


Abschlussbericht

M@OK

Online Echtzeit-Wissensmanagement, Data-Mining und
Machine-Learning für den Maschinen- und Anlagenbau



Laufzeit des Vorhabens:	01.02.2018 – 31.10.2020
Förderkennzeichen:	IUK566
Projektpartner:	DORST Technologies GmbH & Co. KG (Dorst) GROB-WERKE GmbH & Co. KG (Grob) Continental Reifen Deutschland GmbH (Conti) [assoziiert] HAWE Hydraulik SE (HAWE) [assoziiert] Technische Universität München, Lehrstuhl für Automatisierung und Informationssysteme (TUM)

Inhaltsverzeichnis

1	Ausgangssituation	1
2	Ergebnisse	2
2.1	Entwicklung und Modellierung von Datenanalysearchitektur	4
2.2	Entwicklung von Anwendungen des maschinellen Lernens	6
2.2.1	Alarmmanagement	7
2.2.2	Qualitätsüberwachung an hydraulischen Metallpulverpressen	8
2.2.3	Condition Monitoring in hydraulischen Systemen	10
2.2.4	Text Mining in Instandhaltungsmeldungen	11
2.3	Umsetzung von maschinellen Lernverfahren mittels Agenten	13
3	Nutzung und Verwertung.....	16
3.1	Wirtschaftliche Nutzung und Verwertung	16
3.2	Wissenschaftliche Nutzung und Verwertung.....	17

1 Ausgangssituation

Das Forschungsvorhaben zielt auf die Maximierung der Overall Equipment Effectiveness (OEE), d. h. der Produktqualität sowie der Leistung und Verfügbarkeit von Maschinen, ab. Diese soll durch eine intelligente Analyse und Auswertung von Sensor- und Betriebsdaten sowie Alarmdaten während des Maschinenbetriebs realisiert werden. Um von Anfang an eine zielführende, ergebnisorientierte Datenanalyse zu ermöglichen, soll menschliches Wissen über die Maschine und die darin ablaufenden Prozesse in die Analyse mit einfließen (vgl. Abbildung 1 „Wissensgenerierung“). Die Umsetzung der datengetriebenen Modelle während des Maschinenbetriebs erfordert intelligente, selbständige Einheiten, die sich an verändernde Umgebungsparametern autonom anpassen und somit den bestmöglichen Einsatz der Modelle garantiert. Daher sollen Softwareagenten zur Ausführung von maschinellen Lernverfahren erforscht werden (vgl. Abbildung 1 „Agentensystem“). Die Entwicklung von datengetriebenen Verfahren im Maschinen- und Anlagenbau ist nur möglich, wenn Daten aus dem operativen Betrieb der Maschinen vorliegen. Hierzu werden Anwendungsfälle der eigenen Produktion der industriellen Kooperationspartner, sowie deren Kunden in die Analyse einbezogen (vgl. Abbildung 1 „Anwendung“).

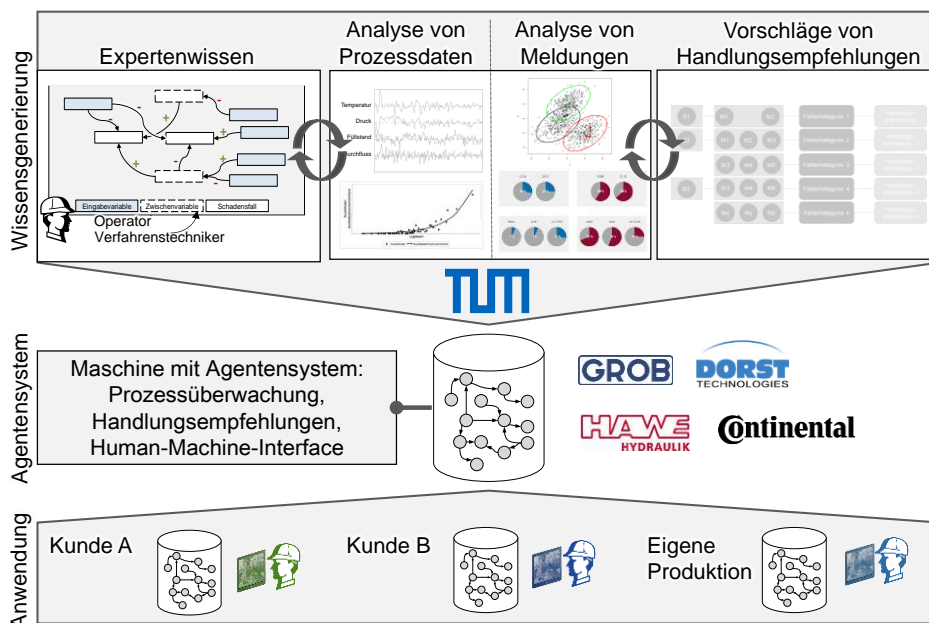


Abbildung 1: Konzept des Projekts M@OK: Verknüpfung von Datenquellen zur Ableitung von Handlungsempfehlungen.

Das Konsortium setzt sich aus Unternehmen des Maschinen- und Anlagenbaus und dem Lehrstuhl für Automatisierung und Informationssysteme der Technischen Universität München zusammen. Gemeinsam wird an Methoden und Verfahren des maschinellen Lernens geforscht, um Maschinenstillstände zu vermeiden bzw. die Wiederaufnahme des Maschinenbetriebs zu beschleunigen und die Produktqualität zu überwachen und zu steigern. Darüber hinaus bringen die Unternehmen wertvolles Expertenwissen ein, welches im Projekt genutzt wird, um die vorliegenden Daten effizient zu nutzen. Der Lehrstuhl für Automatisierung und Informationssysteme setzt zudem sein Wissen zu Agentensystemen ein, um flexible Lösungen zu schaffen.

Im Projekt haben die Partner gemeinsam über 2,5 Jahren an unterschiedlichen Use Cases zur Steigerung der OEE mittels datengetriebener Methoden geforscht. Folgender Arbeitsplan wurde verfolgt:

- **AP1:** Auswahl der Anwendungsfälle und Definition der Anforderungen
Erarbeitung eines Lastenhefts für das Projekt
(Anwendungsfall, funktionale Anforderungen, Nicht-funktionale Anforderungen, Risiken)
- **AP2:** Datenakquise & semantische Beschreibung
Erhebung von Daten sowie Bewertung deren Qualität (iterativer Prozess zur Generierung einer Datenbasis für die Entwicklung datengetriebener Verfahren)

- **AP3:** Konzept zur Wissensmodellierung
Erhebung und Verknüpfung von Expertenwissen mit der Datenanalyse z.B. zur Evaluierung datengetriebener Ergebnisse
- **AP4:** Auswahl der Machine-Learning-Methoden für die Anwendungsfälle
Auswahl von Methoden abhängig vom Anwendungsfall (Komplexität der Methoden vs. Rechenintensität) und der Datengrundlage (Verfügbarkeit der Daten, Vollständigkeit etc.).
- **AP5+6:** Konzept und Konzeptbewertung des Agentensystems
Entwicklung von wiederverwendbaren Mustern für Agenten und Evaluierung dieser.
- **AP7+8:** Anwendung der Methoden an Laboranlagen und industriellen Pilotanlagen
Umsetzung der Methoden zuerst an Laboranlagen und später an industriellen Pilotanlagen.
- **AP9:** Evaluation
Bewertung der Projektergebnisse

2 Ergebnisse

Die verschiedenen Anwendungsfälle mit ihren spezifischen funktionalen sowie nicht-funktionalen Anforderungen und Risiken wurden in AP1 für das Projekt identifiziert und strukturiert (vgl. Tabelle 1). Gemeinsame Herausforderung ist die Entwicklung von datengetriebenen Verfahren zur Anwendung in der Produktion.

Tabelle 1: Zusammenfassung der im Projekt definierten Anwendungsfälle.

Anwendungsfall	Funktionale Anforderungen	Nicht-Funktionale Anforderungen	Risiken
Alarmmanagement: Alarmfluten verhindern die Behebung von Fehlern und die Erkennung der Ursachen; Reduzierung von Alarmfluten + Identifikation der Ursachen notwendig.	<ul style="list-style-type: none"> • Identifizierung von Alarmsequenzen / -clustern • Detektion der Zeitstruktur innerhalb der Alarme • Identifizierung von Ursachen (Root Causes) 	<ul style="list-style-type: none"> • Verknüpfung der Alarmdaten mit Prozessdaten • Erweiterung der Algorithmen zur Berücksichtigung zusätzlich verfügbarer Informationen (z.B. Betriebsmodi) 	<ul style="list-style-type: none"> • Korrelationen werden fälschlich als Kausalitäten interpretiert • Detektierte Muster können nicht validiert werden
Überwachung der Produktqualität in hydraulischen Metallpulverpressen: Bauteildefekte wie Risse erst spät und unter großem Aufwand erkennbar; Notwendigkeit der Online-Überwachung anhand des Prozessverlaufs.	<ul style="list-style-type: none"> • Anomaliedetektion anhand Kraft- und Positionsdaten • Unüberwachtes Lernen: spezifische Fehlerbilder sind nicht bekannt • Spezifizierung von charakteristischen Merkmalen und Toleranzschwellen 	<ul style="list-style-type: none"> • Meldung/Visualisierung der Anomalie • Nicht erkannte Anomalie schwerwiegender als Fehlalarm • Übertragbarkeit auf unterschiedliche Pressen und Bauteile 	<ul style="list-style-type: none"> • Hohe Fehlalarmquote durch unvorhergesehene Einflussgrößen • Modell genießt kein Vertrauen bei Kunden/Bedienern
Condition Monitoring: Zustandsüberwachung von Hydrauliksystemen zur Vermeidung ungeplanter Stillstände.	<ul style="list-style-type: none"> • Identifizierung relevanter Sensoren • Unüberwachtes Lernen: spezifische Fehlerbilder sind nicht bekannt • Isolation von Anomalien: Welches Bauteil ist für eine Anomalie ursächlich? 	<ul style="list-style-type: none"> • Nachvollziehbarkeit der Analyse zur Schaffung von Vertrauen in die Ergebnisse • Übertragbarkeit auf Hydrauliksysteme mit leicht unterschiedlichem Aufbau 	<ul style="list-style-type: none"> • Hohe Fehlalarmquote durch die Vielzahl an Umgebungseinflüssen • Nicht alle relevanten Parameter verfügbar • Abstraten für manche Fehlerbilder nicht hoch genug

