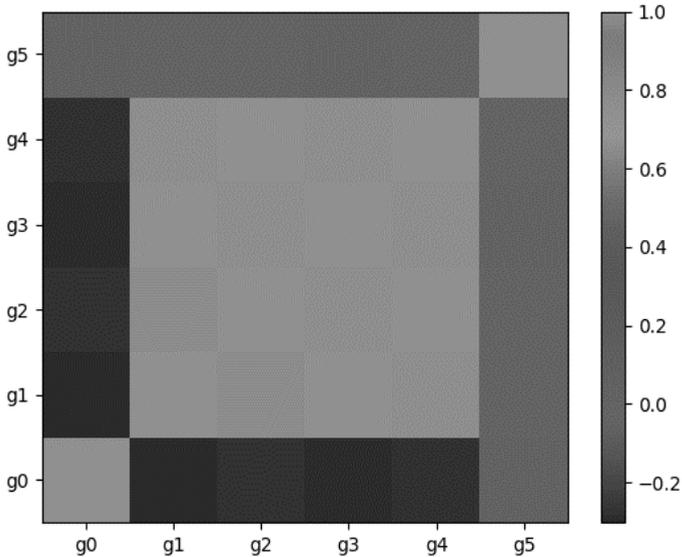


Abbildung 14.6: Korrelationsmatrix mit Korrelationskoeffizienten zwischen Messgrößen.

Eine Hauptkomponentenanalyse bestätigt, dass gemäß Abbildung 14.7 drei Größen ausreichen, um fast 100% der Variabilität in den Messdaten zu erklären.

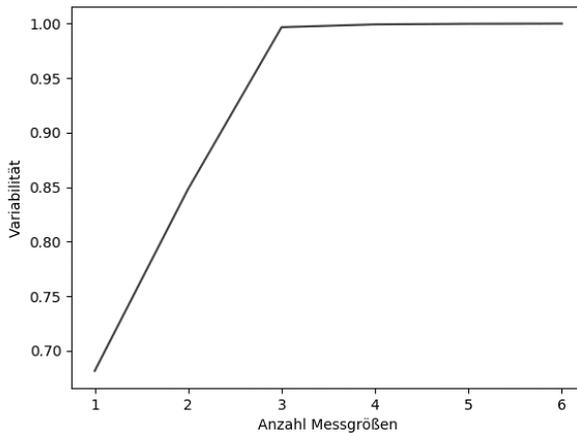


Abbildung 14.7: Hauptkomponentenanalyse.

Eine Transformation auf die ersten drei Hauptkomponenten sollte ausreichen, um Beziehungen im Datensatz zu erklären. Um die physikalische Interpretierbarkeit der Größen zu ermöglichen, wird aber weiterhin mit den Originalgrößen weitergerechnet. Das Vorliegen von diskreten Stufen der Betriebsbedingung g_5 für den gesamten Bereich der Größe g_0 könnte auf einen zyklischen Verlauf der Größen über g_0 hinweisen

Bei einer zyklischen Darstellung von g_1 über g_0 ist ersichtlich, dass sich Werte von g_1 zyklisch über g_0 wiederholen. Charakteristisch ist in Abbildung 14.8 gut zu beobachten wie sich die Kanten ansteigender g_1 Werte mit jedem Zyklus verschieben.

