

Schlussbericht

zu IGF-Vorhaben Nr. 19341 BG

Thema

Assistenzsysteme zur Überwachung von vernetzten Anlagen - Herausforderungen beim Vernetzen sowie beim Erkennen von kausalen Zusammenhängen in Industrie 4.0 Umgebungen

Berichtszeitraum

01.03.2017 - 28.02.2019

Forschungsvereinigung

Forschungsvereinigung Elektrotechnik beim ZVEI e.V.

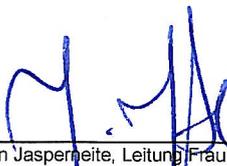
Forschungseinrichtung(en)

Fraunhofer Gesellschaft e.V. - Institutsteil für industrielle Automation (IOSB-INA)

IMMS Institut für Mikroelektronik- und Mechatronik-Systeme gemeinnützige GmbH

Lemgo, 19.06.19
Ort, Datum

Blumberg, 25.06.19
Ort, Datum


Prof. Dr. Jürgen Jaspermeite, Leitung Fraunhofer IOSB-INA


Dr. Tino Hutschenreuther, Leitung System Design, IMMS

Gefördert durch:

Abschlussbericht zum Forschungsvorhaben *AgAVE*

Assistenzsystem zur Überwachung von vernetzten Anlagen -
Herausforderungen beim Vernetzen sowie beim Erkennen von
kausalen Zusammenhängen in Industrie-4.0-Umgebungen

Fraunhofer IOSB-INA

Campusallee 6

32657 Lemgo

IMMS Institut für Mikroelektronik- und
Mechatronik-Systeme gemeinnützige GmbH (IMMS GmbH)

Ehrenbergstraße 27

98693 Ilmenau

Laufzeit: 01.03.2017 - 28.02.2019

Inhaltsverzeichnis

1	Kurzfassung	5
2	Einleitung	6
2.1	Motivation	6
2.2	Stand der Technik	6
3	Wissenschaftlich-technische und wirtschaftliche Relevanz	10
3.1	Wissenschaftlich-technischer Nutzen	10
3.2	Wirtschaftliche Bedeutung der Forschungsergebnisse für KMU	14
4	Durchgeführte Arbeiten und Ergebnisse	17
4.1	Arbeitshypothese	17
4.2	Arbeitspaket 1: Erfassung der Anforderungen	22
4.2.1	AP 1.1: Analyse und Definition der Anforderungen	22
4.2.2	AP 1.2: Analyse und Definition der Anforderungen an die Infrastruktur	23
4.3	Arbeitspaket 2: Systemmodellierung und Maschinelles Lernen	24
4.3.1	AP 2.1: Übernahme der Methoden aus Vorarbeiten	24
4.3.2	AP 2.2: Erweiterung der Algorithmen für alternative Verfahren	26
4.3.3	AP 2.3: Schnittstellen zur Kopplung von Assistenzsystemen	28
4.3.4	AP 2.4: Plattformuntersuchungen für I4.0-fähige Dienste	29
4.3.5	AP 2.5: Lernen von kausalen Zusammenhängen in hybriden Systemen	30
4.4	Arbeitspaket 3: Ablaufumgebungen für Assistenzsysteme	33
4.4.1	AP 3.1: Aufbau einer Ablaufumgebung für Assistenzsysteme im I4.0 Umfeld	34
4.4.2	AP 3.2: Aufbau einer Serviceschnittstelle zur Vernetzung von Assistenzsystemen	35
4.4.3	AP 3.3: Untersuchungen zu Prozessverlagerung in Cloudarchitekturen	37
4.4.4	AP 3.4: Ableitung eines Vorschlages für die Erfassung von Maintanancedaten	38
4.5	Arbeitspaket 4: Projektmanagement und Ergebnistransfer	39
4.5.1	AP 4.1: Demonstrator	39

4.5.2	AP 4.2: Dokumentation der Resultate	41
4.5.3	AP 4.3: Projektmanagement und Transfer zu Projektpartnern . .	41
5	Verwendung der Zuwendung	42
5.1	Fraunhofer IOSB-INA	42
5.2	IMMS GmbH	42
6	Notwendigkeit und Angemessenheit der geleisteten Arbeit	43
7	Transfer der Ergebnisse	44
7.1	Ergebnistransfer in die Wirtschaft	44
7.2	Aussagen zur voraussichtlichen industriellen Umsetzung der FuE-Ergebnisse nach Projektende	45
7.3	Einschätzung zur Realisierbarkeit des vorgeschlagenen und aktualisier- ten Transferkonzepts	47
	Literatur	57

Abbildungsverzeichnis

1	Beispielhafter Einsatz des intelligenten Assistenzsystems	13
2	Globaler Markt der intelligenten Maschinen [4]. Zahlen in Millionen US\$.	14
3	Stadien eines ausfallenden Systems nach [36]	15
4	Unterscheidung in High-Level- und Low-Level-Learning	18
5	Verwendung von regelbasiertem Lernen auf dem High-Level, um Modelle des Low-Level zu kombinieren.	19
6	Grafische Darstellung des Algorithmus <i>HyBUTLA</i>	26
7	Grafische Darstellung eines Entscheidungsbaumes	32
8	Vernetzung der Analyseassistenten	33
9	Struktur der Verwaltungsschale	36
10	Abbildung des Versatile Production System in der SmartFactoryOWL	40
11	Einordnung des projektbegleitenden Ausschusses entlang der Wertschöpfungskette	44

1 Kurzfassung

Im Rahmen des IGF-Projektes *Assistenzsystem zur Überwachung von vernetzten Anlagen - Herausforderungen beim Vernetzen sowie beim Erkennen von kausalen Zusammenhängen in Industrie 4.0 Umgebungen* (kurz: *AgAVE*, FKZ: 19341BG) wurde ein Assistenzsystem entwickelt, das Anlagenbetreiber bei der Erkennung von Fehlern und deren Ursachen in vernetzten Produktionsanlagen unterstützt. Das Assistenzsystem basiert auf einer verteilten Datenanalyse, die direkt während des Anlagenbetriebs durchgeführt wird.

Die Datenanalyse im Assistenzsystem wird auf zwei verschiedenen Ebenen durchgeführt. Eine erste, lokale Analyse wird sub-symbolisch an den einzelnen Anlagemodulen durchgeführt. Hier kommen verschiedene, etablierte Algorithmen des maschinellen Lernens zum Einsatz. So werden zum Beispiel zeitbehaftete Automaten verwendet, um die diskreten Ereignisse in der Anlage zu überwachen, während Klassifikationsverfahren zur Überprüfung der kontinuierlichen Werte verwendet werden. Jedes Verfahren hat dabei eigene Schwerpunkte, sodass die Daten durch vielfältige Verfahren analysiert werden.

Um die Ausgaben dieser verschiedenen Analysealgorithmen in eine verständliche Form zu bringen, wird eine weitere, höhergelagerte Lernschicht verwendet. Diese sammelt die Ausgaben der verschiedenen lokalen Module und generiert aus diesen Regeln, die Aussagen über das aktuelle Anlagenverhalten treffen. Dieses algorithmische Konzept erfordert eine sorgfältige Datenverwaltung. So muss das Assistenzsystem die aktuellen Daten der Anlagenmodule erhalten, damit es während des Anlagenbetriebs eingesetzt werden kann. Eine weitere Anforderung an das Assistenzsystem war eine herstellerunabhängige Lösung der Datenakquise, sodass es für verschiedenste Anlagen einsetzbar ist. Diese Anforderungen können durch den Industrie4.0-konformen Kommunikationsstandard OPC UA sichergestellt werden.

Zusätzlich erhält jedes Modul des Assistenzsystems eine Verwaltungsschale, die die jeweilige Komponente beschreibt. Dabei erhalten sowohl die algorithmischen Analysemodule als auch die physischen Anlagenmodule eine Verwaltungsschale. Mithilfe dieser Selbstbeschreibung wird spezifiziert, welcher Algorithmus welche Eingangsvariablen benötigt (zum Beispiel diskrete oder kontinuierliche Variablen). Weiterhin werden auch die Ausgabe und das Analyseverfahren selbst beschrieben. So kann der Austausch zwischen den Komponenten sichergestellt werden.

Das Forschungsziel wurde erreicht.

2 Einleitung

2.1 Motivation

Unter Assistenzsystemen wird die große Gruppe von Systemen zusammengefasst, die den Arbeiter bei der Ausführung seiner Arbeit an den Maschinen unterstützt. Dies reicht von einfachen Anzeigen bis hin zur Unterstützung durch Augmented-Reality-Funktionen. Diese Assistenzsysteme sind dabei auf den Arbeiter ausgerichtet, der die Maschine bedient oder zusätzliche manuelle Arbeiten zur Herstellung von Teilen verrichtet. Ein Beispiel für Projekte, welche in diesem Umfeld angesiedelt sind, ist „4.0 ready“ (FKZ: 18897 N) welches sich mit neuartigen Mensch-Maschine-Schnittstellen für Produktion und Logistik beschäftigt [33].

Die andere Gruppe von Assistenzsystemen bezieht sich auf die Wartung und Instandhaltung der Maschine selbst. Dazu gehören Predictive-Maintenance-Systeme, Condition-Monitoring-Systeme oder Systeme zur Wartung der Anlagen, die auch durch Augmented Reality unterstützt werden können. In diesem Projekt sollen Grundlagen für ein Assistenzsystem entwickelt werden, welches seinen Fokus auf die automatische Analyse von Maschinenzuständen im Betrieb richtet und im Fehlerfall Rückschlüsse auf die Fehlerursache in komplexen Anlagen erlaubt. Ziel dabei ist die Reduktion von Stillstandszeiten durch Reduktion von Fehlersuche und Fehlerbehebung bei Ausfällen.