Anwendungsfall	Funktionale Anforderungen	Nicht-Funktionale Anforderungen	Risiken
Wissensmanagement in der Instandhaltung: Analyse von Instandhaltungsmeldungen zur Verbesserung des Instandhaltungsprozesses.	<ul style="list-style-type: none"> Clustering von Meldungen auf Basis von Text Mining Ausgabe von ähnlichen, vergangenen Meldungen zur Unterstützung des Instandhalters bei der Diagnose 	<ul style="list-style-type: none"> Sehr spezielles technisches Vokabular Abkürzungen, Umgangssprache etc. müssen verarbeitet werden 	<ul style="list-style-type: none"> Aussagekraft der kurzen Meldungen limitiert Cluster können nicht von den Experten validiert werden
Datenreduktion: Integration und Aggregation von Daten mehrerer Maschinen stellen hohe Anforderungen an das Netzwerk. Reduktion des Datenvolumens soll das Netzwerk entlasten.	<ul style="list-style-type: none"> Bandbreitebedarf pro Nachricht reduzieren Minimaler Informationsverlust Vorverarbeitung der Daten nahe der Datenquelle (direkt auf der SPS) Geringe Rechenlast 	<ul style="list-style-type: none"> Entwicklung von Methoden, die auf unterschiedliche Signale angewandt werden können Zuverlässige Datenvorverarbeitung ohne Störung des Betriebs der Maschine 	<ul style="list-style-type: none"> Methoden zu komplex, um Datenvorverarbeitung auf der SPS durchzuführen Datenreduktion nur mit hohem Informationsverlust

Eine Vielzahl an Daten sind für die verschiedenen Anwendungsfälle in AP2 erhoben worden (vgl. Tabelle 2). Diese dienen als Basis für die im Projekt erzielten Ergebnisse.

Tabelle 2: Im Projekt verfügbare bzw. erhobene Datensätze.

Anwendungsfall	Maschine	Datenpunkte	Beschreibung
Alarmmanagement	Reifenbaumaschine	3.680.000	Daten von 4 verschiedenen Maschinen; jeweils zwei typengleich
	Werkzeugmaschine 1	1.292.880	Daten von 3 typengleichen Maschinen
Qualitätsüberwachung	Hydraulische Metallpulverpresse	2.510.220	Prozessdaten von 5457 produzierten Presslingen
Condition Monitoring	Werkzeugmaschine 2	29.870.000	Prozessdaten (Temperaturen, Druck) über 1 Jahr
Wissensmanagement	Werkzeugmaschine 1	10.000	Instandhaltungsmeldung mit im Median 37 Wörtern pro Meldung
Datenkomprimierung	Hydraulische Metallpulverpresse	2.510.220	Prozessdaten von 5457 produzierten Presslingen
	Laboranlage Hybrides Prozessmodell an der TUM	kontinuierliche Erhebung von Prozessdaten	Prozessdaten eines Servomotors

Die in den Arbeitspaketen AP3-9 durchgeführten Forschungsarbeiten und deren Ergebnisse lassen sich in drei Bausteine untergliedern:

- Datenanalysearchitektur als Voraussetzung für die Umsetzung von datengetriebenen Methoden im laufenden Betrieb: Modellierung der Systeme und der Datenflüsse zur Schaffung eines disziplinübergreifenden Verständnisses (Kapitel 2.1).
- Algorithmen und maschinelle Lernverfahren zur Mustererkennung, Qualitäts- und Zustandsüberwachung (Kapitel 2.2).
- Agentensystem zur flexiblen Adaption von maschinellen Lernverfahren an sich verändernde Parameter (Kapitel 2.3).

Die entsprechenden Forschungsergebnisse sind in den folgenden Unterkapiteln weiter ausgeführt.

2.1 Entwicklung und Modellierung von Datenanalysearchitektur

Bevor Daten überhaupt analysiert und ein Nutzen aus diesen generiert werden kann, müssen diese zunächst in geordneter Form gesammelt werden. Weiterhin sind für eine kontinuierliche Überwachung von Anlagen im Gegensatz zur Datenanalyse historischer Datensätze auch Echtzeit-Daten aus der Produktionsanlage notwendig. Echtzeit bezieht sich hierbei auf ein kontinuierliches Übertragen (Streaming) der Daten von der Quelle zur Analyse mit, je nach Anforderungen, unterschiedlichen Zeitanforderungen hinsichtlich erlaubter Latenz und Jitter.

Eine der zentralen Herausforderungen bei der Nutzung von Datenanalysemethoden im Produktionsumfeld ist die Heterogenität der Domäne, welche sich in verschiedenen Aspekten zeigt:

- Vielzahl an unterschiedlichen Herstellern, Bussystemen und Datenquellen auf der Feldebene. Darüber hinaus das Vorhandensein von sogenannten Legacy-Quellen, also Altsystemen mit sehr begrenzten Kommunikationsfähigkeiten.
- Notwendigkeit, verschiedene weitere Datenquellen, z.B. Manufacturing Execution Systeme (MES) oder Engineeringsysteme, nutzbar zu machen. Diese Systeme sind klassischerweise reine IT-Softwarelösungen, der Zugriff auf die hierin gespeicherten Daten gestaltet sich jedoch je nach verwendetem System sehr unterschiedlich.
- Vielzahl an Kommunikationslösungen und -protokollen, welche sich im Zuge der Industrie 4.0-Offensive, aber auch aus anderen Domänen, z.B. dem (Industrial) Internet of Things, der Analyse von Logdateien etc. etablieren.

Um eine weitreichende Informationsintegration und Verfügbarkeit der Daten sicherzustellen bedarf es deshalb skalierbarer Systemarchitekturen, welche das Sammeln und die Verarbeitung von Daten aus heterogenen Quellen erlauben, und hierbei gleichzeitig auf etablierte Standardprotokolle fußen. Des Weiteren ist die Nutzbarmachung von Altsystemen, bspw. installierten Speicherprogrammierbaren Steuerungen (SPS), und der Zugriff auf hierin gespeicherten Daten essenziell für die Etablierung von Datenanalysen im Produktionsumfeld.

Zunächst wurden deshalb verfügbare Protokolle, welche in der Literatur für verschiedene Zwecke im Themenblock industrielle Datenanalyse verwendet werden, auf ihre jeweiligen Eigenschaften untersucht. Ziel war die Klassifikation der Protokolle hinsichtlich Architekturmuster, sowie Sicherheitsaspekten und Verfügbarkeit von Implementierungen. Die Studie wurde weiterhin durch kurz zuvor veröffentlichte Protokollspezifikationen zum noch neuen OPC UA PS (Publish Subscribe) ergänzt. Die Ergebnisse dieser Untersuchung sind in Tabelle 3 zusammengefasst. Aus der Klassifikation lassen sich direkt keine Entscheidungen für ein bestimmtes Protokoll ableiten. Es zeigt sich vielmehr, dass je nach Anforderungen an die Systemarchitektur und Protokollunterstützung vorhandener Systeme entschieden werden muss. Weiterhin ist die Kombination von Protokollen denkbar und ggf. von Vorteil: So setzt sich innerhalb des europäischen Marktes auf Feldebene derzeit OPC UA durch, während für IT-Anwendung klassischerweise das AMQP-Protokoll (Advanced Message Queuing Protocol) Verwendung findet. Eine Kombination der Protokolle, vor allem durch Verwendung des neuen OPC UA PS-Standards unter Verwendung eines AMQP-Brokers zur Übermittlung von Informationen über OPC UA ist hier also sehr vielversprechend. Weiterhin existiert ein definiertes Mapping zwischen OPC UA und dem im amerikanischen Markt verbreiteteren DDS (Data Distribution System) Standard.

Tabelle 3: Vergleich verschiedener Protokolle/Middlewarelösungen für die Realisierung von Datenanalyse- und -sammelarchitekturen hinsichtlich Kommunikationsaspekten, zugrundeliegendem Transportprotokoll und Eigenschaften.

Kriterium	DDS	Kafka	AMQP	OPC UA			MQTT	REST	CoAP	MTConnect
				Standard	PS					
					UADP	Broker				
Messaging-Muster	PS	PS	PS	RR	PS & RR	PS	RR	RR	PS & RR	
Protokoll	UDP	TCP	TCP	TCP	UDP	TCP	TCP	TCP	UDP	TCP
Architektur	DZ	V	Z	DZ	DZ	Z	Z	DZ	DZ	DZ
QoS	++	-	+	-	+	-	+	-	+	-
Verschlüsselung	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓
Authentifizierung	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓
Open Source Anbieter	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓
Anzahl Anbieter	5-10	1	>10	>10	1	0	>10	>10	>10	>10
Besitzer Standard	OMG	Open	ISO/IEC	IEC	OPC Foundation		ISO/IEC	Open	IETF	MTC

PS: Publish-Subscribe; RR: Request-Response; DZ: Dezentralisiert; Z: Zentralisiert; V: Verteilt

Aus diesem Grund wurden anschließend zunächst verschiedene Feldstudien und beispielhafte Implementierungen unter Verwendung unterschiedlicher Protokolle konzeptioniert und im Labormaßstab umgesetzt, um die Auswirkungen auf Architekturentscheidungen und der Leistungsfähigkeit des Systems untersuchen zu können. Problematisch an der Heterogenität der Protokolle ist der enorme Aufwand, welcher entsteht, wenn ein Maschinenhersteller gemäß Kundenanforderungen mehr als eines dieser Protokolle zur Verfügung stellen/bedienen muss. Aus diesem Grund wurde ein technologie-agnostischer Ansatz entwickelt, welcher die jeweiligen protokollspezifischen Programmierschnittstellen hinter einer abstrahierten Standardschnittstelle mit Unterstützung der wichtigsten Funktionalitäten kapselt. Tests im Labormaßstab zeigten hier, dass eine deutliche Reduktion des Programmieraufwands und der Komplexität der Programme erzielt werden kann (teilweise 50% Aufwandsreduktion).

Eine weitere Hürde bei der Konzeptionierung und Umsetzung von Datenanalysearchitekturen ist neben der Komplexität der Umsetzung und der Heterogenität der Systeme auch die Beteiligung mehrerer Fachdisziplinen: Neben der IT-Abteilung, welche oftmals mit der Umsetzung beauftragt wird, sind auch Automatisierungstechniker für die Anbindung der Produktionsanlagen, aber auch Datenanalysten für die Auswertung der Daten ebenso wie Prozessexperten, welche die Ziele der Datenanalyse durch ihr Prozessverständnis definieren und evaluieren können, beteiligt. Mit dieser Beteiligung verschiedener Fachdisziplinen geht auch die Verwendung verschiedenen Vokabulars einher. Zwischen den Disziplinen kommt es deshalb häufig zu Abstimmungsschwierigkeiten. Während in den einzelnen Disziplinen zum Teil bereits Methoden und Ansätze zur Strukturierung und zum Austausch des vorhandenen Wissens existieren, ist dies disziplinübergreifend für Datenanalyse- und -sammelarchitekturen noch nicht der Fall.