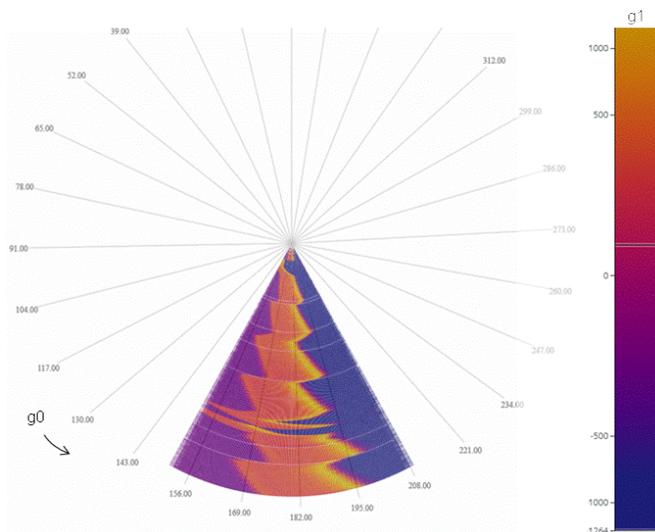


Abbildung 14.8: Spiraldarstellung

14.5 Anomaliedetektion

Fehler bei sonst ordnungsgemäßem Betrieb sollten sich als einzelne Anomalien in den homogenen Daten zeigen. Mit unüberwachten Lernverfahren lassen sich Cluster identifizieren. Mit Algorithmen wie K-Means wird die gesuchte Anzahl von Clustern vorgegeben, die im Fall von Fehler- und Gutdaten mindestens zwei betragen sollte. Bei Anwendung auf die Daten für vier Cluster zeigt Abbildung 14.9, dass sich Cluster für hohe, mittlere, kleine und sehr kleine Werte der Variablen $g1$, $g2$, $g3$ bilden für beliebige $g0$ und $g5$.

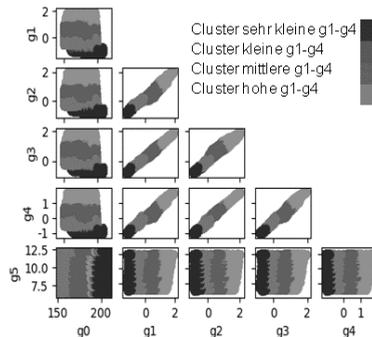


Abbildung 14.9: Mit K-Means identifizierte Cluster.

$g5$ stellt sich wieder als Größe mit diskreten Betriebsbedingungen dar. Bei der Gegenüberstellung von $g5$ zu $g0$ scheint der typische Werteverlauf (klein, mittel, hoch, klein, sehr klein der Größen $g1$ - $g4$) zu höheren $g0$ Werten zu springen. Innerhalb der verschiedenen Betriebsbedingungen von $g5$ kommt es zu einer regelmäßigen Verschiebung der Bereiche mit $g0$ wie sie auch zyklisch in Abbildung 14.8 zu beobachten ist. Ohne Vorgabe der Anzahl von Clustern können mit DBSCAN [Ek96] weitere Cluster gefunden werden, die in Abbildung 14.10 farblich codiert sind.

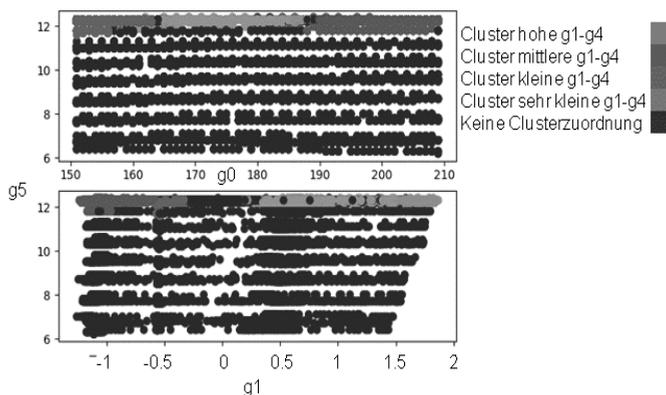


Abbildung 14.10: Mit DBSCAN identifizierte Cluster.

Einzelne Werte sind beim Übergang von mittleren zu hohen und von hohen zu kleinen Werten für $g1$ bis $g4$ über $g0$ auffällig, die als Anomalien keinem Cluster zugeordnet sind. Ebenfalls werden kleine Werte von $g5$ keinem Cluster zugeordnet und einzelne Werte von $g1$ sind auffällig. Interessant ist es, für die jeweiligen Cluster Modelle anzulernen, die das Normalverhalten in diesem Cluster abbilden. Die Bereiche, in denen Modelle voneinander abweichen, sind charakteristisch für den jeweiligen Cluster. Anomalien weichen von allen Modellen ab. In Abbildung 14.11 sind die Fehler eines Modells über $g0$ angegeben, wobei das Modell an Daten von zwei unterschiedlichen Clustern angelehrt wurde.