2.2 Stand der Technik

Dieses Thema ist noch Gegenstand der Forschung, da das maschinelle Lernen gerade von komplexen Systemen noch nicht hinreichend untersucht wurde. Ein Projekt, welches sich mit diesem Thema beschäftigt ist „APPsist“ [30]. Im Projekt „APPsist“ wird ein ganzheitlicher Ansatz für die Interaktion zwischen Mensch und Maschine in der Produktion entwickelt.

Softwarebasierte Assistenzsysteme werden sich anhand spezifischer, vorhandener Kompetenzen von Mitarbeitern automatisch auf deren Unterstützungsbedarf einstellen. Somit könnten Unterstützungen und Lernprozesse für die unterschiedlichsten Anforderungen entwickelt werden, wie z.B. für die Inbetriebnahme, den Betrieb, die Wartung, Reparatur und vorbeugende Instandhaltung von Anlagen. Durch diese passgerechte Unterstützung können Mitarbeiter mit unterschiedlichem Vorwissen umfassender als bisher eingesetzt werden.

„APPsist“ konzentriert sich dabei auf die Schnittstelle zum Menschen, während die

in diesem Projekt angestrebten Inhalte als Basis vorausgesetzt werden. Somit bietet dieses Projekt ideale Anknüpfungspunkte, die Projektergebnisse für die Visualisierung zu nutzen.

Ein weiteres Projekt, „AGATA“ (Analyse großer Datenmengen in Verarbeitungsprozessen, FKZ: 01IS4008 A-F), beschäftigt sich mit Datenanalyse-Methoden rund um Big Data und auch um Infrastrukturfragen (Datenhaltung etc.), um die Einrichtung von Assistenzsystemen zu ermöglichen [15]. Zum Einsatz kommen dabei Verfahren, die auf Basis der erfassten Daten Muster und Zusammenhänge in den Prozessdaten herstellen und somit Anomalien finden können. Die Anwendungspartner nutzen diese Verfahren dann für ihre individuellen Anwendungen. Weitere laufende Forschungsprojekte in diesem Themenkomplex sind „iPRODIGT“ (Intelligente Prozessprognose basierend auf Big-Data-Analytics-Verfahren, FKZ: 01IS14004A-F), „FEE“ (Frühzeitige Erkennung und Entscheidungsunterstützung für kritische Situationen im Produktionsumfeld: Entwicklung von Assistenzfunktionen zur Unterstützung von Anlagenbedienern in kritischen Situation, FKZ: 01IS14006A-E) und das Projekt „BigPro“ (Big-Data-Einsatz und eventbasierte Regelung zur Gestaltung von robusten Produktionssystemen, FKZ: 01IS14011) [20, 10, 31].

Diagnose in technischen Systemen Die Verwendung modellbasierter Verfahren zur Diagnose wurde in den letzten Jahren immer populärer. Generell verwenden modellbasierte Ansätze, wie [41, 18], ein Modell des Systems, um während des Systembetriebs durch einen Vergleich zwischen Messungen am System und der Modellvorhersage (Simulation des Modells) Symptome zu generieren und um den Zusammenhang zwischen Symptom und Ursache zu ermitteln. Die Art der Modelle für das Normalverhalten ist dabei vielfältig. Die Modellidentifikation (Lernen des Normalverhaltens) stellt dabei eine besondere Herausforderung dar. Zur Diagnose werden vorrangig Modelle verwendet, die die Beziehung zwischen Ursache und Wirkung beschreiben können. Als Beispiel sei hier die Fehlerbaumanalyse (Fault Tree Analysis, FTA) genannt [2, 32]. Sie basiert auf Boolescher Algebra und Wahrscheinlichkeitsrechnung. Die Ereignisbaumanalyse (Event Tree Analysis, ETA) ist ein induktives Verfahren, welches ebenfalls auf boolescher Algebra und Wahrscheinlichkeitsrechnung beruht [14]. Das ganze Verfahren der Ereignisbaumanalyse ist ausführlich in der DIN 25419 beschrieben. Die ETA betrachtet die Auswirkung eines Ereignisses auf das System. Ein Nachteil dieser Verfahren ist, dass sie nur eingeschränkt mit maschinellen Verfahren ermittelt werden können. In der Regel ist ein enormes Maß an Expertenwissen notwendig. Aus diesem

Grund hat sich das Fraunhofer IOSB mit dem Lernen von Verhaltensmodellen zum Zwecke der Diagnose technischer Systeme beschäftigt. Verhaltensmodelle werden dabei als endliche Automaten, auch mit Erweiterungen wie bspw. Zeit oder hybriden Signalen, gelernt [27]. Endliche Automaten beinhalten eine Folge von Events, die jeweils Zustandswechsel auslösen. Ein Überblick und ein komparativer Vergleich sind in [40] gegeben.

Weitere Verfahren zum automatischen Lernen des Normalverhaltens und der anschließenden Möglichkeit zur Diagnose sind z.B. selbstorganisierende Karten (self-organizing maps, SOMs) [16], Bayessche Netze [35], Neuronale Netze [21], Support Vector Machines [8] oder Fuzzy-Ansätze [42].

Lernen von kausalen Zusammenhängen Kausalität ist die Beziehung zwischen Ursache und Wirkung. Bei der Fehlerdiagnose ist es von großem Interesse, bei einem beobachteten Fehler (Wirkung) die Ursache zu ermitteln. Sind jedoch die Zusammenhänge nicht bekannt, ist man auf die Deutung von Beobachtungen angewiesen. Sollen die kausalen Zusammenhänge datengetrieben ermittelt werden, so werden dazu u.a. auch Methoden der Statistik verwendet. Mehrere Verfahren wurden bereits für die Identifikation von kausalen Zusammenhängen aus Daten entwickelt. Einer der ersten Ansätze wurde von Granger entwickelt [17], in dem zwei autoregressive Modelle miteinander verglichen werden. Dabei enthält das erste Modell nur verzögerte Werte von sich selbst, während das zweite Modell verzögerte Werte einer anderen Variablen erhält. Wird dadurch die Regression verbessert, wird davon ausgegangen, dass die erste Variable die Ursache für die andere ist. In einem anderen Ansatz schlägt Horch einen Algorithmus auf Grundlage der Kreuzkorrelationsfunktion für die Ursachenanalyse vor [1]. In diesem Fall werden der maximale Absolutwert der Kreuzkorrelationsfunktion und die entsprechende Zeitverschiebung für die Beschreibung der kausalen Abhängigkeiten in den Daten verwendet. Schreiber stellt ein Konzept zur Analyse von kausalen Abhängigkeiten als Informationsfluss von einer Variablen zu einer anderen vor [28]. Dazu nutzt er den Begriff der Transfer-Entropie, die die Reduktion von Unsicherheit misst, wenn angenommen wird, dass eine Variable zukünftige Werte des anderen prognostiziert. Des Weiteren wurden Bayes-Netzwerke erweitert, um das dynamische Verhalten in Daten zu erkennen, die wiederum verwendet werden, um kausale Abhängigkeiten berechnen zu können [7]. Bauer schlägt mehrere Algorithmen vor, die einen nearest-neighbor-Ansatz als kausale Messgröße verwenden, indem der Wert einer Variablen durch einen anderen vorhergesagt wird [3].

Am Fraunhofer IOSB wurde eine Dissertation zum Thema „Datengetriebene Methoden zur Fehlerlokalisierung in der Prozesstechnik“ durchgeführt [23]. Dabei wurden Verfahren entwickelt, welche auf Kreuzkorrelation, Granger-Kausalität, Transfer-Entropie und Support Vector Machines basieren.

3 Wissenschaftlich-technische und wirtschaftliche Relevanz

3.1 Wissenschaftlich-technischer Nutzen

Die Komplexität moderner Produktionsanlagen steigt stetig an - Produktionsanlagen bestehen häufig aus vielen unterschiedlichen Modulen, die auf unterschiedliche Art und Weise verknüpft werden. Somit kann Trends wie sinkenden Losgrößen und der kundenindividuellen Produktion, wie sie durch die Hightech-Strategie der Bundesregierung beschrieben werden, begegnet werden [6].

Die steigende Komplexität und Modularität bringt allerdings auch Nachteile mit sich. Treten Fehler in der Produktionsanlage auf, können diese sich weit fortpflanzen und zu Fehlern an nachgeschalteten Modulen führen. Die Fehlerursachen zu finden wird aufgrund der vielseitigen Fehlerfortpflanzung zunehmend schwieriger. Dies führt zu langen Stillstandszeiten und Ausfällen der Produktionsanlage. Solche Ausfälle haben in den vergangenen Jahren zu einem erheblichen, finanziellen Schaden geführt. Gerade für KMU bergen solche unvorhergesehene Schäden ein wirtschaftliches Risiko.

Um unvorhergesehene Stillstandszeiten zu minimieren und die Fehlersuche zu unterstützen, wurde in diesem Projekt der Einsatz von intelligenten Assistenzsystemen zur Fehlerursachenanalyse und Anomalieerkennung in modularen Produktionsanlagen untersucht. Dieses Assistenzsystem sammelt die Daten aus der modularen Produktionsanlage, führt eine Datenanalyse durch und detektiert Anomalien und mögliche Fehlerursachen. Diese werden dem Anlagenoperator in einer menschlich-verständlichen Art präsentiert.