Aus diesem Grund wurde eine grafische Notation entwickelt, welche die disziplinübergreifende Beschreibung der Systemarchitektur sowie der zugrundeliegenden Datenflüsse erlaubt. Die Notation trennt hierbei zwischen verschiedenen Ansichten, verfügt zur Steigerung des Verständnisses über verschiedene grafische Symbole, und ermöglicht die Ergänzung der Architekturbeschreibung mittels der Annotation von Eigenschaften (gemessene, ausgeprägte Werte) sowie Anforderungen (zu realisierend). Hierdurch kann die Notation sowohl zur Beschreibung und zum Retrofitting bestehender Automatisierungs-/Datenanalysearchitekturen genutzt werden, als auch ein wertvolles Werkzeug beim Design neuer Datenanalysearchitekturen darstellen. Abbildung 2 zeigt beispielhaft die modellierte Systemarchitektur eines industriellen Anwendungsfalls der beteiligten Industriepartner.

Die grafische Sprache wurde zudem in Anwendungsstudien zusammen mit den industriellen Partnern auf ihre Eignung und grafische Qualität evaluiert. Hierzu wurde für jeden Partner ein für M@OK exemplarischer Anwendungsfall ausgewählt und die bestehende Systemarchitektur zusammen mit den jeweiligen Experten modelliert. Anschließend wurden aus Datenanalyse-sicht neue Analysefunktionalitäten modelliert und hierdurch weiterhin Anforderungen an die Datenerhebung, die Abtastung der Signale etc. formuliert. Im nächsten Schritt wurde dann eine geeignete Systemarchitektur zur Sammlung und Analyse der Daten konzeptioniert. Im letzten Schritt wurden sowohl die Notation als auch die Modelle innerhalb von Interviews mit den jeweiligen Experten evaluiert. Es zeigte sich über alle Anwendungsfälle hinweg eine große Zufriedenheit mit der grafischen Notation. Hervorgehoben wurden insbesondere die hohe Übersichtlichkeit und das einfache Verständnis bei der Anwendung der Sprache. Weiterhin waren alle Experten der Ansicht, dass die grafische Notation bei der Abstimmung und der Entwicklung der Systemarchitekturen ein sehr hilfreiches und förderliches Werkzeug darstellt.

Ausgehend von der grafischen Notation und der Betrachtung einer technologie-agnostischen Programmierbarkeit der zugrundeliegenden Kommunikationsarchitektur wurde daher ein modellbasierter Ansatz zur Entwicklung von Datensammel- und -analysearchitekturen erforscht. Hierzu wurde die grafische Notation um ein zugehöriges Metamodell erweitert, welche das modellierte Wissen formalisiert und computerauswertbar speichert. Hierdurch wurde aus der grafischen Notation eine vollwertige Domänenspezifische Sprache entwickelt. Weiterhin wurde die erforschte, abstrahierende Programmierbibliothek deutlich erweitert und verbessert. Durch eine zusätzlich entwickelte Modelltransformation, welche die vorhandenen Architekturmodelle unter Verwendung der Codebausteine aus der Bibliothek in ausführbaren Code umwandelt, konnte somit die Kommunikationsarchitektur fast vollständig aus den grafischen Modellen abgeleitet werden – ein händisches Programmieren war nur noch in sehr begrenzten Umfang notwendig. Der Ansatz wurde anhand eines umfangreichen Experiments im Labormaßstab evaluiert, aber auch auf Anwendbarkeit auf einen der

zuvor industriell modellierten Anwendungsfälle untersucht. Es zeigte sich über beide Anwendungsfälle eine deutliche Aufwandsreduktion für die Realisierung der Kommunikationsarchitektur von bis zu 87%.




Abbildung 2: Beispiel der Systemansicht der grafischen Notation für einen der industriellen Anwendungsfälle.

In einer weiteren Generalisierungsstudie wurden die Aufwände auf Basis einer Extrapolation untersucht. Auch hier zeigte sich bei realistisch großen Systemen, selbst unter Berücksichtigung des Entwicklungsaufwands für Sprache, Bibliothek und Modelltransformation, eine immense Aufwandsreduktion. Die hierfür notwendigen Systemgrößen sind zwar bei den Partnern nicht mit einem einzelnen System realisierbar, durch die hohe Wiederverwendbarkeit der Lösung und entsprechende Mehrfache Anwendung der Lösung sind die abgeschätzten Systemgrößen aber in einer realistischen Größenordnung um die Entwicklung des Ansatzes zu rechtfertigen. Weiterhin könnte die Lösung durch Dienstleister / ein Systemhaus angeboten werden, um so weitere Synergien zwischen den Anwendungsfällen nutzen zu können und den Aufwand für die Entwicklung der Werkzeugkette weiter aufzuteilen.

2.2 Entwicklung von Anwendungen des maschinellen Lernens

Im maschinellen Lernen wird in drei Kategorien unterschieden, dem überwachten (supervised), dem unüberwachten (unsupervised) und dem verstärkenden (reinforcement) Lernen. Während beim überwachten Lernen der Zusammenhang zwischen den Input-Parametern und den bekannten Output-Parametern trainiert wird, liegen beim unüberwachten Lernen keine Output-Parameter vor. Deshalb werden beim unüberwachten Lernen ausschließlich Struktur und Charakteristika der Input-Parameter genutzt, um Muster zu erkennen. Beim verstärkenden Lernen lernt der Algorithmus basierend auf dem Feedback, welches er als Ergebnis auf seine Aktionen/getroffenen Entscheidungen erhält.

In der industriellen Anwendung sind die Output-Parameter meist nicht bekannt bzw. sind nur mit einem erheblichen Aufwand zu den Input-Parametern zuordenbar. Zudem liegt eine sehr große Vielfalt an unterschiedlichen Maschinen und Anlagen vor, was das Generieren von Trainingsdatensätzen mit der Verbindung von Input- und Output-Parameter zusätzlich erschwert. Aus diesem Grund sind unüberwachte Lernverfahren im industriellen Einsatz von besonderem Interesse. Sie können genutzt werden, um Muster in Sensor- und Aktordaten zu identifizieren, ohne zuvor einen aufwendigen Trainingsdatensatz aus Input- und Output-Parametern zu generieren. Im Projekt finden unüberwachte

Lernverfahren in unterschiedlichen Anwendungen ihren Einsatz (Alarmmanagement, Qualitätsüberwachung, Zustandsüberwachung und Text Mining von Instandhaltungsmeldungen). Es wird gezeigt, dass auch unüberwachte Lernverfahren einen maßgeblichen Beitrag zur Steigerung der OEE beitragen können und flexibel einsetzbar sind.

2.2.1 Alarmmanagement

Das Entstehen von Alarmfluten aufgrund eines sich propagierenden Fehlers an einer Maschine verzögert die Diagnose und damit die Fehlerbeseitigung und die Wiederinbetriebnahme der Maschine. Grund hierfür ist, dass die große Zahl der aktiven Alarme die Bestimmung des ursächlichen Fehlers und hierdurch dessen Beseitigung erheblich erschwert. TUM, Grob und Conti haben daher in diesem Projekt Verfahren des maschinellen Lernens angewendet, um Alarmsequenzen datengetrieben zu erkennen und Ursprungsalarme zu identifizieren. Die Herausforderung hierbei ergibt sich aus der Struktur der historischen Alarmdaten, welche zum Training der Verfahren herangezogen werden. Zufällig auftretende Alarme, welche die Alarmsequenzen unterbrechen (siehe Abbildung 3 links), sowie eine vertauschte Reihenfolge von Alarmen (siehe Abbildung 3 zweite von links) beeinträchtigen das Erkennen von eindeutigen Sequenzen. Hinzu kommen flatternde Alarme (siehe Abbildung 3 dritte von links), welche zwischen aktiv und nicht aktiv innerhalb kürzester Zeit mehrere Male hin und her springen. Diese entstehen unter anderem, wenn die Dynamik des Systems die Hysterese bei Schwellwertalarmen übersteigt. Die dynamischen Zeitdifferenzen zwischen den Alarmen einer Sequenz (siehe Abbildung 3 rechts) stellen eine weitere Herausforderung dar. Basierend auf den unterschiedlichen Modi und Geschwindigkeiten einer Maschine, z.B. Automatik und Handbetrieb, zeigen Alarmsequenzen verschiedene Zeitstrukturen.




Abbildung 3: Herausforderungen in historischen Alarmdaten.

Zur Lösung dieser Herausforderungen wurden abhängige Alarme im Projekt mittels einer Self-Organizing-Map (SOM) geclustert. Dieses unüberwachte Lernverfahren ermöglicht es, ähnliche Alarme auf Basis der Häufigkeit des Auftretens zu clustern. Um innerhalb dieser Cluster Alarmsequenzen zu identifizieren wurden Markov-Ketten eingesetzt. Die Übergangswahrscheinlichkeit zwischen einzelnen Alarmen und der Ausgangspunkt einer Sequenz kann somit ermittelt werden (siehe Abbildung 4 a)). Beim Auftreten einer Alarmflut kann dem Bediener die Sequenz und der Ursprungsalarm angezeigt werden, was die Diagnose und Behebung des Problems beschleunigen. Ein anderer Ansatz, welcher im Projekt erarbeitet wurde, unterteilt die historischen Alarme in Cluster basierend auf der Ähnlichkeit einzelner Alarmfluten (Jaccard Distanz). Die Alarmfluten eines Clusters werden anschließend anhand der Transfer-Entropy in einzelne Sequenzen zerlegt (siehe Abbildung 4 b)). Vorteil dieses zweiten Ansatzes ist, dass im Gegensatz zur Self-Organizing-Map Alarme mehreren Clustern und Sequenzen zugeordnet werden können. Dies ist aus technischer Sicht erforderlich, da ein Alarm je nach Umstand in Zusammenhang mit verschiedenen Fehlern stehen kann. Aus diesem Grund ist der zweite Ansatz zu bevorzugen.