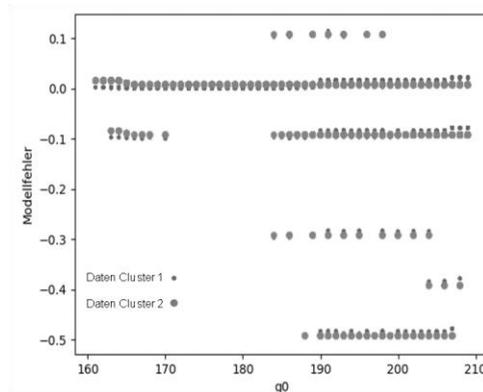


Abbildung 14.11: Fehler des Clustermodells1 für Messwerte aus Cluster 1 (kleine Kreise) und Cluster 2 (große Kreise).

Das Cluster 1 (kleine Kreise) scheint eher charakteristisch für den gesamten Bereich von $g0$ zu sein, während das Cluster 2 (große Kreise) besonders für kleine Werte von $g0$ relevant ist, da es bei großen Werten von $g0$ zu größeren Fehlern führt. Insbesondere bei Werten zwischen ca. 190 und 210, in dem bereits vorherige Analysen Anomalien erkannt hatten, kommt es zu größeren Modellfehlern, die auf Anomalien hinweisen, die sich durch keines der beiden Modelle erklären lassen.

14.6 Ursachenanalyse

Ursachen für dieses unterschiedliche Verhalten der Cluster lassen sich aus der zeitlichen Abfolge von Ereignissen ableiten. Zum Beispiel gibt es eine charakteristische Abfolge von Betriebszuständen der Variable $g5$, die in Abbildung 14.12 dargestellt ist. Die Werte 11.9 und 12.3 treten zu allen Zeiten am häufigsten auf, während die Werte 12, 12.2, 11.8 und 12.1 bei einem Anfahrtszeitraum seltener als 5.9 und 6 auftreten. Zwischenwerte treten am seltensten auf.

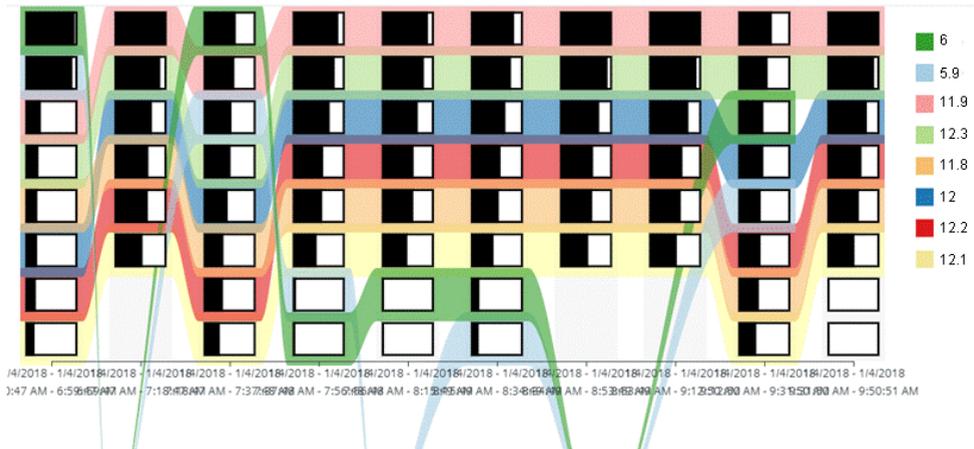


Abbildung 14.12: Nach Häufigkeit sortierter zeitlicher Verlauf der Häufigkeiten der Werte von g_5 .

Insgesamt ist bei der gewählten und auch bei weiteren untersuchten Anzahlen von Perioden keine sich wiederholende Abfolge zu erkennen, die auf eine kausale Abhängigkeit hindeuten könnte. Hingegen sind bei der Verwendung von Sequenzanalysen [Fo+17, VS+15], wiederkehrende Sequenzen von Clustern zu beobachten. Eine Sequenzanalyse für die Abfolge von Clustern entlang der Größe g_0 zeigt in Abbildung 14.13, dass zwischen den Clustern Daten liegen, die sich keinem Cluster zuordnen lassen.