Zu Projektbeginn wurde festgestellt, dass viele KMU nicht in der Lage sind, die Daten aus ihren Produktionsanlagen zu erfassen. Um auf dieses Bedürfnis zu reagieren, ist das entwickelte Assistenzsystem in der Lage, Produktionsdaten im laufenden Anlagenbetrieb zu erfassen und zu verarbeiten. Somit kann während die Anlage produziert eine Aussage zum aktuellen Systemverhalten getroffen werden. Hierfür wurde das Protokoll OPC-UA verwendet, das eine Erfassung von Maschinendaten während des Betriebs ermöglicht. Das IMMS konnte an dieser Stelle seine Expertise in der Datenerfassung und -verwaltung in Industrie-4.0-konformen Umgebungen einbringen.

Eine andere Herausforderung von KMU, die zu Projektbeginn identifiziert wurde, war die Schwierigkeit, erfasste Daten zu verarbeiten. Oft verfügen sie nicht über das notwendige Know-How, um die Masse der vorliegenden Daten zu analysieren.

Das entwickelte Assistenzsystem ist in der Lage, diese Analysearbeiten auf Basis der Daten der Produktionsanlage durchzuführen und dem Anlagenoperator in einer verständlichen Form zu präsentieren. Hierfür wurden verschiedene Verfahren des maschinellen Lernens verwendet, die das Fraunhofer IOSB-INA für industriell eingesetzte Produktionsanlagen entwickelt hat.

Maschinelle Lernverfahren zur Verbesserung der Anlagenproduktivität liegen im Fokus der Forschung [43]. Methoden der künstlichen Intelligenz in die Anwendung zu bringen ist ein Schwerpunkt der Hightech-Strategie 2025 der deutschen Bundesregierung [6]. Im Rahmen dieser Hightech-Strategie soll unter anderem die Steuerung von Produktionsprozessen mithilfe von intelligenten Verfahren vorangetrieben werden. Die Nutzung von maschinellen Lernverfahren, die fehlerhaftes Verhalten in Produktionsanlagen detektieren und mögliche Ursachen vorschlagen, fällt in diesen Förderschwerpunkt.

Durch die steigende Komplexität von Produktionsanlagen ist der Aufwand für ihre Instandhaltung, Wartung und die Reparatur aktuell erhöht. Um eine Überforderung der Anlagenoperatoren mit der Bedienung zu vermeiden, ist ein Ziel der European Factories of the Future Research Association die Integration von Assistenzsystemen [13]. Auch die Plattform Industrie 4.0 beschreibt die zunehmende Digitalisierung als Chance für intelligente Assistenzsysteme [29]. Um den Anlagenoperator jederzeit und umfassend zu unterstützen, können Assistenzsysteme, die die große Masse der Daten der Produktionsanlage aufnehmen und verarbeiten, eingesetzt werden.

Das im Projekt *AgAVE* entwickelte Assistenzsystem führt, basierend auf den Daten der Produktionsanlage, eine automatische Anomalieerkennung und Analyse möglicher Fehlerursachen durch. Die Überwachung findet kontinuierlich während des Anlagenbetriebes statt. Somit ist das Assistenzsystem in der Lage, im laufenden Betrieb eine Aussage über das Anlagenverhalten zu treffen. Bei Normalverhalten führt das Assistenzsystem lediglich eine kontinuierliche Überwachung durch. Tritt ein Fehlerfall ein, analysiert es die Veränderung und gibt mögliche Ursachen aus. Der Anlagenbediener wird somit direkt über Abweichungen des Anlagenverhaltens informiert und kann umgehend reagieren. Stillstandszeiten und größere Maschinenschäden, wie sie bei lange Zeit unentdeckten Fehlern auftreten können, werden somit vermieden.

Das Assistenzsystem basiert auf verschiedenen Methoden des maschinellen Lernens, die Modelle des Anlagenverhaltens lernen. Bei Betrieb der Produktionsanlage können so Abweichungen im Anlagenverhalten detektiert und mögliche Fehlerursachen identifiziert werden. Die gelernten Modelle basieren auf Beobachtungen des

Prozesses. Es ist daher nicht notwendig, ein detailliertes Anlagenmodell zu erstellen. Modifikationen der Produktionsanlage können somit einfach durch einen zusätzlichen Lernprozess in die maschinell erlernten Modelle aufgenommen werden. Es ist keine Adaption der Verfahren an sich notwendig.

Im Fokus der Entwicklung des Assistenzsystems lagen die zwei folgenden wissenschaftlich-technischen Kernfragen:

Wie können kausale Zusammenhänge datengetrieben ermittelt werden? Damit das Assistenzsystem in der Lage ist, mögliche Fehlerursachen zu detektieren, muss es kausale Zusammenhänge in den Daten der Produktionsanlage erkennen. Häufig gemeinsam auftretende Abweichungen in den Daten können ein Hinweis auf einen kausalen Zusammenhang sein. Im Projekt wurden daher Verfahren, die zur Modellierung von Prozessen eingesetzt werden, verwendet und für die Analyse von kausalen Zusammenhängen weiterentwickelt.

In Abbildung 1 ist die Funktionalität des Assistenzsystems gezeigt. Beispielhaft ist der Anwendungsfall eines Transportbandes, verknüpft mit einem Roboterarm, gegeben. Im fehlerfreien Fall transportiert das Förderband eine Flasche zum Roboterarm, der diese Flasche aufnimmt. In Teil A der Abbildung ist der Fall dargestellt, dass die Flasche auf dem Förderband fehlt. Teil B der Abbildung zeigt die Auswirkungen dieses Fehlers - Zum Roboterarm wird keine Flasche geliefert, sodass dieser eine Fehlermeldung herausgibt. Durch das intelligente Assistenzsystem (abgebildet in Teil C), kann der Fehler des Roboterarms auf die fehlende Flasche auf dem Förderband zurückgeführt werden.

Eine Herausforderung war das Lernen von hybriden Daten - Die Daten von Produktionsanlagen bestehen sowohl aus kontinuierlichen als auch aus diskreten Daten. Verfahren des maschinellen Lernens sind meist auf einzelne Schwerpunkte spezialisiert. Während klassische Klassifikationsverfahren Datenpunkte sehr gut voneinander trennen und Kategorien zuordnen können, können zeitbehafte Automaten die im System auftretenden diskreten Ereignisse überwachen und das Zeitverhalten der Anlage bewerten.

Wie können Assistenzsysteme dynamisch vernetzt werden? Üblicherweise ist ein Assistenzsystem auf den Einsatz an einem einzelnen Modul begrenzt. Verschaltete, modulare Anlagen werden so also nicht in ihrer Gänze überwacht, sondern nur jedes Anlagenmodul für sich. Dies hat den Vorteil, dass ein lokales Assistenzsystem auf

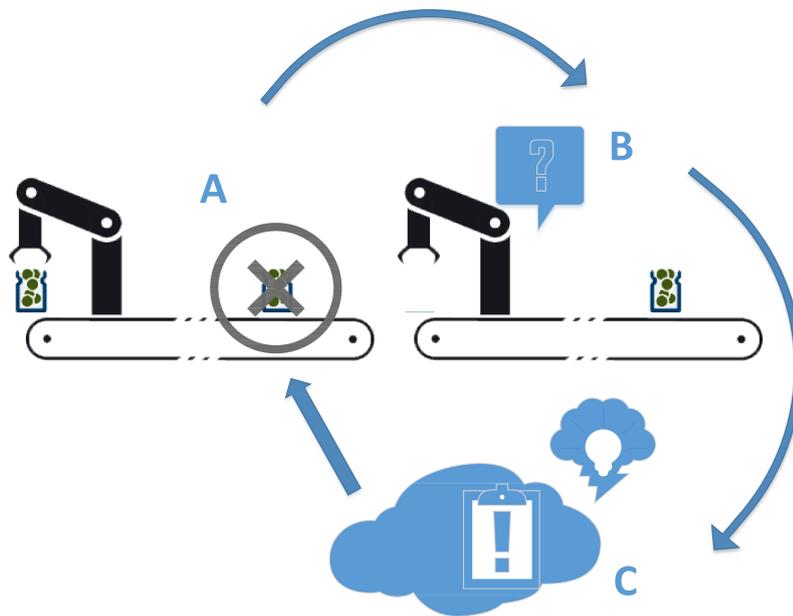


Abbildung 1: Beispielhafter Einsatz des intelligenten Assistenzsystems

die spezifischen Charakteristika der Anlage spezialisiert werden kann. Allerdings sind auf diese Art und Weise keine modulübergreifenden Aussagen möglich. Um kausale Zusammenhänge zwischen den Modulen zu detektieren, ist eine Vernetzung der Assistenzsysteme folglich notwendig.

Daher wurde im Rahmen vom Projekt *AgAVE* ein Konzept entwickelt, wie lokale Assistenzsysteme miteinander verknüpft werden können. Dabei wurde die Kommunikation zwischen Maschinen und Assistenzsystemen als auch zwischen den Assistenzsystemen selbst durch das IMMS mittels Verwaltungsschale und OPC UA Industrie-4.0-konform umgesetzt. So wird jedes lokale Assistenzsystem durch Verwaltungsschale um eine Selbstbeschreibung erweitert, sodass nicht nur die Ausgaben der Assistenzsysteme, sondern auch Informationen über ihren Einsatzbereich verknüpft werden.

Eine über den lokalen Assistenzsystemen liegende Schicht - globales Assistenzsystem genannt - führt auf dieser Basis systemweite Analysen der Anlage durch. Somit können Anomalien, wie zum Beispiel ein Roboterarm ohne Flasche sowie Fehlerursachen - eine fehlende Flasche auf dem Förderband - detektiert werden.