Die Evaluierung basiert auf der Beurteilung der Experten. Ausgewählte Cluster und Sequenzen wurden auf ihre Plausibilität geprüft. Auf Basis häufig auftretender Effekte, z.B. regelmäßige automatische Testläufe, welche mit einer hohen Zahl an Meldungen verbunden sind, konnte die Validität der Ansätze bestätigt werden. Die gefundenen Sequenzen können retrospektiv durch die Experten erklärt werden.

Die in diesem Projekt erfolgreich identifizierten Alarmsequenzen können zum einen dazu genutzt werden, um Bediener und Instandhalter bei der Diagnose von Maschinenstillständen zu unterstützen. Der Ursprungsalarm oder auch mehrerer Ursprungsalarme bei sich überlagernden Fehlerfällen werden durch die Sequenzen aufgezeigt und unterstützen somit bei der Ergreifung geeigneter Maßnahmen. Zum anderen können die gewonnenen Informationen genutzt werden, um die Maschinen zu verbessern. Häufige Alarmfluten können durch ein Reengineering der Komponenten oder durch Anpassungen im Alarmmanagement behoben werden.

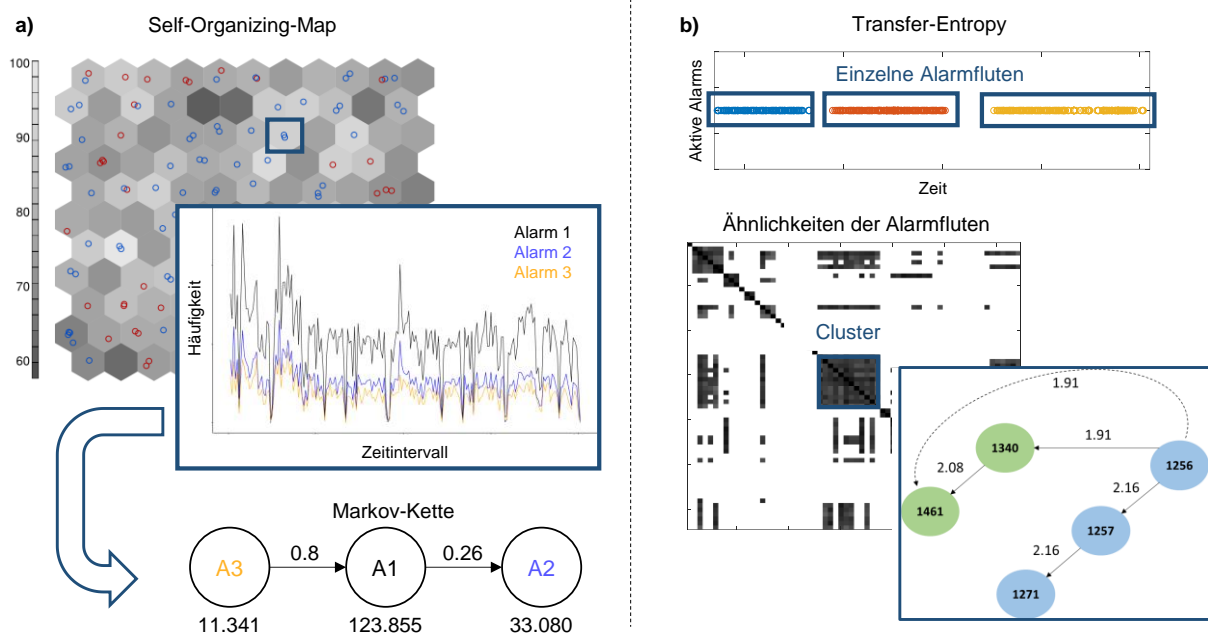


Abbildung 4: Alarmmanagement – alternative Ansätze: a) Clustern der Alarme durch eine Self-Organizing-Map auf Basis der Häufigkeit des Auftretens (Zeitdiagramm). Bildung von Markov-Ketten pro Cluster. b) Aufteilen der Alarme in einzelne Alarmfluten und Vergleich der Ähnlichkeit mittels Jaccard Distanz. Ermittlung der Beziehungen innerhalb eines Clusters auf Basis der Transfer Entropy

2.2.2 Qualitätsüberwachung an hydraulischen Metallpulverpressen

Bauteile wie Zahnräder werden häufig auf Pressen gefertigt. Beim hier betrachteten Pressentyp wird über eine Hydraulik ein Pressdruck auf Metallpulver ausgeübt, um einen formstabilen Grünling zu erhalten. Das fertige Bauteil, welches auf die Bauteilqualität geprüft werden kann, erhält man jedoch erst nach dem Sintern des Grünlings. Selten vorkommende Defekte wie ein Riss im Bauteil können deshalb erst spät im Prozess erkannt werden. Gemeinsam mit TUM hat Dorst daher ein datengetriebenes Verfahren auf Basis der Sensor- und Aktordaten der hydraulischen Metallpulverpresse entwickelt, um die Qualität bereits während des Pressens zu überwachen. Aufgrund der Datenlage bieten sich hierzu lediglich unüberwachte Lernverfahren an. Denn eine Verknüpfung der Sensor- und Aktordaten mit den Daten der Qualitätsprüfung liegt nicht vor. Darüber hinaus stellt die hohe Variabilität eine große Herausforderung dar: jede spezifische Geometrie der zu fertigenden Bauteile verursacht eine Änderung im Zusammenspiel der unterschiedlichen Achsen einer hydraulischen Metallpulverpresse. Anstatt eines einzelnen Qualitätsmodells müssen daher bauteilspezifische Modelle trainiert werden. Im Projekt wurden zwei Ansätze verglichen, die eine Qualitätsüberwachung auf Basis weniger Vergleichsreihen ermöglichen. Zum einen kann über Dynamic Time Warping (DTW) die Distanz zwischen den Sensordaten zweier Bauteile ermittelt werden. Zeigt ein Bauteil eine unverhältnismäßig große Distanz zu den anderen Bauteilen auf, kann von einer Anomalie im Prozessablauf und damit auf mögliche Qualitätsdefekte geschlossen werden (siehe Abbildung 5 a). Zum anderen kann eine einfache Regression zwischen Aktor- und Sensordaten, z.B. über eine Random Forest Regression (RFR), dazu genutzt werden das Verhalten der Presse auf Basis einiger Bauteile zu trainieren. Weicht dieses Verhalten bei zukünftigen Bauteilen ab, ist eine Anomalie detektiert (siehe Abbildung 5 b).

Da nur bestimmte Phasen des Prozesses für das Entstehen von Bauteildefekten, wie z.B. Risse, maßgeblich verantwortlich sind, müssen die Signale vor der Anomaliedetektion vorverarbeitet werden. Ziel ist es, die unterschiedlichen Phasen des Prozesses zu identifizieren, zu trennen und nur relevante Phasen weiter zur verarbeiten. Mittels Experten wurden die Zeitreihen verschiedener Bauteile und Pressen (Größe, maximale Kraft, Antriebssystem) händisch in ihre Phasen segmentiert. Vorteil ist, dass der Pressprozess stets einem vorgegebenen Verlauf folgt, welcher bei jedem Bauteil und Pressentyp gleiche Charakteristiken aufweist. Das aufwändige Markieren der Daten durch die Experten muss somit nur einmal und für eine geringe Anzahl an Zeitreihen durchgeführt werden. Auf Basis von 20 markierten

Zeitreihen wurde im Projekt eine Klassifikation trainiert. Die Segmentierung auf einer neuen Zeitreihe ist in Abbildung 6 gezeigt. Die Phasen sind korrekt getrennt und die Anomaliedetektion kann anschließend über die relevanten Phasen 3 und 4 ausgeführt werden.

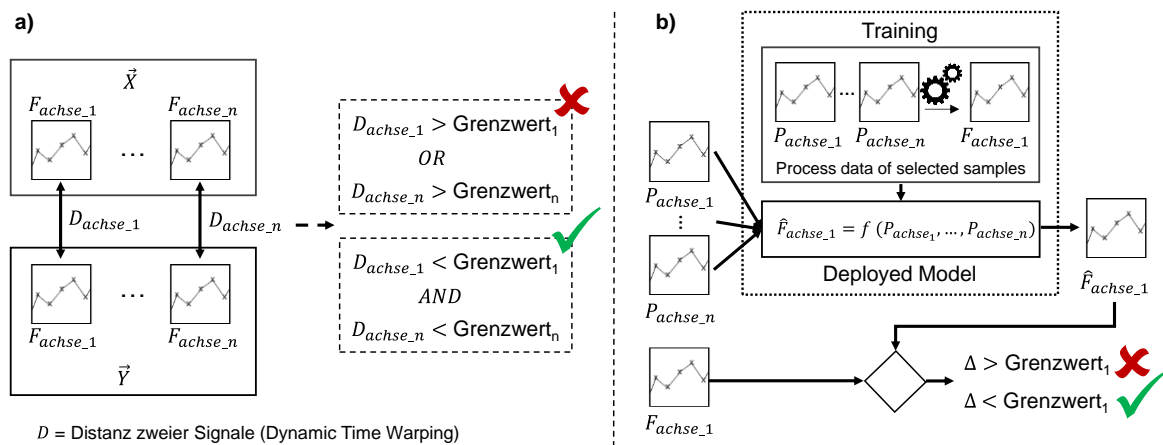


Abbildung 5: Qualitätsüberwachung in hydraulischen Metallpulverpressen a) mittels Dynamic Time Warping b) mittels Random Forest Regression.




Abbildung 6: Segmentierung des Prozessverlaufs in seine Phasen.

Die Evaluation der beiden Methoden DTW und RFR auf einem Datensatz mit 37 Bauteilen, wovon 2 einen Bauteildefekt aufweisen, zeigt die Effizienz der Algorithmen. Beide Ansätze können die beiden Bauteildefekte in den Daten identifizieren. Fehleralarme werden von DTW 4 und von RFR 7 verursacht (siehe Tabelle 4). Während DTW damit eine leicht bessere Treffsicherheit erreicht, wird aufgrund des paarweisen Vergleichs von Signalen ein erheblicher Rechenaufwand verursacht. Für eine Überwachung im Maschinentakt (circa alle 8 Sekunden wird ein Bauteil fertig) legt die Rechenlast klare Grenzen auf.

Die entwickelten Methoden ermöglichen eine datengetriebene Überwachung der Qualität bereits während der Produktion. Die arbeitsintensive manuelle Prüfung kann dann auf Bauteile mit anomalen Prozessablauf beschränkt werden. Gegenüber einer stichprobenartigen Prüfung können somit Ressourcen eingespart und eine höhere Detektionsrate von Bauteildefekten erreicht werden.