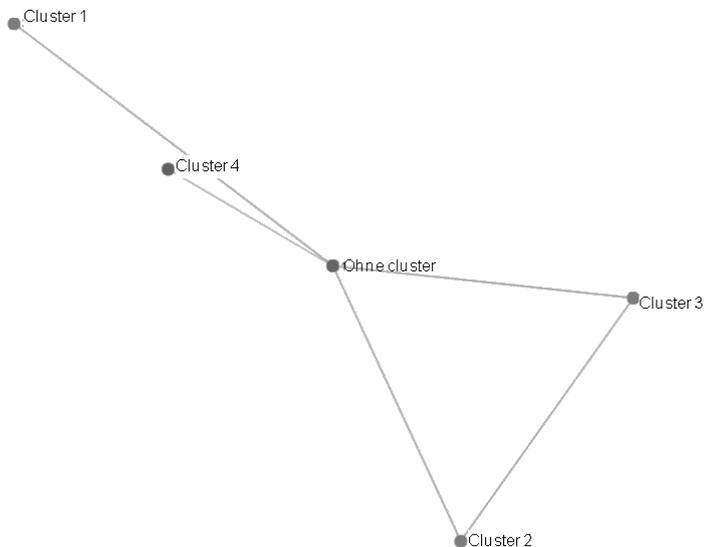


Abbildung 14.13: Häufige Sequenzen von aufeinanderfolgenden Clustern.

Wie schon aus Abbildung 14.10 vermutet folgen nur die Cluster 2 und 3 unmittelbar aufeinander. Auf diese Art hilft das Wissen über die zeitliche Abfolge der Clusterereignisse bei der Interpretation der Cluster als aufeinanderfolgende Betriebsbedingungen.

14.7 Interpretation

Cluster lassen sich über ihre Merkmale unterscheiden. So lassen sich mit einer Entscheidungsbaumanalyse nach Abbildung 14.14 vier Cluster nach dem Wert der Daten unterscheiden. Von den 100.000 Datenpunkten werden 16.144 dem Cluster 1, 14.751 dem Cluster 2, 38.972 dem Cluster 3, 27.481 dem Cluster 3 und 2.652 Datenpunkte dem Cluster 4 zugeordnet.

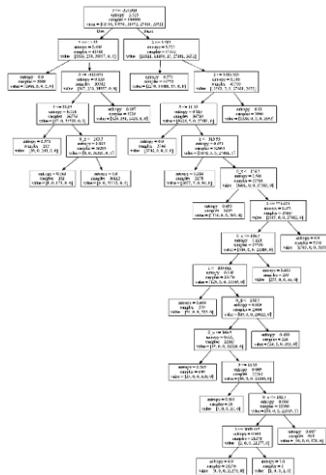


Abbildung 14.14: Entscheidungsbaum.

Der Baum erklärt, dass das Cluster 1 durch kleine g_5 bei kleinen g_2 und sehr kleinen g_3 gekennzeichnet ist; d.h. während der Anfahrphase mit kleinen g_5 . Das Cluster 2 ist durch kleine g_2 sowie mittlere und große g_3 gekennzeichnet, die sich im Bereich nach dem Anstieg in Abbildung 14.8 befinden, d.h. bei Beginn der Betriebsphase. Cluster 3 umfasst den Bereich auf und nach dem in Abbildung 14.8 orange gekennzeichneten durch hohe Werte von g_1 charakterisierten Plateau bei großen Betriebsbedingungen g_5 , kleinen g_2 bei den Betriebsbedingungen mit großen g_0 , d.h. nach der Betriebsphase. Das Cluster 4 stellt dann den Bereich während des Plateaus bei großen Betriebsbedingungen g_5 dar, d.h. während der Betriebsphase.