Die zwei dominanten Forschungsziele, die im Projekt *AgAVE* verfolgt wurden sind




Abbildung 2: Globaler Markt der intelligenten Maschinen [4]. Zahlen in Millionen US\$.

also

- **das datengetriebene Lernen von kausalen Abhängigkeiten in verteilten Systemen und**
- **die Definition einer geeigneten Infrastruktur von Schnittstellen für das Assistenzsystem.**

3.2 Wirtschaftliche Bedeutung der Forschungsergebnisse für KMU

Individuelle und flexible Lösungen entlang von Produktionsketten sind die Stärken von KMU. Bislang sind die deutschen Unternehmen, insbesondere KMU, allerdings nicht ausreichend auf die Wachstumsraten der Märkte für Experten- sowie für intelligente Assistenzsysteme vorbereitet. So wird für Expertensysteme bis zum Jahr 2024 ein Wachstum von jährlich 12% bis 15% prognostiziert [4]. Nach dieser Studie ist der Markt für intelligente Assistenzsysteme zwar etwas kleiner, doch mit 30% wird ein wesentlich stärkeres Wachstum pro Jahr prognostiziert.

Zum anderen sind die Produktionsanlagen der Unternehmen auf hohen Durchsatz und einen fortwährenden (24 Stunden - 7 Tage) Betrieb ausgelegt. Stillstandzeiten sind aus diesem Grund möglichst gering zu halten. So entstand im Jahr 2006 den Industrieländern durch Stillstand und Ausfälle der Produktionsmaschinen bzw. -anlagen ein volkswirtschaftlicher Schaden von etwa 5% des Bruttoinlandproduktes. Das entspricht für den Wirtschaftsstandort Deutschland ca. 38 Mrd. Euro[9].

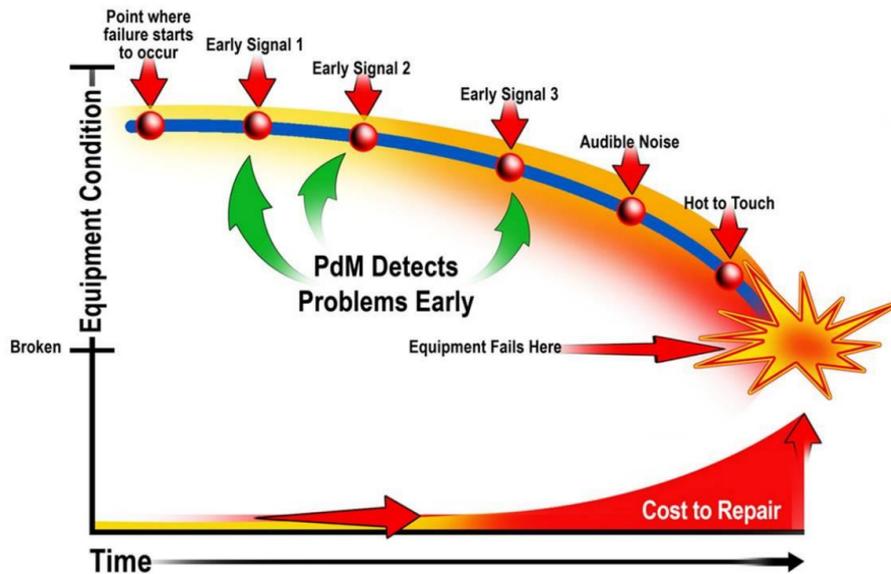


Abbildung 3: Stadien eines ausfallenden Systems nach [36]

So kostet bspw. eine Stillstandsstunde im Spritzguss im Mittel zwischen 10.000€ und 40.000€. Sind diese Anlagen in eine Produktionskette integriert, bspw. in der Automobilindustrie, können sich die Kosten schnell auf mehrere Millionen Euro summieren.

Daher wurden entlang des Projektes *AgAVE* Grundlagen für ein intelligentes Assistenzsystem geschaffen. Damit wird es dem Anlagenbetreiber ermöglicht, die Produktionsprozesse zu analysieren und frühzeitig Anomalien an den eingesetzten Anlagen und Maschinen zu erkennen. Darüber hinaus ist das System fähig, entlang einer Trainingsphase die einzelnen Produktionsschritte, die später überwacht werden sollen, zu erlernen.

Mit diesen Grundlagen zur Analyse der individuellen Produktionsschritte sowie der Anomalieerkennung wird den KMU, die Assistenz- bzw. Expertensysteme in ihrem Portfolio haben, die Möglichkeit geboten, ihre Produkte um eine automatische Anomalieerkennung zu erweitern. Dadurch ist es diesen KMU möglich einen wesentlichen Teil zur prädiktiven Wartung von Anlagen und Maschinen beizutragen.

Den Anlagenbetreibern wird durch den Einsatz der prädiktiven Wartung eine gesteigerte Verfügbarkeit der Maschinen und Anlagen gewährleistet. Sie steigt um 30% bis 50% im Vergleich zu den Produktionszeiträumen ohne prädiktive Wartung. Ein nicht zu unterschätzender positiver Seiteneffekt ist dabei ebenfalls, die längere Lebensdauer der Maschinen und Anlagen, die um ca. 20% bis 40% gesteigert werden kann [39].

Die Geschäftsergebnisse der KMU können durch prädiktive Wartung ebenfalls verbessert werden, da sich die Wartungskosten um 18% bis 25% reduzieren [34]. Dies entlastet die KMU sehr, da die Kosten für die Wartung und Instandhaltung teilweise bis zu 40% der Gesamtkosten betragen können [26]. Somit wird Raum für Investitionen geboten, um die wirtschaftliche Position der KMU zu stärken.

Anlagenherstellern, oft ebenfalls KMU, wird die Möglichkeit geboten ihre Produktionsanlagen mittels der geschaffenen Grundlagen mit Analyseassistenten auszustatten. Für sie eröffnen sich neben dem eigentlichen Verkauf ihrer Anlagen auch neue Geschäftsmodelle.

So gibt es neben der Möglichkeit, Expertensysteme oder intelligente Assistenzsysteme als Bestandteil von Produktionsanlagen zu vertreiben, ebenfalls die Möglichkeit die Maschine nicht mehr direkt als solche zu verkaufen, sondern Betriebszeit der Maschine. Dies eröffnet gleichzeitig für den Betreiber der Maschine oder Anlage nur für die eigentliche Nutzung zu bezahlen. Somit wird der Hersteller aufgrund der Pay-Per-Use-Methode sicherstellen müssen, dass die Anlage möglichst oft einsatzfähig ist.

Weitere Service-Modelle für den Einsatz der Analyseassistenten sind nach [22]:

- **Equipment-Health-Monitoring und Maintenance-Empfehlungen als Dienstleistung**
- **Garantie als Dienstleistung**
- **Supply-Chain-Management-Informationen als Dienstleistung**

4 Durchgeführte Arbeiten und Ergebnisse

Entlang des Projektes *AgAVE* sollten algorithmische Grundlagen für Assistenzsysteme, welche direkt in den Anlagenbetrieb integriert werden und den Anlagenbediener bei den Analyseaufgaben (z.B. Fehlersuche) unterstützen, geschaffen werden. Weiterhin war zu untersuchen, wie diese Form der Assistenzsysteme in Industrie-4.0-Umgebungen zu integrieren sind. Für die Forschungsarbeiten ist die nachfolgend erläuterte Arbeitshypothese herangezogen worden.

4.1 Arbeitshypothese

Forschungsziel 1: Lernen von kausalen Abhängigkeiten in verteilten Systemen
Basis für eine erfolgreiche Diagnose in einer Produktionsanlage ist die genaue Kenntnis über jeden einzelnen Zustand. Es existiert eine Reihe von Verfahren im Bereich des maschinellen Lernens, welche Modelle des Anlagenverhaltens lernen. Jedes dieser Verfahren ist für einen ganz bestimmten Einsatzbereich bestimmt (z.B. zeitbehaftete Automaten für die zeitliche Abfolge von diskreten Events, oder die Principal Component Analysis (PCA) für die Analyse einer Menge von kontinuierlichen Signalverläufen). Zudem ist es aufgrund der Kombinatorik nicht möglich, ein einziges Modell für ein verteiltes System zu lernen, da das Vorhandensein von parallelen Prozessen die Komplexität des Modells enorm ansteigen lässt [25]. Ziel von *AgAVE* war daher die Entwicklung einer übergeordneten Lernschicht, der symbolischen Ebene (High-Level-Learning, siehe Abbildung 4), die in der Lage ist, aus den Ausgaben der unterschiedlichen, lokalen Modelle kausale Abhängigkeiten zu erlernen.