Dieser Ansatz ist auf andere Prozesse übertragbar. Voraussetzung ist, dass das Verfahren ein sich stetig wiederholender Prozess darstellt, dessen Verlauf im besten Fall in jeder Wiederholung identisch ist wie zum Beispiel beim Abkanten von Blechen.

Tabelle 4: Konfusionsmatrix der Anomaliedetektion mittels DTW und RFR.

		tatsächlich		Summe
		Anomalie	Keine Anomalie	
DTW / RFR	Anomalie	2 / 2	4 / 7	6 / 9
	Keine Anomalie	0 / 0	31 / 28	31 / 28
Summe		2 / 2	35 / 35	37 / 37

2.2.3 Condition Monitoring in hydraulischen Systemen

Ein hydraulisches System ist ein komplexes System mit einer Vielzahl an Einzelkomponenten, z.B. Pumpen, Ventilen und Rohrleitungen. Die Gewährleistung der Funktion dieses Systems ist daher von einer Vielzahl von Parametern abhängig. Datengetriebene Methoden können eingesetzt werden, um die Parameter des Systems zu überwachen und dessen aktuellen Zustand zu bestimmen. Stillstände des Systems und schwerwiegendere Ausfälle sollen verhindert werden, indem ein frühzeitiges Eingreifen auf Basis der Zustandsüberwachung ermöglicht wird. Eine Herausforderung stellt die Datengrundlage dar. Die Erhebung von Daten aller möglichen Fehler eines solchen Systems übersteigt für gewöhnlich die Kosten-Nutzen-Relation. Aus diesem Grund muss auch in diesem Anwendungsfall auf unüberwachte Lernverfahren zurückgegriffen werden. Um nicht nur Anomalien des Systems zu detektieren (Detektion), sondern auch die mögliche Ursache zu identifizieren (Isolation), werden verschiedene Algorithmen zur Anomaliedetektion adaptiert und weiterentwickelt. In Zusammenarbeit zwischen HAWE und TUM wurden vier Modelle an industriellen Daten getestet. Der Ansatz des One-Class Nearest Neighbor Verfahrens hat dabei die besten Ergebnisse gezeigt. Anhand eines Trainingsdatensatzes, welcher den Normalbetrieb des Systems darstellt, kann das Gutverhalten trainiert werden. Neue Daten aus dem laufenden Betrieb können anschließend mit dem Gutverhalten verglichen werden: weichen diese erheblich vom Gutverhalten ab, ist eine Anomalie erkannt. Die Distanzen zwischen den Datenpunkten werden als Features verwendet (vgl. Abbildung 7 a). Sind die Distanzen $D_1 - D_3$ erheblich größer als die Distanzen $D_{11} - D_{33}$ wird von einer Anomalie ausgegangen. Zur Bestimmung eines Grenzwertes wurden statistische Kennwerte, wie Mittelwert bzw. Quantile, herangezogen. Die Isolation der Anomalie (Identifizierung möglicher Ursachen) erfordert eine weitere Aufschlüsselung der Distanzen. Diese ist in Abbildung 7 b) für den 2-dimensionalen Raum graphisch dargestellt. Sind die Distanzen D_1 und D_2 auf eine ungewöhnlich hohe Abweichung eines einzelnen Systemparameters x_1 oder x_2 zurückzuführen, kann dieser als Ursache für die Anomalie angesehen werden. Als Merkmal wird der Anteil der einzelnen Parameter d_1x_1 bis d_2x_2 an der Distanz D_i ermittelt.

Zur Evaluation wurden historische Daten verwendet, welche von Experten vorab markiert wurden. Fünf Schlechtzustände zu unterschiedlichen Zeitpunkten konnten durch die Experten in den Daten identifiziert werden, wobei ein Totalausfall durch Schaden des Hydraulikaggregates nicht vorhanden war. Diese fünf Datenreihen und weitere Gutzustände wurden zum Testen des trainierten Modells eingesetzt. Das vorgestellte One-Class Nearest Neighbor Verfahren konnte alle Schlechtzustände korrekt erkennen. Ein Beispiel für ein Gutverhalten und zwei Beispiele für Schlechtzustände sind in Abbildung 8 abgebildet. Nimmt der Parameter „Anomalie“ den Wert 1 an, ist zu diesem Zeitpunkt eine Unregelmäßigkeit detektiert. Die kurzzeitigen Ausschläge des Modells im Gutzustand (Abbildung 8 links) sind auf Rauschen zurückzuführen. Solange der Wert nicht über einige Zeitpunkte hinweg den Wert 1 annimmt, wird keine Anomalie gemeldet. In den beiden gezeigten Schlechtzuständen nimmt das Modell über die meisten Zeitpunkte hinweg den Wert 1 an. Eine Anomalie wird erkannt.

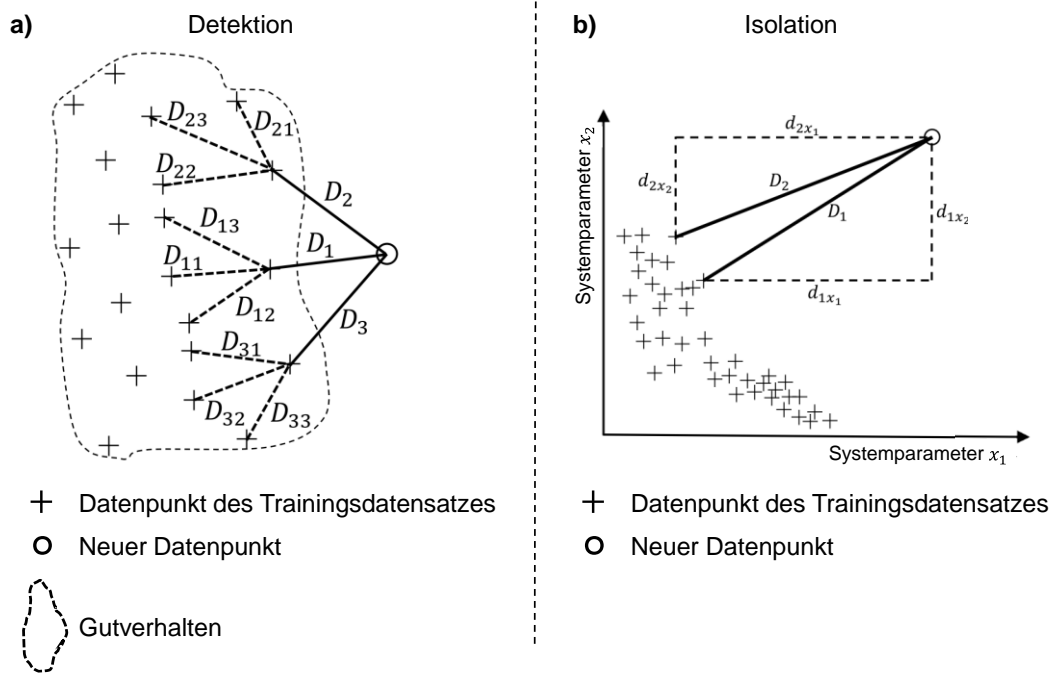


Abbildung 7: Anomaliedetektion (a) und -isolation (b) mittels One-Class Nearest Neighbor Verfahren.

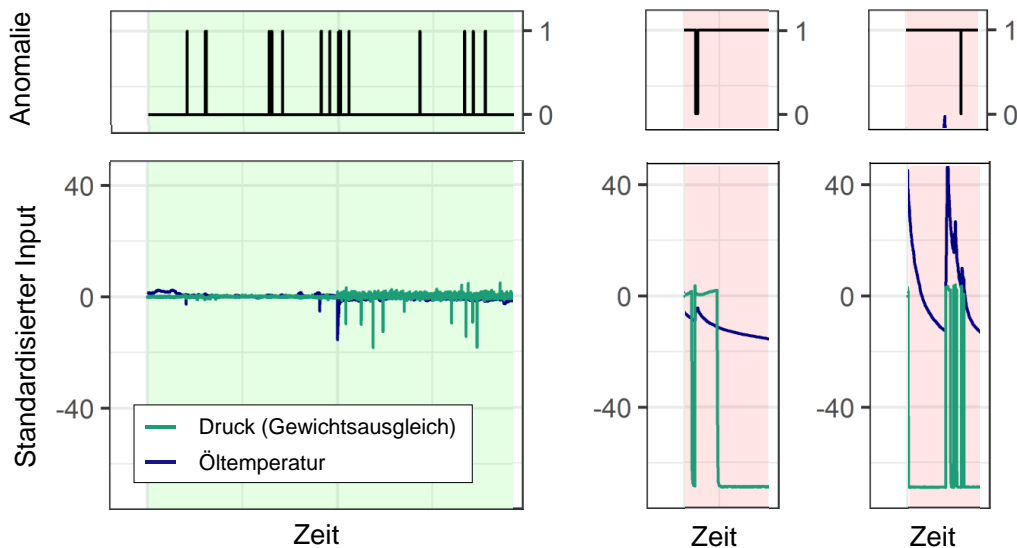


Abbildung 8: Ergebnis des One-Class Nearest Neighbor Verfahrens am Beispiel eines Gutzustands (grün) und zwei Anomalien (rot).

Die entwickelte Methode zur Anomaliedetektion und -isolation unterstützt das Instandhaltungsmanagement für hydraulische Systeme. Wird durch das Modell eine Anomalie angezeigt, kann der Maschinenführer die Fahrweise der Maschine anpassen und einen Instandhaltungsfall aufgeben. Entsprechende Maßnahmen können geplant werden, ohne den Prozessablauf zu stören. Zudem können unerwartete Stillstände vermieden und somit die Verfügbarkeit der Maschine erhöht werden. Der entwickelte Ansatz eignet sich hierdurch zur Anwendung in einer Vielzahl von Maschinen- und Anlagentypen mit hydraulischen Systemen.

2.2.4 Text Mining in Instandhaltungsmeldungen

Probleme an Maschinen bzw. Maschinenstillstände können häufig nicht vom Maschinenführer behoben werden, sondern erfordern das Eingreifen eines Instandhalters. Die Benachrichtigung des Instandhalters erfolgt über eine kurze Meldung, welches das Problem bzw. die Symptome erläutern. Ziel ist es, den Instandhalter bestmöglich zu informieren, damit dieser bereits das erforderliche Werkzeug zur

Behebung mitbringen und sich auf die Problemlösung vorbereiten kann. Die Untersuchung von Instandhaltungsmeldungen hat jedoch ergeben, dass die Informationen häufig unvollständig sind bzw. keinen eindeutigen Hinweis zur Ursache beinhalten. Um das Instandhaltungsmanagement zu verbessern und damit Maschinenstillstände zu verkürzen, erproben TUM und Grob gemeinsam Lösungen zur effizienten Verarbeitung von Instandhaltungsmeldungen. Dies umfasst zum einen die Entwicklung einer mobilen, sprachbasierten App zur Aufnahme von Instandhaltungsmeldungen durch den Maschinenführer und die datengetriebene Verarbeitung dieser Meldungen mittels Text Mining Methoden.