Tabelle 14.1: Charakterisierung identifizierter Cluster:

Cluster	Charakterisierung
1	$g3 \leq -0.219$ $g5 \leq 11.55$; $g3 > -0.219$ $g2 > 0.03$; $g2 \leq 1.4$ $g5 \leq 11.85$ kleine $g2$, sehr kleine $g3$, kleine $g5$
2	$g3 > -0.219$ $g2 \leq 0.03$ kleine $g2$, mittlere und große $g3$
3	$g3 \leq -0.219$ $g5 > 11.55$; $g3 \leq -0.443$ $g5 > 11.85$; $g0 > 163.5$ sehr kleine $g2$, große $g5$, große $g0$
4	$g2 > 0.03$ $g2 \leq 1.4$ $g2 \leq 0.774$; $g5 > 11.95$ $g5 > 11.85$; $g1 > 0.313$ $g1 > 0.399$; $g0 > 156.5$ $g0 \leq 186.5$ $g0 \leq 184.5$ $g0 > 160.5$ $g0 \leq 181.5$; $g3 > -0.219$ $g3 \leq 1.069$ große $g1$ mittlere $g2$ große $g5$ mittlere $g0$ mittlere $g3$

Diese Cluster sind unterschiedlich im Vergleich zu den DBSCAN und K-Means Clustern, da bei den Verfahren nach unterschiedlichen Kriterien gruppiert wird, so dass die Art der gesuchten Abweichung angelernt werden sollte. Zur weiteren Beschreibung der Abweichungen von Clustern werden die in Abschnitt 14.3 bereits genannten Wartungsdaten genutzt, die eine textuelle Beschreibung des Fehlerfalls besitzen. Aufgrund der Vielzahl von auftretenden Fehlerfällen ist es notwendig, einen Experten bei der Identifikation und Bezeichnung des relevanten Falles zu unterstützen. Anhand der in Abschnitt 14.3 beschriebenen Textanalyse werden von einem Experten einmalig Wörter identifiziert, die auf den gesuchten Fehlerfall hinweisen [Pa18]. Anhand eines Ähnlichkeitskennwertes, der auf der relativen Anzahl relevanter Wörter beruht, werden Fehlerfälle identifiziert, die dann von einem Experten bewertet werden. In Abbildung 14.15 ist der geschätzte Ähnlichkeitswert (dunkle Quadrate) den real vorkommenden Fehlern (helle Dreiecke) gegenübergestellt. Der Grenzwert für den Ähnlichkeitswert zur Meldung eines ähnlichen Fehlers wird so angepasst, dass ein passender Kompromiss zwischen Arbeitsaufwand für das Durchsehen der Fehlerfälle und geringe Kennzeichnungsgüte durch Übersehen von realen Fehlern erreicht wird.

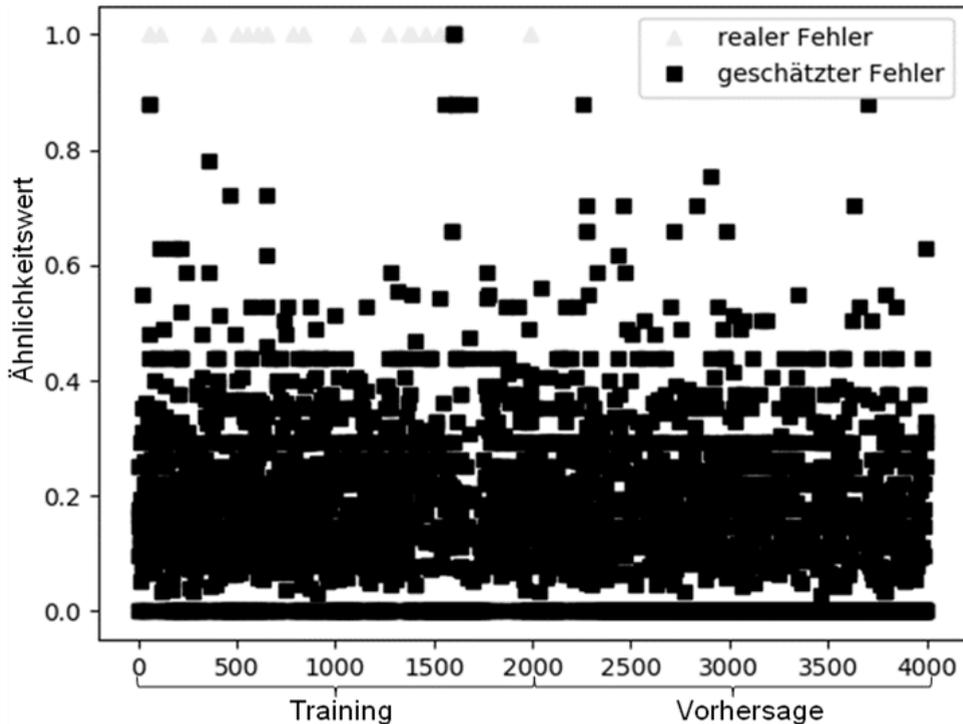


Abbildung 14.15: Mithilfe natürlicher Sprachverarbeitung geschätzter und realer Fehlerzeitpunkt bei Training und Testdaten.