Lernen auf symbolischer Ebene Zweck der Assistenzsysteme ist die Unterstützung des Mitarbeiters in diversen Aufgaben wie z.B. der Fehlerdiagnose sowie die Reduktion der Systemkomplexität. Viele maschinelle Lernverfahren sind für den Einsatz in Assistenzsystemen ungeeignet, da der Output nicht in einer intuitiven Art und Weise vom Menschen interpretiert werden kann. Dies ist jedoch Voraussetzung für einen erfolgreichen Einsatz in einem Assistenzsystem. Das Problem liegt darin, dass maschinelle Lernverfahren typischerweise auf subsymbolischer Ebene arbeiten (Low-Level-Learning). Um die Ergebnisse dem Menschen zugänglich zu machen, müssen jedoch Algorithmen entwickelt werden, die auf symbolischer Ebene arbeiten (High-Level-Learning). Abbildung 4 verdeutlicht den Unterschied zwischen dem Low-

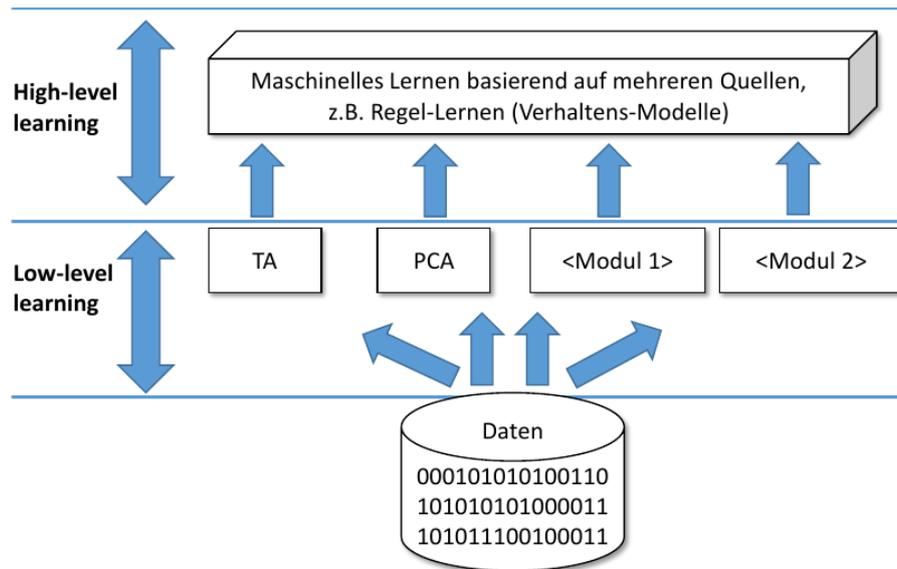


Abbildung 4: Unterscheidung in High-Level- und Low-Level-Learning

Level- und dem High-Level-Learning. Während beim Low-Level-Learning lediglich auf Maschinenkomponenten begrenzte Modelle gelernt werden können, die zudem nur bestimmte Aspekte des Verhaltens abdecken können (diskret, kontinuierlich, etc.), soll mit Methoden des High-Level-Learning die Kombination aller untergelagerten Verfahren ermöglicht werden (siehe Abbildung 4). Zusätzlich sollen sie in einer für den Menschen verständlichen Form aufbereitet werden, z.B. durch Integration von semantischem Wissen (Benennung der Systemzustände) oder eine interpretierbare Struktur (Regeln „wenn... dann...“).

Das High-Level-Learning ermöglicht sowohl die Kombination unterschiedlich gearteter Modellformalismen (z.B. Timed Automata (TA) und Principal Component Analysis (PCA), Neuronale Netze, Bayessche Netze, Clustering-Verfahren, Klassifikationsalgorithmen wie Support Vector Machine) als auch die Kombination der Modelle unterschiedlicher Module, was wiederum eine globale Systemmodellierung ermöglicht. Als mögliche Lernverfahren kommen hier regel- und fallbasierte Methoden in Frage. Insbesondere regelbasierte Lernverfahren sind an dieser Stelle vielversprechend, da sie aufgrund ihrer Struktur (wenn... dann ...) kausale Zusammenhänge ermitteln können. Basierend auf unterschiedlichen Lernverfahren des Low-Level-Learning sind die einzelnen Module (hier Roboter und Förderband) in der Lage, Meldungen über den Zustand zu broadcasten. Das Ziel ist nun, diese „Broadcast-Nachrichten“ in Bezug auf vorhandene Kausalitäten auszuwerten. Abbildung 5 zeigt an einem minimalen

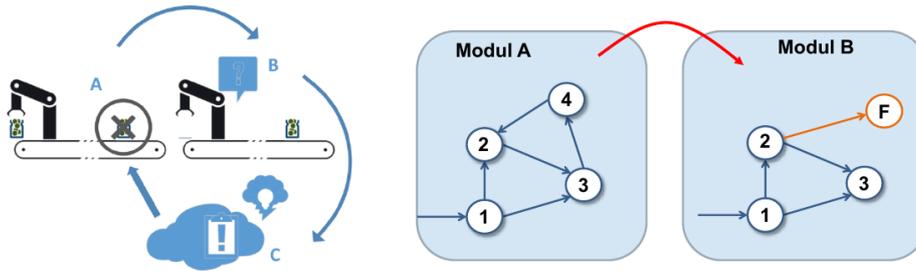


Abbildung 5: Verwendung von regelbasiertem Lernen auf dem High-Level, um Modelle des Low-Level zu kombinieren.

Beispiel, wie das Lernen von Regeln auf dem High-Level verwendet werden kann, um Modelle des Low-Level zu kombinieren und daraus auf kausale Zusammenhänge zu schließen. Eine entsprechende Regel könnte wie folgt aussehen: „Wenn das Förderband A steht, dann bekommt das Modul B keine Flasche.“ Der technische Hintergrund dieser Regel wäre der folgende: „Wenn Modul A in Zustand 4 und $t > 5s$, dann ist das Modul B in Fehlerzustand F.“ Der gelernte Automat liefert weitere Details zu den einzelnen Zuständen - Zustand 4 von Modul A entspricht „Förderband steht“, während der Zustand F von Modul B dem Fehlerzustand „Flasche fehlt“ entspricht. Das Lernen der zugrundeliegenden Zustandsautomaten wurde im Vorgängerprojekt *ANUBIS* (FKZ: 16419 BG/2) erforscht (z.B. (Hy-)BUTLA) und sollte in diesem Projekt nachgenutzt werden.

Alternativ zum Regel-Lernen können Algorithmen der Mustererkennung und des Clusterings angewendet werden, um kausale Zusammenhänge zu erkennen. Dazu werden die Daten nach häufig wiederkehrenden Mustern durchsucht, wodurch Zusammenhänge erkannt werden können, die für die weitere Analyse hilfreich sein können, z.B. „Jeden Morgen steigt der Energieverbrauch sprunghaft an.“ oder „Die Zustands-paare $Modul_A/Zustand_4$ und $Modul_B/Zustand_F$ treten häufig gemeinsam auf.“ Das zweitgenannte Muster entspricht dabei der Regel aus dem vorherigen Abschnitt. Hierbei ist allerdings die Vorsicht geboten, beobachtete Korrelationen nicht mit Kausalität zu verwechseln.

Des Weiteren sollen fallbasierte Methoden verwendet werden. Für jeden detektierten Fehler wird ein Fall in der Form ($Fall_C = Anomalie + Ursache$) gespeichert. Anschließend werden Ähnlichkeitsmaße gelernt, welche Funktionen der Fallbeschreibungen sind (Funktion $f(c1, c2)$ mit den Fallbeschreibungen $c1, c2$). Für neu eintretende Fälle werden mittels der Ähnlichkeitsmaße ähnliche Fälle gesucht. Wichtig ist dabei, dass

die Fälle mit Features formalisiert werden. Des Weiteren werden Zusammenhänge zwischen diesen Anomalien und Fehlerursachen in einer Datenbank gespeichert und bilden somit ein Gedächtnis für den Diagnoseassistenten, welches bei zukünftigen Diagnosen genutzt werden kann, um Anomalien noch zuverlässiger zu erkennen und einer Ursache zuzuordnen.

Abgrenzung: Ziel des Projektes ist es nicht, neue mathematische Methoden für die Analyse von Kausalitäten zu entwickeln, sondern auf einer algorithmischen Ebene (datentrieben) kausale Zusammenhänge zu erkennen. Hierzu werden u.a. existierende mathematische Methoden verwendet.

Forschungsziel 2: Definition einer geeigneten Infrastruktur für das Assistenzsystem Das in diesem Projekt angestrebte Assistenzsystem muss in der Lage sein, Daten von verschiedenen Modulen entgegen zu nehmen, damit diese zur Modellbildung und anschließend zur Diagnose genutzt werden können. Um dies zu gewährleisten, soll im Projekt ein Architekturvorschlag für solch ein modulares Assistenzsystem entworfen werden, dieser auf sein Verhalten hin validiert und ein übergreifender Ansatz abgeleitet werden. Somit soll sichergestellt werden, dass er für die Erfassung und Bewertung von Maintenance-Daten in Industrie-4.0-Architekturen unter Berücksichtigung von Cloudsystemen geeignet ist. Damit wird den beteiligten KMU ein Werkzeug an die Hand gegeben, um eigene Lösungen für sich abzuleiten und somit ein Angebot für Assistenzsysteme bestehend aus Hardware und Software anzubieten. Dazu werden folgende Schwerpunkte im Projekt untersucht:

Plattformen für Industrie-4.0-fähige Dienste Eingebettete Plattformen stehen von vielen kommerziellen Anbietern für die Verarbeitung von Sensordaten und prozessnahen Daten zur Verfügung. Meist sind diese auf bestimmte Anwendungsbereiche zugeschnitten und berücksichtigen noch keine Industrie-4.0-Anforderungen. Im Projekt sollen deshalb die Standards und Normen der Industrie-4.0-konformen Kommunikation auf ihre Eignung für die Übertragung der Informationen des Assistenzsystems untersucht werden. Weiterhin werden grundsätzlich offene Architekturen betrachtet, so dass eine Nachnutzung durch die KMU ohne zusätzliche Lizenzkosten ermöglicht wird. Beispielhaft soll an dieser Stelle Open Core Engineering von BoschRexroth oder auch das MICA-Konzept von Harting erwähnt werden [5, 19]. Für dieses Projekt soll einerseits eine Plattform ausgewählt werden, die in der Lage ist, die auf dem