Mit der App zur Aufnahme von Instandhaltungsmeldungen wird das Ziel verfolgt, inhaltlich umfangreiche Meldungen zu erheben, ohne den Maschinenführer in seiner Arbeit zu behindern. Im Projekt ist daher der Prototyp einer sprachbasierten App für Mobilgeräte entstanden. Zusätzlich zur Beschreibung des Fehlers als gesprochenes Wort, kann der Maschinenführer der Meldung auch Bilder beifügen. Über eine Schnittstelle zum ERP System wird die Meldung nach dem Abschicken an das Instandhaltungsbüro gemeldet. Der Instandhalter kann somit in kürzester Zeit umfangreich informiert werden.

Ziel der datengetriebenen Auswertung von Instandhaltungsmeldungen ist das Finden von Fehlerklassen und die Identifizierung ähnlicher Fehler. Dies ermöglicht dem Instandhalter aus vergangenen Fällen zusätzliche Informationen zu gewinnen und damit die Diagnose zu vereinfachen. Häufig sind Instandhaltungsmeldungen nur wenige Sätze oder Wörter lang. Dies stellt eine zusätzliche Herausforderung in der datengetriebenen Analyse dar. Zudem ist zu erwarten, dass es eine Vielzahl von unterschiedlichen Fehlern gibt, deren Anzahl im Vorhinein unbekannt ist. Des Weiteren ist das Vokabular sehr spezifisch. Um diesen Herausforderungen entgegen zu treten wurde im Projekt das Gibbs Sampling Algorithm Dirichlet Multinomial Mixture Model (GSDMM) verwendet, um historische Instandhaltungsmeldungen auf Basis der Wahrscheinlichkeitsverteilungen der Wörter in Cluster zu unterteilen. Im Preprocessing wurde unter anderem eine domänenspezifische Rechtschreibprüfung vorgenommen. Hierzu wurde eine aus dem ERP-System ausgeleitete Komponentenliste als Vergleichsbasis verwendet, um unidentifizierbare (falsch geschriebene) Wörter mit dem in der Liste befindlichen ähnlichstem Wort zu ersetzen. Auf Basis der historischen, vorverarbeiteten Meldungen wird mit GSDMM ein Clustermodell trainiert. Beim Eingang einer neuen Meldung kann durch das Modell ein passendes Cluster gefunden und ähnliche vergangene Fälle identifiziert werden (siehe Abbildung 9). Die Lösung zu diesen Fällen können dem Instandhalter die nötigen Informationen liefern, den vorliegenden Fehler schnell zu diagnostizieren und zu beheben.

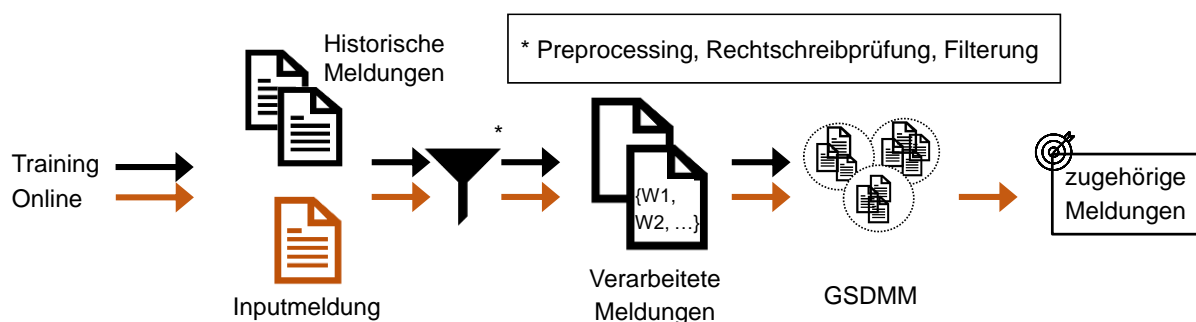


Abbildung 9: Datengetriebene Verarbeitung von Instandhaltungsmeldungen.

Die Evaluation des Clustering durch einen Experten zeigte, dass GSDMM eine Gruppierung ähnlicher Meldungen ermöglicht. Bei der händischen Untersuchung einzelner Cluster ist festgestellt worden, dass die sich darin befindlichen Meldungen einem bestimmten Thema zuzuordnen sind. Bei größeren Clustern ist aufgefallen, dass mehrere, sich leicht überlappende Themen in ein einziges Cluster gruppiert wurden.

Mithilfe des Modells können dem Instandhalter beim Auftreten eines Instandhaltungsfalls ähnliche vergangene Fälle angezeigt werden. Aus diesen bzw. aus den Lösungen zu diesen Fällen kann der Instandhalter wichtige Informationen für die Diagnose gewinnen und somit die Zeit zwischen Stillstand einer Maschine und der wieder Inbetriebnahme verkürzen.

2.3 Umsetzung von maschinellen Lernverfahren mittels Agenten

Änderungen von Umgebungsparametern oder auch Anpassungen an der Maschine können die Validität von trainierten Modellen maßgeblich beeinflussen. Zur Nutzung datengetriebener Verfahren ist daher sicher zu stellen, dass die Einhaltung der Ausgangsparameter gewährleistet ist bzw. eine Änderung auch eine neue Prüfung und Anpassung der Modelle auslöst. Agentensysteme, welche das autonome Agieren von System ermöglicht, wurden daher im Projekt untersucht, um einen flexiblen Einsatz von datengetriebenen Modellen zu realisieren. Als Anwendungsfall wird die Datenreduktion auf Feldebene genutzt.

Die Prozessabläufe und die Vielzahl an Sensoren und Aktoren in einer Maschine generieren in kürzester Zeit eine große Menge an Datenpunkten. Sollen diese Daten nicht nur lokal ausgewertet, sondern über mehrere Standorte geteilt werden, um Synergieeffekte zu generieren und flottenbasierte Erkenntnisse zu gewinnen, werden die Grenzen des Durchsatzes von Wide Area Networks (z.B. Internet) schnell erreicht. Aus diesem Grund müssen Daten bereits an ihrem Ursprung möglichst verlustfrei reduziert und am Speicherort wieder rekonstruiert werden. Grundsätzlich unterscheidet man zwischen verlustfreier und verlustbehafteter Datenreduzierung. Während gängige Kompressionsverfahren häufig verlustfreie Kompression mittels Entropie nutzen, gibt es auch bekannte Anwendungsfälle mit verlustbehafteter Datenverdichtung, wie etwa bei Medienformaten wie Bildern, Audio oder Video. Das in diesem Projekt erarbeitete Konzept zur Datenreduktion sieht vor, dass eine Reduktion einer Sensormessreihe über ein datengetriebenes Vorhersagemodell realisiert wird (vgl. Abbildung 10). Regression und Zeitreihenmodelle (Auto Regressive Moving Average Modelle) wurden als Vorhersagemodelle im Projekt verwendet. Auf der SPS wird der Wert zum Zeitpunkt t vom Modell auf Basis der historischen Sensorwerte berechnet. Stimmt dieser prognostizierte Wert \hat{y}_t mit dem tatsächlichen Wert y_t überein, muss dieser nicht übertragen werden. Der Wert wird bei der Rekonstruktion am Zielort durch die parallele Ausführung des gleichen Modells wiederhergestellt. Weichen prognostizierter und tatsächlicher Werte voneinander ab, muss der Wert y_t übermittelt werden. Je nach Grenzwert, wann eine Abweichung zu groß ist, können unterschiedliche Reduktionsraten erreicht werden. Für einen Servomotor an einem Demonstrator der TUM konnte bereits mit sehr kleinen Grenzwerten eine Reduktion der zu übertragenden Datenmenge von 60% erreicht werden. Im Anwendungsfall Dorst konnte eine Reduktionsrate für die Positionsdaten von bis zu 90% erzielt werden. Der geringe Datenverlust bei gleichzeitig hoher Verdichtung hat bei der Anwendung der rekonstruierten Daten auf die Segmentierung des Prozesses (vgl. Abschnitt 2.2.2) keine Auswirkungen gezeigt. Andernfalls müsste der Grenzwert bei der Datenreduktion zu Lasten der Reduktionsrate verkleinert werden, um den Datenverlust weiter zu minimieren.

Im Projekt konnte der zunächst theoretische Ansatz auf einer SPS implementiert werden. Die entwickelten Algorithmen wurden dahingehend optimiert, um quasi in Echtzeit gerechnet werden zu können. Die zusätzliche Rechenlast ist von einer modernen SPS CPU problemlos zu bewältigen.

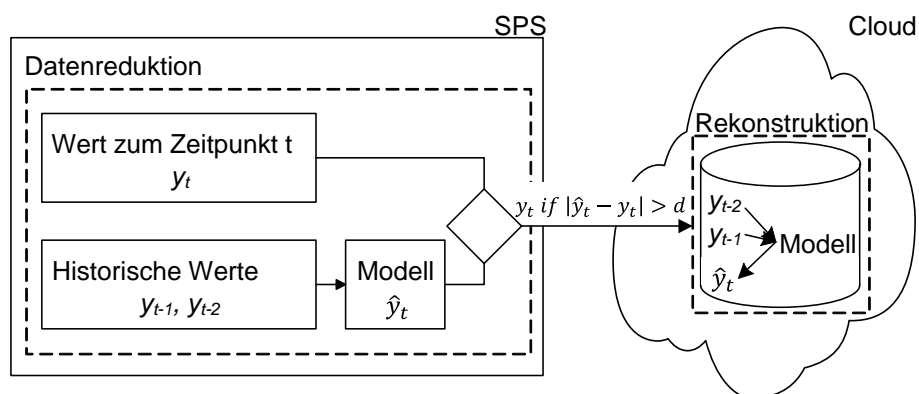


Abbildung 10: Datenreduktion auf einer SPS und Rekonstruktion auf einem zentralen Datenspeicher in der Cloud.