In dem genannten Beispiel kann so auf die Durchsicht Tausender nicht relevanter Fehler für die Kennzeichnung verzichtet werden. Liegen die Bezeichner vor, können sie zum Anlernen von Fehlermodellen genutzt werden, die in die Zukunft extrapoliert werden.

14.8 Vorhersage

Die in Abschnitt 14.5 clusterspezifisch an Gutdaten angelernten Modelle werden auf zusätzliche Eingangsdaten angewendet, um eine Vorhersage durchzuführen, welchen Clustern sie zugeordnet werden. Dabei werden die Daten dem Cluster zugeordnet, dessen Modell den geringsten Fehler aufweist. Wenn der kleinste Fehler allerdings einen Grenzwert überschreitet, sind die Daten keinem Cluster zuordenbar und es ist eine Experteneinschätzung des Zustandes notwendig, ob es sich um Fehlerdaten handelt oder Gutdaten, die zu einer Verbesserung des Modells genutzt werden. In Abbildung 14.16 ist der geschätzte (dunkel) und reale (hell) Zustand für die auf alle Daten angewandte Modelle für Cluster 1 und 2 aus Abschnitt 14.5 gezeigt.

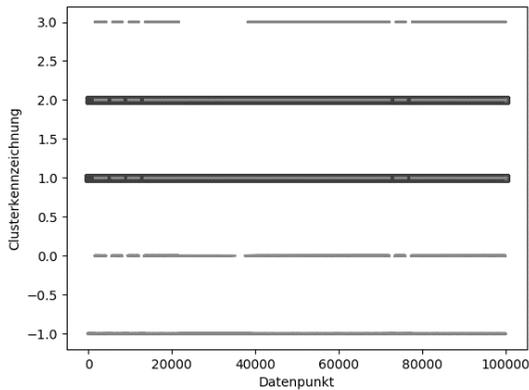


Abbildung 14.16: Geschätzter und realer Zustand.

Bei vielen Messpunkten wird der reale Zustand nicht richtig erkannt, da nicht für alle Cluster Modelle verwendet werden. Die Darstellung des Modellfehlers der beiden Clustermodelle in Abbildung 14.17 macht deutlich, dass hier bei bestimmten Betriebszuständen der Modellfehler zu groß ist, um für eine Gutfallerkennung genutzt zu werden. Die Mithilfe eines Experten oder die Verwendung weiterer Modelle ist notwendig, um diese Abweichung als Gut- oder Fehlerzustand zu erklären. Sobald genügend Daten vorliegen, können auch neuronale Netzmodelle genutzt werden [Ab+16]. Vorteilhaft ist hier die Verwendung einer skalierbaren Plattform, um die vorhandene Rechenleistung an den variablen Bedarf unterschiedlicher Modelle anzupassen.

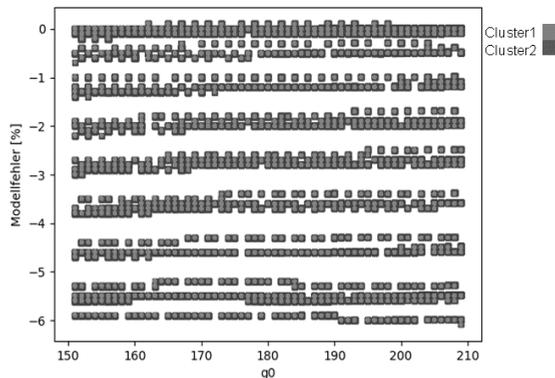


Abbildung 14.17: Fehler der Modelle der Cluster 1(hell) und 2(dunkel) für alle Messdaten.