PC entwickelten Lernalgorithmen auszuführen als auch selbst Industrie-4.0-konforme Schnittstellen anzubieten, um die Vernetzung dieser Systeme auf der entsprechenden Ebene zu ermöglichen. Ein weiterer Aspekt, der untersucht werden soll, ist die Einbindung von Cloud-Services, um die notwendigen Algorithmen abzuarbeiten und entstehende Ergebnisse zur Verfügung zu stellen. In Cloud-Architekturen steht hinreichend viel Verarbeitungskapazität zur Verfügung, so dass keine Reduzierung der Umfänge an den Lernalgorithmen wie auf eingebetteten Plattformen notwendig ist. Jedoch muss untersucht werden, ob die zusätzliche Latenz, die bei der Übertragung über größere Entfernungen entsteht, Auswirkungen auf die Ergebnisse bei den Algorithmen hat. Zwar steht die Vermutung im Raum, dass aufgrund der Zeitsynchronisation bei der Erhebung der Sensordaten und der Vergabe von Zeitstempeln alle notwendigen Informationen für eine zentrale Verarbeitung zur Verfügung stehen, jedoch werden große Datenmengen erzeugt und übertragen, was Auswirkungen auf die beteiligte Infrastruktur haben kann. Insofern sollen im Projekt alle Aspekte einer dezentralen versus zentralen Verarbeitung untersucht werden. Zusätzlich soll berücksichtigt werden, ob notwendige Daten für die Lernalgorithmen auch von anderen Systemen kommen können und damit die Erhebung der Daten nicht doppelt geschehen muss. Es ist außerdem zu verifizieren, ob zwischen dem „Lern-Modus“ und der Verhaltensanalyse während der Betriebsphase der beteiligten Systeme Unterschiede zu finden sind, welche Auswirkungen auf den Ort der Verarbeitung haben.

Kopplung von Assistenzsystemen Um das Lernen von kausalen Abhängigkeiten in verteilten Systemen zu unterstützen, gibt es den zentralen und den dezentralen Ansatz. Im Projekt soll ein dezentraler Ansatz untersucht werden, d.h. auf Basis der Ergebnisse von verschiedenen Assistenz-Modulen übergreifende Aussagen zu gewinnen. Dazu müssen die einzelnen Assistenz-Module auf Basis einer einheitlichen (Service-)Schnittstelle, welche in diesem Projekt definiert und beispielhaft implementiert werden soll, miteinander verbunden werden. Dazu soll untersucht werden, welche Daten in welcher zeitlichen Auflösung benötigt werden, um übergreifende Aussagen abzuleiten. Weiterhin muss analysiert werden, wie das Zusammenspiel zwischen den beteiligten Systemen organisiert werden muss. Dabei ist die Frage zu klären, ob einzelne Module übergreifende High-Level-Learning Methoden ausführen können (Master-Modus), oder ob zusätzliche Systeme für die Ableitung übergreifender Aussagen von Nöten sind, die in die Architektur integriert werden müssen. Ein Ansatz, der in diesem Projekt auf Eignung untersucht werden soll, ist ein container-basierter Ansatz

für die Überwachungsalgorithmen, welcher einerseits die Funktionen für die Abarbeitung kapseln kann und andererseits die Möglichkeit bietet, die Container (Funktionen) über Systemgrenzen hinweg auszutauschen. Damit bestünde die Möglichkeit, flexibel Ketten von Lernalgorithmen zu definieren und diese dynamisch auf die zur Verfügung stehenden Systeme zu verteilen. Dies minimiert den Hardwareaufwand für die Assistenzfunktionen und ermöglicht den flexiblen Umgang mit den gekapselten Methoden in Industrie-4.0-Architekturen. Nach Untersuchung der unterschiedlichen Möglichkeiten soll ein übergreifender Ansatz zur Erfassung und Bewertung von Maintenance-Daten in Industrie-4.0-Architekturen unter Berücksichtigung von Cloudsystemen abgeleitet werden, der für KMU als Referenz zum Aufbau solcher Serviceangebote genutzt werden kann. Dies soll z.B. über angebotene Workshops und Vorträge im Rahmen von Konferenzen und Messen geschehen.

4.2 Arbeitspaket 1: Erfassung der Anforderungen

Damit das Assistenzsystem beim Einsatz an Anlagen und Maschinen eine Unterstützung zur Analyse der Arbeitsvorgänge / -prozesse der täglichen Arbeiten ist, gilt es die genauen Anforderungen an ein solches Assistenzsystem zu untersuchen. Berücksichtigung finden bei dieser Analyse zur Einsetzbarkeit zum einen die Anforderungen aus Sicht der Endanwender als auch die Anforderungen an die Infrastruktur eines solchen Assistenzsystems.

4.2.1 AP 1.1: Analyse und Definition der Anforderungen

Im Arbeitspaket 1.1 wurden die zur konzeptionellen Umsetzung des Assistenzsystems gestellten Anforderungen aus Sicht der benannten Endanwender (Riha Wesergold, Weidmüller Interface und 3D-Schilling) des projektbegleitenden Ausschusses analysiert und definiert. Ein Fragenkatalog diente dabei zur Identifikation der genauen Umgebungen.

Ergebnisse	Ein Fragebogen zur Identifikation der Anforderung an Assistenzsysteme sowie ein daraus abgeleitetes Dokument zur Auflistung der Anforderungen an Assistenzsysteme. Weiterhin entstand ein Konzept zur Durchführung von <i>AgAVE</i> , welches die Anforderungen der Endanwender aufgreift und entsprechende Forschungsfragen definiert. Bestandteil des Konzeptes sind dabei (i) eine Anlagenbeschreibung, (ii) Anforderungen für die Einsatzszenarien, (iii) eine Beschreibung der Messsignale für die Anlage und (iv) typische Fehlersituationen sowie Wartungszyklen.
Personaleinsatz	FE 1 (INA): HPA A: 0,75 PM HPA B: 0,00 PM FE 2 (IMMS): HPA A: 0,65 PM HPA B: 0,75 PM
Erfüllungsgrad	100 %

4.2.2 AP 1.2: Analyse und Definition der Anforderungen an die Infrastruktur

Im Arbeitspaket 1.2 werden die zur konzeptionellen Umsetzung des Assistenzsystems gestellten Anforderungen aus Sicht der Komponentenentwickler und Systemintegratoren (TE Connectivity, ifm electronic, iba AG, Weidmüller Interface, BN Automation AG und pmOne) des projektbegleitenden Ausschusses an die Infrastruktur bzw. Architektur eines solchen Assistenzsystems analysiert und definiert. Ein Fragenkatalog diente dabei zur Identifikation der genauen Anforderungen.

Ergebnisse	Ein Fragebogen zur Identifikation der Anforderung an Assistenzsysteme sowie ein daraus abgeleitetes Dokument zur Auflistung der Anforderungen an Assistenzsysteme. Weiterhin entstand ein Konzept zur Durchführung von <i>AgAVE</i> , welches die Anforderungen der Komponentenhersteller und Systemintegratoren aufgreift und entsprechende Forschungsfragen definiert. Bestandteil des Konzeptes sind dabei Architektur der Analyseebenen, einsetzbare Plattformen bzw. Schnittstellen und die Industrie-4.0-Konformität.
Personaleinsatz	FE 1 (INA): HPA A: 0,80 PM HPA B: 0,00 PM FE 2 (IMMS): HPA A: 1,22 PM HPA B: 0,76 PM
Erfüllungsgrad	100 %

4.3 Arbeitspaket 2: Systemmodellierung und Maschinelles Lernen

4.3.1 AP 2.1: Übernahme der Methoden aus Vorarbeiten

Um das Normalverhalten von Produktionsanlagen zu erlernen, wurden bereits im Vorgängerprojekt *ANUBIS* Algorithmen entwickelt. Diese wurden im Projekt *AgAVE* weiterentwickelt, sodass sie in modularen Produktionsanlagen anwendbar sind.

Im Projekt *ANUBIS* wurde der Einsatz von hybriden, zeitbehafteten Automaten im Produktionsumfeld erprobt. Zeitbehaftete Automaten sind explizite Verfahren, die zu jedem Zeitpunkt Informationen über den aktuellen Zustand der Maschine geben. Abbildung 6 zeigt grafisch, wie der Algorithmus *HyBUTLA*, der in *ANUBIS* verwendet wurde, arbeitet. Das Verfahren basiert auf vier Schritten:

- Im ersten Schritt werden Messungen an der Anlage durchgeführt, die zunächst in einer Datenbank abgespeichert werden.

- Im zweiten Schritt werden Ereignisse (auch Events) generiert, die Umschaltprozesse in der Anlage darstellen.
- Danach wird ein zeitbehafteter Automat erstellt, der zunächst eine Baumstruktur (das heißt es gibt keine Zyklen in der Struktur) hat.
- Anschließend wird die Struktur des Automaten reduziert, indem übereinstimmende Äste miteinander migriert werden.