Ändert sich die Charakteristik des Sensorsignals zum Beispiel durch neue Prozessabläufe, kann ein trainiertes Vorhersagemodell keine präzisen Werte für \hat{y}_t berechnen. Eine Reduktion ist nicht mehr möglich, bis das Modell an die neuen Gegebenheiten angepasst wurde. Um dies zu automatisieren und damit ein flexibleres System zu schaffen, wurde im Projekt ein Agentensystem entwickelt. Das Konzept

besteht aus zwei Komponenten: Zum einen die Datenreduktion auf einer SPS und zum anderen die Rekonstruktion auf einem zentralen Datenspeicher. Bei der Datenreduktion wird in den operativen und trainierenden Bereich unterschieden. Im operativen Bereich ist ein Modellagent aktiv, welcher über ein Repertoire aus trainierten Modellen verfügt. Dieser berechnet die Modellvorhersage, welche vom Modellkontrollagent auf die Abweichung zum tatsächlichen Wert geprüft wird. Kann der Modellagent keine ausreichende Vorhersagegüte erreichen, wird ein Trainingsbefehl an den trainierenden Bereich übergeben. Auf Basis der letzten Werte kann der Trainingsagent ein neues Modell mit verbesserter Vorhersagegüte trainieren und dieses an den operativen Bereich übergeben (vgl. Abbildung 11). So kann in kürzester Zeit flexibel auf sich ändernde Signale und Systemzustände reagiert werden.

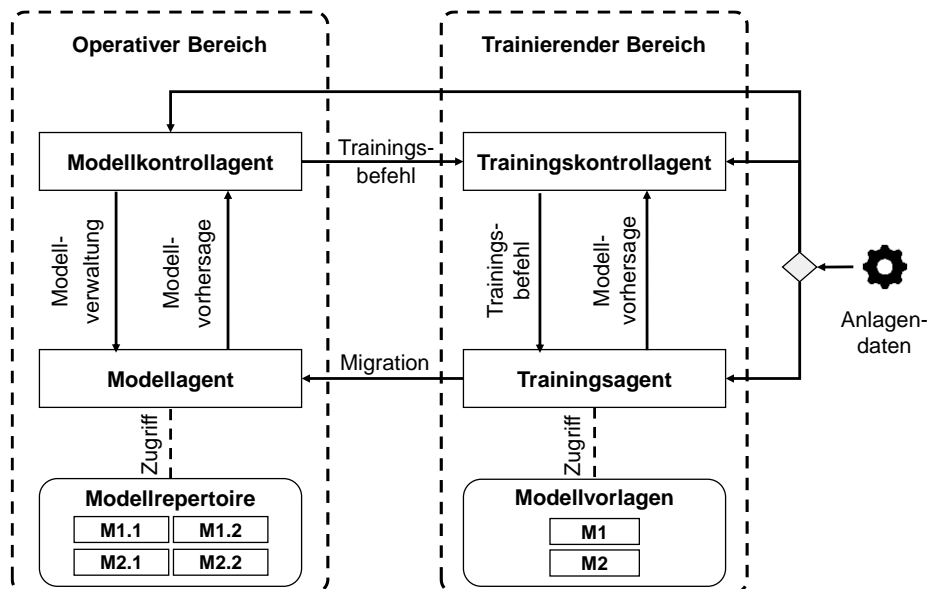


Abbildung 11: Funktionsprinzip des Agentensystems zur Datenreduktion auf einer SPS.

Die verwendeten Modelle sowie Datenpunkte, welche nicht vorhergesagt werden können, werden an den zentralen Datenspeicher übermittelt. Ein Entpackagent kann auf Basis dieser Daten und dem Modell die Rekonstruktion durchführen.

Eine prototypische Implementierung am Demonstrator der TUM zeigt das Umschalten zwischen verschiedenen Modellen des Agentensystems. In Abbildung 12 sind zwei Modelle gezeigt, die der Modellagent zur Verfügung hat. Überschreitet die Modellabweichung von Modell 1 die von Modell 2, wird das aktive Modell dynamisch umgeschaltet (erster roter Pfeil). Anschließend ist nicht mehr Modell 1, sondern Modell 2 aktiv. Zurückgeschaltet wird wieder, sobald Modell 2 eine größere Modellabweichung aufweist als Modell 1.

Das Agentensystem steigert die Anwendbarkeit der datengetriebenen Methoden erheblich. Das erneute Training erhöht die Modellqualität und ermöglicht so eine verlustarme Reduktion der Daten. Unnötiges Training z.B. zeitbasiert wird durch das System ebenfalls unterbunden. Ein erneutes Training wird erst durchgeführt, wenn der Modellkontrollagent eine abfallende Modellgüte erkennt und die Notwendigkeit für ein Training gegeben ist.

Der agentenbasierte Ansatz zur Gestaltung einer flexiblen datengetriebenen Lösung für die Datenreduktion ist auf weitere Anwendungen von Datenvorverarbeitung und maschinellen Lernen in der industriellen Praxis übertragbar. Im Condition Monitoring von Hydrauliksystemen könnten Agenten, z.B. beim Hinzufügen eines neuen Sensors im System, die Bewertung des Einflusses des neuen Sensors auf die bisherigen Modelle automatisch prüfen und entsprechend reagieren. Verbessert sich die Modellgüte durch den neuen Sensor, sollte ein erneutes Training angestoßen werden. Die Herausforderung ist, den Handlungsraum der Agenten und dessen Entscheidungsmechanismen so abzustimmen, dass ein flexibles aber sicheres System entsteht. In zukünftiger Forschung müssen wiederverwendbare Muster für Agenten in der Datenverarbeitung und -analyse entwickelt werden, welche einen Einsatz in der Industrie erleichtern.

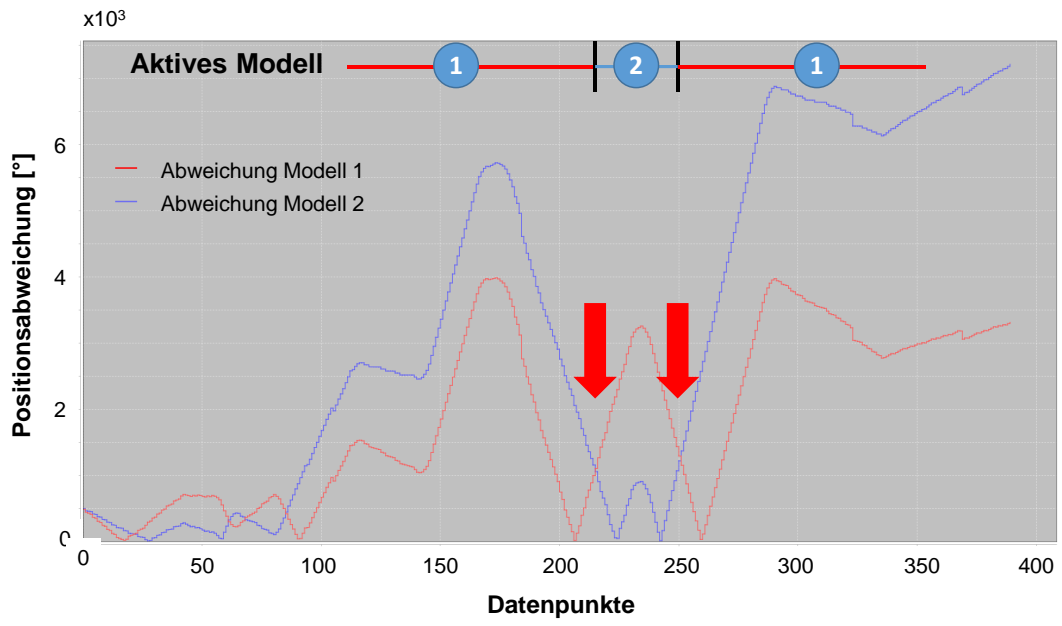


Abbildung 12: Abweichung zwischen berechneter und tatsächlicher Position für zwei Modelle des Modellagenten.

3 Nutzung und Verwertung

Die Projektergebnisse in M@OK werden sowohl wirtschaftlich auch als wissenschaftliche genutzt und verwertet.

3.1 Wirtschaftliche Nutzung und Verwertung

Anwendungsfall	Partner	Nutzen	Form der Vermarktung	Eingeleitete Maßnahmen
Alarmmanagement	Grob Conti	<ul style="list-style-type: none"> Verringerung von Maschinenstillständen (Erhöhung OEE) durch die Unterstützung von unerfahrenen Maschinenbedienern 	<ul style="list-style-type: none"> Verkauf an Kunden als Service (Zeithorizont 5 a) 	<ul style="list-style-type: none"> Ausdehnung der Tests und Evaluierung an Kundendaten Zusammenstellung von Expertenteams unterschiedlicher organisationaler Einheiten zur Evaluation der gefundenen Alarmcluster
Qualitätsüberwachung	Dorst	<ul style="list-style-type: none"> Bedarfsgerechte anstatt stichprobenartige manuelle Qualitätsprüfung (Erhöhung OEE des Kunden) 	<ul style="list-style-type: none"> Verkauf an Kunden als zusätzliches Feature (Zeithorizont 5 a) 	<ul style="list-style-type: none"> Ausdehnung der Test und Evaluierung an weiteren Kundendaten
		<ul style="list-style-type: none"> Verbesserung datengetriebener Verfahren durch vorherige Segmentierung des Prozessablaufs in seine relevanten Phasen 	<ul style="list-style-type: none"> Zusätzliches Produktfeature zur Stärkung der Wettbewerbsposition (Zeithorizont 1 a) 	<ul style="list-style-type: none"> Integration in den Workflow der Datenverarbeitung
Condition Monitoring	HAWE	<ul style="list-style-type: none"> Erhöhung der Verfügbarkeit durch frühzeitige Benachrichtigung/Anzeige von sich anbahnenden Schwierigkeiten (Erhöhung OEE) Reengineering von Komponenten, bei denen höherer Ausfallrate identifiziert werden Verwendung der Daten zur Lebensdaueranalyse 	<ul style="list-style-type: none"> Vorerst Überwachung der eigenen Produktion (Zeithorizont 3 a) 	<ul style="list-style-type: none"> Klärung von Schnittstellen und Identifikation von Hardware-Implementierung auf vorhandenem Dauerprüfstand (Start der Langzeitbeobachtung in circa 1 a); derzeit Evaluierung weiterer Sensoren
Text Mining in Instandhaltungsmeldungen	Grob	<ul style="list-style-type: none"> Zeitersparnis bei der Diagnose von Maschinenstillständen (Verkürzung der Zeit zwischen Stillstand und Wiederinbetriebnahme) der eigenen Produktion (Erhöhung OEE) Zeitersparnis auch bei der Ferndiagnose beim Kunden (Erhöhung OEE des Kunden) Verfügbarmachung von vorhandenen/unstrukturierten Informationen (Nutzung auch im Re-Engineering) 	<ul style="list-style-type: none"> Vorerst Einführung in der eigenen Produktion (Zeithorizont 2 a) 	<ul style="list-style-type: none"> Schnittstelle (REST) zur Integration von Python-Skripten im SAP -> Entwickelte Python-Skripte können schnell produktiv geschaltet werden Vollständige Abwicklung der Instandhaltung in SAP, damit keine weitere Integration in andere Systeme notwendig ist
		<ul style="list-style-type: none"> Erhöhung der Qualität von Instandhaltungsmeldungen durch sprachbasierte App 	<ul style="list-style-type: none"> Einführung in der eigenen Produktion (Zeithorizont 1 a) 	<ul style="list-style-type: none"> Konzeption und Umsetzung des Datentransfers zwischen APP und SAP (bish. Mailversand der Meldung)
Datenreduktion	Dorst	<ul style="list-style-type: none"> weniger Ausfälle bei Datenübertragung durch Verringerung der Datenmenge 	<ul style="list-style-type: none"> Integration in die Produkte zur Schaffung neuer Datenpotentiale (Zeithorizont 2 a) 	<ul style="list-style-type: none"> Integration auf der SPS