Nach ausreichendem Test der Modelle auf der Cloud Plattform können sie auf einer lokalen Umgebung deployed werden. Zum Beispiel werden auf der Plattform verwendete Python Skripts in einem Node-RED Knoten auf der gewünschten lokalen Umgebung ausgeführt [Ba18].

14.9 Optimierung

Wenn die Modelle ausreichend lange erfolgreich Vorhersagen durchgeführt haben und sich über die Zeit nicht mehr ändern, können sie für eine Optimierung in einem Wertebereich genutzt werden, der nicht unbedingt dem tatsächlichen Messbereich entspricht. Zum Beispiel lässt sich die zu wählende Betriebsbedingung g_5 , wie in Abbildung 14.18 gezeigt, abhängig von Eingangsgrößen bestimmen.

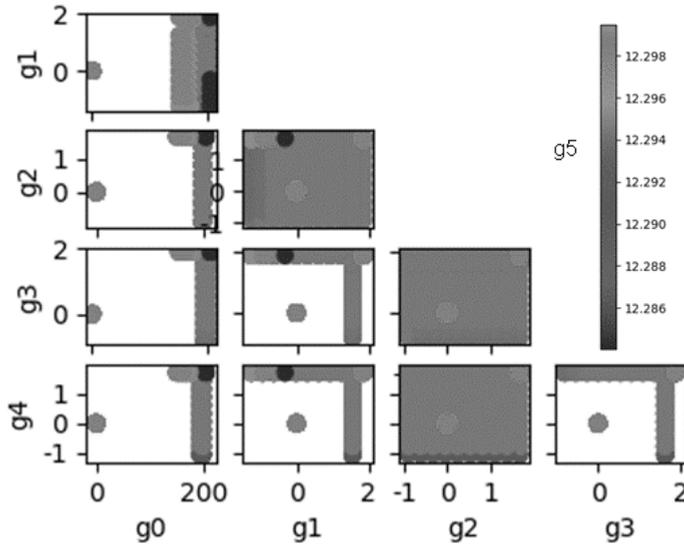


Abbildung 14.18: Mit Modell des Clusters 1 aus Eingangsgrößen geschätzte Betriebsbedingung g_5 .

Im Beispiel zeigt das Modell auf, dass bestimmte Betriebsbedingungen nur für bestimmte Eingangsgrößen geeignet sind. Umgekehrt sind für eine Optimierung der Betriebsbedingungen bestimmte Eingangsgrößen zu wählen. Für eine weitere Auswertung sind Bewertungen der Betriebsbedingungen und Messwerte notwendig, da z.B. benötigte Leistungen typischerweise minimiert und Produktionsgeschwindigkeiten maximiert werden sollen. Die Größe g_5 ähnelt einer Betriebsbedingung, die entweder als Leistung zu minimieren oder als Produktionsgeschwindigkeit zu maximieren ist. Im ersten Fall sollte die Anlage bei der Betriebsbedingung 12.3 (hell markiert in Abbildung 14.18) gefahren werden, während im letzteren Fall die Anlage bei der Leistung 12.2 (dunkel markiert in Abbildung 14.18) gefahren werden sollte.