Ein Nachteil dieses Verfahrens ist, dass die Daten der Produktionsanlage zunächst einmal abgespeichert werden müssen. Der manuelle Aufwand für die Implementierung ist daher relativ hoch. Daher wurde der Algorithmus *Online Timed Automaton Learning Algorithm (OTALA)* entwickelt [24]. Dieser Algorithmus ist sehr ähnlich zu *HyBUTLA*, allerdings ist für die Implementierung kein gespeicherter Datensatz notwendig. Der Algorithmus ist dazu in der Lage, den dahinterliegenden Automaten bei Betrieb der Anlage (online) zu erlernen. Ein eingebautes Konvergenzkriterium beendet die Lernphase, wenn das Modell ausreichend genau ist und überführt das Verfahren eigenständig in die Überwachungsphase. Die Zustände dieses Automaten repräsentieren die möglichen Anlagenzuständen, die Transitionen repräsentieren den Übergang von einem Zustand zum nächsten. Während der Lernphase wird die durchschnittliche Dauer der Transitionen bestimmt. So kann in der Überwachungsphase überprüft werden, ob sich die Anlage wie das gelernte Modell verhält. Tritt ein Zustand auf, der in der Lernphase nicht aufgetreten ist, wird dies durch den Algorithmus detektiert. Bei solch einem Zustand kann es sich um einen Fehler, zum Beispiel ein stehendes Förderband oder ein verstopftes Rohr, handeln.

Zusätzlich wurde am Fraunhofer IOSB-INA ein Verfahren entwickelt, mit dem Abweichungen in den kontinuierlichen Anlagenparametern erkannt werden können [11]. Es basiert auf der Kombination einer Hauptkomponentenanalyse und einer Nächsten-Nachbarn-Klassifikation. Dafür wird die Dimension der Daten zunächst durch Analyse der Hauptkomponenten reduziert. Anschließend wird der Abstand des zu überprüfenden Datenpunktes zu den Datenpunkten, die Normalverhalten repräsentieren, bestimmt. Auf Basis dessen wird eine Wahrscheinlichkeit bestimmt, die ein Maß dafür ist, ob der Punkt eine Anomalie repräsentiert.

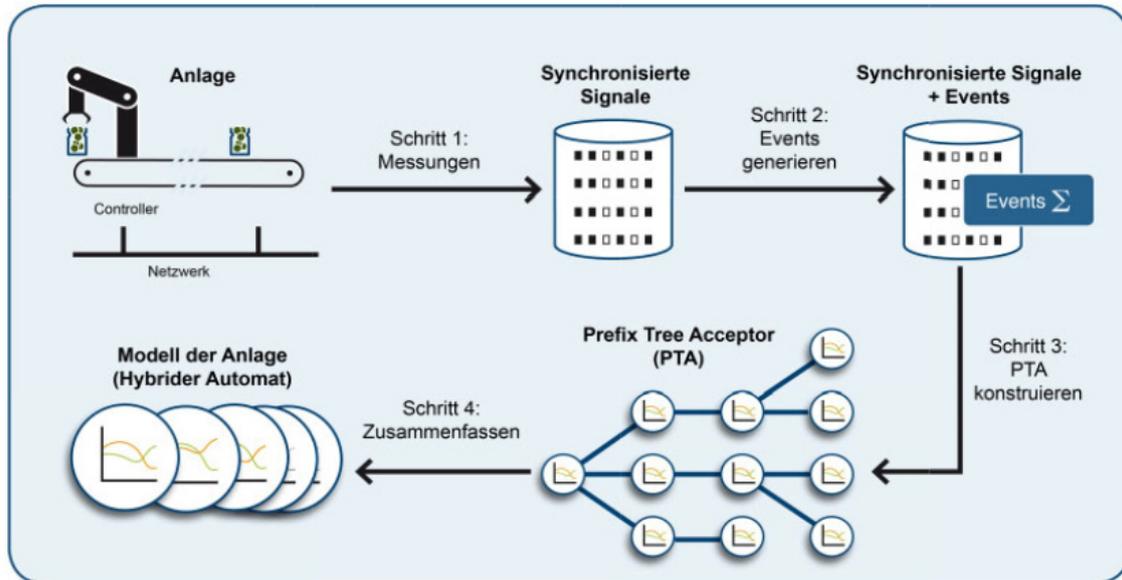


Abbildung 6: Grafische Darstellung des Algorithmus *HyBUTLA*

Ergebnisse	Eine Auswahl von geeigneten Algorithmen wurde getroffen, die für den Einsatz in realen Produktionsanlagen vielversprechend erscheinen. Die verschiedenen Verfahren wurden bereits an Demonstratoren und realen Produktionsanlagen erprobt.
Personaleinsatz	FE 1 (INA): HPA A: 1,10 PM HPA B: 0,00 PM FE 2 (IMMS): HPA A: 0,00 PM HPA B: 0,00 PM
Erfüllungsgrad	100 %

4.3.2 AP 2.2: Erweiterung der Algorithmen für alternative Verfahren

Die in Arbeitspaket 2.1 getroffene Auswahl der Algorithmen wurde in diesem Arbeitspaket erweitert. Bestehende Algorithmen wurden auf den Einsatz in modularen Produktionsanlagen angepasst. Dabei lag ein Schwerpunkt auf der Entwicklung von herstellerunabhängigen und anlagentypunabhängigen Verfahren. Somit kann das ent-

wickelte Assistenzsystem in verschiedenen Anlagen unterschiedlichen Produktionstyps eingesetzt werden.

Eine Herausforderung hier war die Schaffung einer einheitlichen Schnittstelle zu den Algorithmen, damit diese unabhängig von dem dahinterliegenden Verfahren vom globalen Assistenzsystem angesteuert werden können. Daher wurden sämtlich Verfahren mittels der Interpretersprache *python* implementiert. Die jeweiligen Algorithmen stellen dabei Instanzen einer Algorithmus-Klasse dar, die über eine einheitlich Schnittstelle verfügt. Somit wird jeder Algorithmus auf die gleiche Art und Weise angesteuert, was eine flexible Auswahl der Algorithmen ermöglicht.

Zusätzlich wurden etablierte Verfahren des maschinellen Lernens (Klassifikationsverfahren, Clusteringverfahren, Ausreißeranalyse, Neuronale Netze, ...) auf ihre Anwendbarkeit im Bereich der Anomalieerkennung in Produktionsanlagen untersucht. Eine Implementierung dieser Verfahren wurde ebenfalls an das Assistenzsystem angebunden.

Um kausale Zusammenhänge in den Anlagendaten zu detektieren, lag ein besonderer Fokus auf der Auswahl erklärbarer Verfahren. So liefern zum Beispiel zeitbehafte Automaten nicht nur Informationen über auftretende Anomalien, sondern auch über den aktuellen Anlagenzustand und den Prozessschritt, der zu der Anomalie geführt hat. Bei Überwachung mehrerer Module können durch Gebrauch erklärbarer Verfahren kausale Zusammenhänge (zum Beispiel ein stehendes Förderband in Modul A führt zu einem fehlenden Produkt in Modul B) detektiert werden.

Ergebnisse	Ansatz zum Lernen von Anlagendaten, hier liegt der Fokus insbesondere auf der Möglichkeit, Daten unabhängig vom Anlagentyp zu erlernen.
Personaleinsatz	FE 1 (INA): HPA A: 6,80 PM HPA B: 0,00 PM FE 2 (IMMS): HPA A: 0,00 PM HPA B: 0,00 PM
Erfüllungsgrad	90 %

4.3.3 AP 2.3: Schnittstellen zur Kopplung von Assistenzsystemen

Im Arbeitspaket 2.3 galt es die Kommunikationsschnittstellen der einzelnen Assistenzsystemmodule (Low-Level- und High-Level-Learning) untereinander als auch mit den Anlagen- bzw. Maschinenmodulen zu eruieren. Bestandteil der Analysen ist dabei ebenfalls die Definition der benötigten Granularität der Daten als auch Wege, um auf die Daten entlang von Industrie-4.0-Netzwerken zugreifen zu können. Eingeflossen sind zur Ausarbeitung eines Kommunikationsschnittstellenarchitekturkonzepts die verfügbaren individuellen Kommunikationsschnittstellen der Anlagen- bzw. Maschinen bei den Mitgliedern des projektbegleitenden Ausschusses.

Damit die einzelnen Komponenten des Assistenzsystems auf eine standardisierte Art und Weise ihre Daten austauschen können wurde als Kommunikationsschnittstelle OPC UA aus mehreren Gründen gewählt. Zum einen ist OPC UA der Quasi-Kommunikationsstandard entlang von Industrie-4.0-Netzwerken. Weiterhin ist es mittels OPC UA möglich zusätzlich zu den übertragenen Datenwerten eine entsprechende Semantik zu übertragen. Außerdem kann mithilfe der in OPC UA umgesetzten Verwaltungsschale die Selbstbeschreibung der Komponenten des Assistenzsystems realisiert werden. Ein weiterer nicht zu unterschätzender Vorteil von OPC UA ist die Möglichkeit das Assistenzsystem in vorhandene Infrastrukturen die bereits OPC UA einsetzen zu integrieren.