Um die Ergebnisse auch im industriellen Umfeld einer breiten Öffentlichkeit bekannt zu machen, sind die Projektergebnisse in Arbeitskreisen unterschiedlicher Verbände eingeflossen. Die VDI/VDE Richtlinie 3714 „Big Data“¹ des GMA 7.24 zeigt das Vorgehen, die Herausforderungen und die Kernaspekte eines Big Data Projekts in der Industrie auf. Erfahrungen aus dem Projekt wurden in dieser Richtlinie als Empfehlungen aufbereitet. Auch im NAMUR Arbeitskreis MES (2.4) sind die Ergebnisse (Veröffentlichung „Gib den Daten einen Kontext“²) eingeflossen.

In der industriellen Öffentlichkeit sind die Projektergebnisse auch in Vorträgen oder als Beitrag in Zeitschriften präsentiert worden:

- Posterpräsentation beim Automation Symposium am 27.09.2018 mit 70 Vertretern aus der Industrie; Veranstaltung an der TUM
- Projektvorstellung auf der IPC SPS Drives vom 27.-29.11.2018; Vertretung des Projekts auf dem Codesys Gemeinschaftsstand durch die TUM
- H. Gröbl, A. Stolz, I. Weiß. „No Fear of Detail Work – Towards Intelligent Data Preparation,” ceramic forum international, 96, 2019.
- 3. Jahrestagung Machine Learning & Data Analytics in Manufacturing vom 05. - 07.03.2019 in Köln (Vortrag Grob)
- 4. Workshop Digitalisierung an der FAU am 18.11.2020 (Vortrag TUM)

3.2 Wissenschaftliche Nutzung und Verwertung

In Veröffentlichungen, durch Einbindung in die Lehre und in weiteren Forschungsprojekten wurden die Projektergebnisse wissenschaftlich genutzt und verwertet.

In folgenden peer-reviewed Veröffentlichungen wurden die Ergebnisse präsentiert und ggf. im Rahmen der Konferenz mit wissenschaftlichen Fachpublikum diskutiert:

- E. Trunzer, P. Prata, S. Vieira and B. Vogel-Heuser. "Concept and Evaluation of a Technology-independent Data Collection Architecture for Industrial Automation", in 45th Annual Conference of the IEEE Industrial Electronics Society (IECON), IEEE, Oct. 2019, pp. 2672-2678.
- E. Trunzer, A. Wullenweber, F. Ocker and B. Vogel-Heuser. "Graphical Modeling Notation for Data Acquisition and Analysis Architectures in Cyber-Physical Systems of Systems (Abstract Only)", in 15th International Conference on Automation Science and Engineering (CASE 2019), IEEE, Aug. 2019, p. 2.
- E. Trunzer, A. Wullenweber and B. Vogel-Heuser. "Graphical Modeling Notation for Data Collection and Analysis Architectures in Cyber-Physical Systems of Systems," Journal of Industrial Information Integration, vol. 19, p. 100155, Sep. 2020.
- M. FahimiPirehgalin, I. Weiß and B. Vogel-Heuser. "Causal Inference in Industrial Alarm Data by Timely Clustered Alarms and Transfer Entropy". in ECC 2020, IFAC, Mar. 2020, pp. 2056-2061.
- I. Weiß, B. Vogel-Heuser. „Unternehmensübergreifendes Teilen von Wissen und Daten in Industrie 4.0 Anwendungen – Beispiele aus den Projekten SIDAP und M@OK“ in Industrie 4.0 (3. Auflage), Hrsg. B. Vogel-Heuser, T. Bauernhansl, M. ten Hompel, 2020 (in press).
- E. Trunzer, T. Schilling, M. Müller and B. Vogel-Heuser. "Comparison of Communication Technologies for Industrial Middlewares and DDS-based Realization," in 21st IFAC World Congress in Berlin, Germany, July 12-17, 2020, Jul. 2020, pp. 11082-1108.
- I. Weiß, B. Vogel-Heuser, P. Holstein and E. Trunzer. "Machine-Learning Models on the Edge to reduce Data Volume in Wide-Area Networks between various Production Sites," in 46th Annual Conference on the IEEE Industrial Electronics Society (IECON), IEEE, Oct. 2020.

¹ VDI/VDE Richtlinie 3714 (12-2019) Blatt 1: Implementierung und Betrieb von Big-Data-Anwendungen in der produzierenden Industrie - Durchführung von Big-Data-Projekten

² U. Enste, A. Hartwich, C. Benthack, P. Wiemer und I. Weiß. „Gib den Daten einen Kontext – Echtzeit-Kontextmanagement – ein Beitrag zur NOA,“ atp edition, 2020.

- I. Weiß, B. Vogel-Heuser, E. Trunzer and S. Kruppa. "Unsupervised Quality Monitoring in Hydraulic Presses using a Minimal Sample of Sensor and Actuator Data," ACM Transactions on Internet Technology (angenommen).
- E. Trunzer, B. Vogel-Heuser, J. Chen and M. Kohnle. "Model-driven Approach for Realization of Data Collection Architectures for Cyber-physical Systems of Systems to Lower Manual Implementation Efforts," Sensors, p. 21 (angenommen).
- Condition Monitoring of Hydraulic Systems (geplant).

In der Lehre werden die Projektergebnisse aus M@OK vor allem in den Veranstaltungen „Intelligente Systeme und Machine Learning für Produktionsprozesse“ und „Automatisierungstechnik 2“ integriert. Die Anwendungsfälle des Projektes werden zur Veranschaulichung von datenbetriebenen Methoden in der Automatisierungstechnik herangezogen und die entwickelten Konzepte zum Aufbau von Methodenkompetenzen genutzt.

Zudem wurden folgende studentische Abschlussarbeiten, welche eine intensive Auseinandersetzung der Studenten mit wissenschaftlichen Fragestellungen des Projektes fördern, betreut:

- Bachelorarbeit F. Mann „Bottom-Up Development of an Ontology for Maintenance based on Automated Generation of Knowledge Graphs using Natural Language Processing“, 2020.
- Masterarbeit S. Kruppa „Merkmalsextraktion von Instandhaltungsmeldungen mittels Natural Language Processing und Identifikation ähnlicher Meldungen mit Clusteralgorithmen“, 2020.
- Masterarbeit P. Holstein „Concept, Implementation and Evaluation of Machine Learning Models for Anomaly Detection of Hydraulic Systems on Basis of Industrial Data of a Machine Tool“, 2020.
- Masterarbeit M. Pundel „Conceptualization and Extension of a Communication Software Framework for Technology-neutral Industrie 4.0 Data Collection Architectures“, 2020.
- Bachelorarbeit M. Kohnle „Conception and Realization of Model-driven Generation of Supervisory Functions to Monitor Quality of Service in Data Collection Architectures for Industrie 4.0“, 2020.
- Bachelorarbeit O. Landenberger „Model-Driven Development for Field Level Integration of Cyber-Physical Systems into Data Collection and Analysis Architectures“, 2020.
- Semesterarbeit F. Kirschner „Wissensmanagement in automatisierten Produktionsanlagen - Konzeptionierung einer datengestützten Formalisierung von impliziten Wissen anhand eines Industriellen Anwendungsfalls in der Fertigungstechnik“, 2019.
- Bachelorarbeit F. Kolb „Konzeption und Umsetzung eines Multiagentensystems für die flexible Datenanalyse in Cyber-Physischen Produktionssystemen“, 2019.
- Masterarbeit V. Kreschenski „Datengetriebene Root Cause Analyse von Alarmdaten in automatisierten Produktionssystemen“, 2019.
- Masterarbeit P. Prata „Concept and Evaluation of a Technology_independent Data Acquisition Architecture for Industrie 4.0“, 2019.
- Masterarbeit F. Schäfer „Methodische Entwicklung einer Sprachschnittstelle zur Unterstützung der mobilen Wartung“, 2019.
- Semesterarbeit J.-K. Chen „Model-Driven Development of Data Acquisition and Analysis Architectures for Cyber-Physical Systems of Systems“, 2019.
- Bachelorarbeit A. Wullenweber „Enhancement and Industrial Evaluation of a Modelling Notation for Industrie 4.0 Data Acquisition Architectures“, 2019.
- Masterarbeit J. Dongyu „Root-Cause Analysis of Industrial Alarm Data with Bayesian Network“, 2019.
- Semesterarbeit F. Mourao „Root-Cause identification in Industrial Alarm Analysis by using time analysis between alarms and Bayesian Networks“, 2019.
- Semesterarbeit S. Kruppa „Datengetriebene Anomalie-Erkennung in automatisierten Produktionssystemen mittels Ähnlichkeitsanalysen der Prozessdaten“, 2018.

- Semesterarbeit P. Holstein „Edge Data Preprocessing in PLCs for Big Data Applications in Automated Production Systems“, 2018.

Die Zusammenarbeit der Partner im Projekt hat weitere forschungsrelevante Aspekte rund um das Thema Datenanalyse im Maschinen- und Anlagenbau aufgebracht. Die Nutzung weiterer Datenquellen (z.B. Modelle aus Konstruktion und Design) und die Integration dieser in die Datenanalyse stellt ein wesentlicher Punkt weitere Forschungsaktivitäten dar. Ein Folgeantrag zusammen mit AIS, HAWE und Grob wird derzeit erarbeitet.