14.10 Zusammenfassung

Gemäß dem Datenanalyseprozess „Identifiziere Fragestellung, Visualisiere Daten, Finde Anomalien und Klassifiziere Anomalien, Analysiere Ursachen, Interpretiere, Prognostiziere und Optimiere“ werden aus Wartungsdaten relevante Fehlerfälle, wie Teileverschleiß, und zugehörige Bauteile, wie Werkzeuge, identifiziert. Die einem Werkzeug zuordenbaren Daten lassen sich in vier korrelierte Prozessdaten, eine Betriebsbedingung und eine zyklische Messgröße unterteilen. Mit K-Means und DBSCAN werden charakteristische Cluster identifiziert. Anomalien sind insbesondere beim Anstieg der Prozessdaten zwischen Betriebsphasen zu beobachten. Für die einzelnen Cluster werden Gutmodelle identifiziert, mit denen das normale Betriebsverhalten beschrieben wird. Aufgrund von Analysen des zeitlichen Verlaufes und Sequenzanalysen werden Ursachen für Anomalien bei kleinen Werten von g_4 als Anfahrverhalten und bei bestimmten Werten von g_0 als Übergangsverhalten zwischen zwei Betriebsphasen interpretiert. Mit Entscheidungsbaumanalysen können die Cluster als Vorlaufphase, Beginn der Betriebsphase, Nachlaufphase und Hauptbetriebsphase identifiziert werden. Eine weitere Kennzeichnung der Cluster erfolgt durch die zeitliche Zuordnung zu textuellen Kennzeichnungen von Experten. Wiederkehrende Kennzeichnungen werden anhand von Textanalysen erkannt. Fälle, in denen wie im Beispiel keine Fehlerkennzeichnung erfolgt, werden als gut markiert. Dann wird der Modellfehler genutzt, um potentiellen Wartungsbedarf zu identifizieren. Eine Optimierung mit Hilfe der Modelle ergibt effiziente Bereiche von Eingangs- bei gegebenen Ausgangsgrößen oder effektive Bereiche von Ausgangs- bei gegebenen Eingangsgrößen. Die Analyseplattform MindSphere unterstützt bei der Datenhaltung unterschiedlicher Daten, der flexiblen Bereitstellung von Rechenleistung, dem Deployment auf lokalen Umgebungen und der einheitlichen Darstellung.

14.11 Danksagung

Ein Dank geht an die Kunden der Siemens AG, die im Rahmen von Kooperationsvereinbarungen Daten bereitgestellt haben, um den Analyseprozess zu entwickeln und im Produktionsprozess zu testen. TensorFlow, das TensorFlow Logo und verwandte Zeichen sind Schutzmarken von Google Inc.

Literatur

- [Ab+16] M. Abadi. et al.: TensorFlow : A System for Large-Scale Machine Learning. In: Proceedings of the 12th USENIX Symposium on Operating Systems Design and Implementation, Savannah, 2016, S. 265-283.
- [Ba18] E. Bartmann: IoT-Programmierung mit Node-RED. Elektor-Verlag, Aachen, 2018.
- [Es+96] M. Ester et al.: A Density-Based Algorithm for Discovering Clusters in Large Spatial Databases with Noise. In: Proceedings of 2nd International Conference on Knowledge Discovery and Data Mining, Portland, 1996, S. 226-231.
- [Er16] W. Ertel: Grundkurs Künstliche Intelligenz: Eine praxisorientierte Einführung. Springer-Verlag, Wiesbaden, 2016.
- [Fo+17] P. Fournier-Viger et al.: A Survey of Sequential Pattern Mining. Data Science and Pattern Recognition, Vol. 1, Nr.1 S. 54-77, 2017.
- [LB02] W. Loper, S. Bird: NLTK: The Natural Language Toolkit. In: Proceedings of the ACL Workshop on Effective Tools and Methodologies for Teaching Natural Language Processing and Computational Linguistics, Philadelphia, Vereinigte Staaten von Amerika, 2002, S. 62-69.
- [NN18] N.N.: Von der Cloud zur Edge. Automationspraxis, Vol. 13, Nr. 6, S. 26, 2018.
- [Pa18] C. Paulitsch: Predictive Maintenance Model Retraining Based on Automatic Labels from Maintenance Log Data in an Automotive Press Shop. In: Predictive Analytics World for Industry 4.0, München, 2018.
- [Pe+11] F. Pedregosa et al.: Scikit-learn: Machine Learning in Python. Journal of Machine Learning Research, Vol. 12, S. 2825-2830, 2011.
- [PL12] C. Paulitsch, H. Lenz: Konzept einer durchgängigen Zustandsüberwachung. In: VDI-Berichte Nr. 2171, Baden-Baden, 2012, S.143-146.
- [VD14] Verband Deutscher Maschinen und Anlagenbau e.V. (VDMA): Feldbusneutrale Referenzarchitektur für Condition Monitoring in der Fabrikautomation. VDMA-Einheitsblatt 24582, 2014.
- [VS+15] B. Vogel-Heuser, D. Schütz, J. Folmer: Criteria-based alarm flood pattern recognition using historical data from automated production systems (aPS). Mechatronics, Vol. 31, S. 89-100, 2015.