Ergebnisse	Ein Architekturkonzept zur Vernetzung der einzelnen Module eines Analyseassistenten unter Verwendung von OPC UA als auch für den Aufbau der Verwaltungsschale zum Datenaustausch zwischen den Analyseassistenten und Anlagen- bzw. Maschinenmodulen. Für die Umsetzung des Aufbaus und zur Integration des Assistenzsystems in Industrie-4.0-Umgebungen wurden die benötigten Schnittstellen mit OPC UA als auch die individuellen Verwaltungsschalen für die Analyseassistenten implementiert. Dafür wurde eine <i>AgA-VE</i> -Assistenzsystemtypdefinition für den Einsatz der individuellen Instanziierung von virtuellen Repräsentationen der Analyseassistenten in den OPC-UA-Servern der einzelnen Low-Level-Assistenten spezifiziert, definiert und umgesetzt.
Personaleinsatz	FE 1 (INA): HPA A: 0,00 PM HPA B: 0,00 PM FE 2 (IMMS): HPA A: 2,40 PM HPA B: 3,40 PM
Erfüllungsgrad	100 %

4.3.4 AP 2.4: Plattformuntersuchungen für I4.0-fähige Dienste

An Plattformen für Assistenzsysteme, die entlang von Industrie-4.0-Netzwerken eingesetzt werden sollen, wurden zur Sicherstellung der Konformität der zu integrierenden Geräte Anforderungen seitens der Plattform Industrie 4.0 definiert. So müssen Kommunikationsparadigmen und gängige Security-Richtlinien eingehalten werden sowie verschiedene Dienste zur Verfügung stehen, damit die Geräte zu Industrie-4.0-Komponenten werden können. Dafür wurden im Arbeitspaket 2.4 vorhandene Hardware / Software-Plattformen auf Ihre Eignung für das maschinelle Lernen im Industrie-4.0-Umfeld untersucht. Wobei der Fokus auf die Möglichkeit der Kapselung der Algorithmen als auch deren Integration in vorhandene Infrastrukturen gerichtet wurde. Untersucht wurden container-basierte Konzepte oder auch die Bereitstellung als Dienst; z.B. in Form von Software-as-a-Service (SAAS).

Im Hinblick auf eine Integration der Analysemodule in Anlagensteuerungen wurden

die Arbeiten in Arbeitspaket unter dem Aspekt durchgeführt, die Analysen auch auf eingebetteten Systemen durchführen zu können.

Ergebnisse	Konzept zur Integration von Assistenzsystemen in Industrie-4.0-Umgebungen. Es enthält darüber hinaus das finale Verwaltungsschalenkonzept für den Einsatz bzgl. des Datenaustausches zwischen den einzelnen Analyseassistenten untereinander als auch mit den Anlagen- bzw. Maschinenmodulen. Dabei dient die Verwaltungsschale als virtuelle Repräsentation und Beschreibung der technischen Funktionalität der individuellen Analysemethoden. Assistenzsystem-Verwaltungsschalen mittels <i>pythonOPCUA</i> umgesetzt, wobei auf die Kompatibilität zum Open-Source-Projekt <i>openAAS</i> geachtet wurde. Demonstrator für den Verwaltungsschalenprototyp (<i>openAAS, pythonOPCUA</i>).
Personaleinsatz	FE 1 (INA): HPA A: 0,00 PM HPA B: 0,00 PM FE 2 (IMMS): HPA A: 2,55 PM HPA B: 4,45 PM
Erfüllungsgrad	100 %

4.3.5 AP 2.5: Lernen von kausalen Zusammenhängen in hybriden Systemen

Um kausale Zusammenhänge in hybriden Systemen zu detektieren, müssen die Ausgaben der lokalen Assistenzsysteme analysiert werden. Diese Ausgaben haben eine unterschiedliche Struktur. Zeitbehaftete Automaten liefern Informationen über den aktuellen Systemzustand, mögliche Fehler und an welchem Modul diese Fehler aufgetreten sind. Die Kombination der Hauptkomponentenanalyse mit einer Nächsten-Nachbarn-Klassifikation liefert eine Wahrscheinlichkeit, ob das aktuelle Systemverhalten fehlerhaft ist. Bei Einsatz eines neuronalen Netzes als Klassifikator wird eine Einordnung des aktuellen Systemverhaltens in eine Klasse bestimmt. Die Aussagekraft dieser Ausgabe ist von der Definition der Klassen abhängig.

All diese Ausgaben haben gemein, dass sie *symbolischer* Natur sind. Sie haben kein numerisches Maß sondern transportieren ihre Ausgabe durch ein Symbol. Die

Interpretation des Symbols liefert die entsprechende Information.

Wie die Ausgaben der einzelnen Module von einem übergeordneten Assistenzsystem verarbeitet werden können, wurde in diesem Arbeitspaket untersucht.

Der Einsatz von regel- und fallbasierten Methoden wurde untersucht:

Regelbasierte Methoden basieren auf einem Verfahren, das in der Lage ist, aus einem Beispieldatensatz generische Regeln zu generieren. Dazu gehören zum Beispiel Lernverfahren von Entscheidungsbäumen. Bäume bestehen aus Knoten und Kanten, die die Knoten miteinander verbinden. Die Knoten von Entscheidungsbäumen repräsentieren einzelne Entscheidungen in Form von linearen Ungleichungen. Abhängig davon, ob die Ungleichung erfüllt ist, wird auf einen nachfolgenden Knoten verwiesen, der wiederum eine Entscheidung repräsentiert. Nach einer Anzahl von einzelnen Entscheidungen wird auf einen Knoten verwiesen, der Auskunft darüber gibt, ob ein Fehler vorliegt. Abbildung 7 zeigt einen Entscheidungsbaum, der beispielhaft im höherliegenden Assistenzsystem eingesetzt werden kann. Beginnend beim obersten Knoten, wird zunächst die Ausgabe des Verfahrens *PCNA* (Kombination der Hauptkomponentenanalyse mit Nächsten-Nachbarn-Klassifikation) untersucht. Ist diese Ausgabe kleiner als 0.05, wird mit dem nächsten Knoten fortgefahren. Angenommen, die Ausgabe ist größer als 0.05, wird die Ausgabe des Verfahrens *OTALA* (zeitbehaftete Automaten) untersucht. Ist diese gleich 2, liegt ein Fehler vor. Andernfalls wird eine weitere Ausgabe untersucht, um zu bestimmen, ob das aktuelle Maschinenverhalten fehlerhaft ist oder nicht.

Bei der Verwendung von fallbasierten Methoden wird ein aktueller Datenpunkt mit einer abgespeicherten Fallbasis verglichen. Der ähnlichste Fall wird gesucht und die passenden Lösungsmethoden zu dem Fall werden vorgeschlagen. Eine Herausforderung hierbei ist die Generierung der Fallbasis. Diese besteht aus historischen Fällen, die typisches Anlagenverhalten repräsentieren. Somit muss zur Erstellung eine Reihe von Tests gefahren werden, die sowohl fehlerfreies als auch fehlerhaftes Anlagenverhalten repräsentieren. In der späteren Überwachungsphase können nur Fehler erkannt werden, die sich in der Fallbasis befinden. Unbekannte Fehler können nicht detektiert werden oder werden einem anderen Fehlerfall zugeordnet. Eine weitere Herausforderung ist die Definition von Ähnlichkeit von Fällen. Da hier Ausgaben symbolischen Charakters verglichen werden, wurde eine Metrik entwickelt, die auf symbolischer Ebene arbeitet.

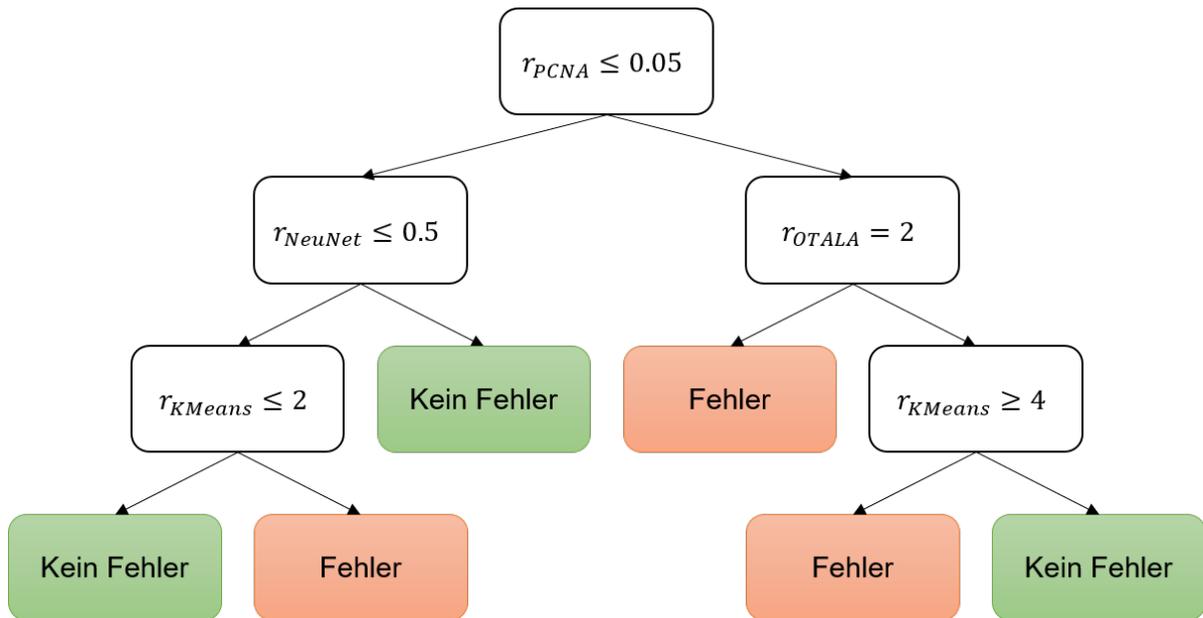


Abbildung 7: Grafische Darstellung eines Entscheidungsbaumes

Ergebnisse	neue Algorithmen für die Identifikation von Kausalitäten in verteilten Produktionsanlagen
Personaleinsatz	FE 1 (INA): HPA A: 8,70 PM HPA B: 0,00 PM FE 2 (IMMS): HPA A: 0,00 PM HPA B: 0,00 PM
Erfüllungsgrad	85 %

4.4 Arbeitspaket 3: Ablaufumgebungen für Assistenzsysteme

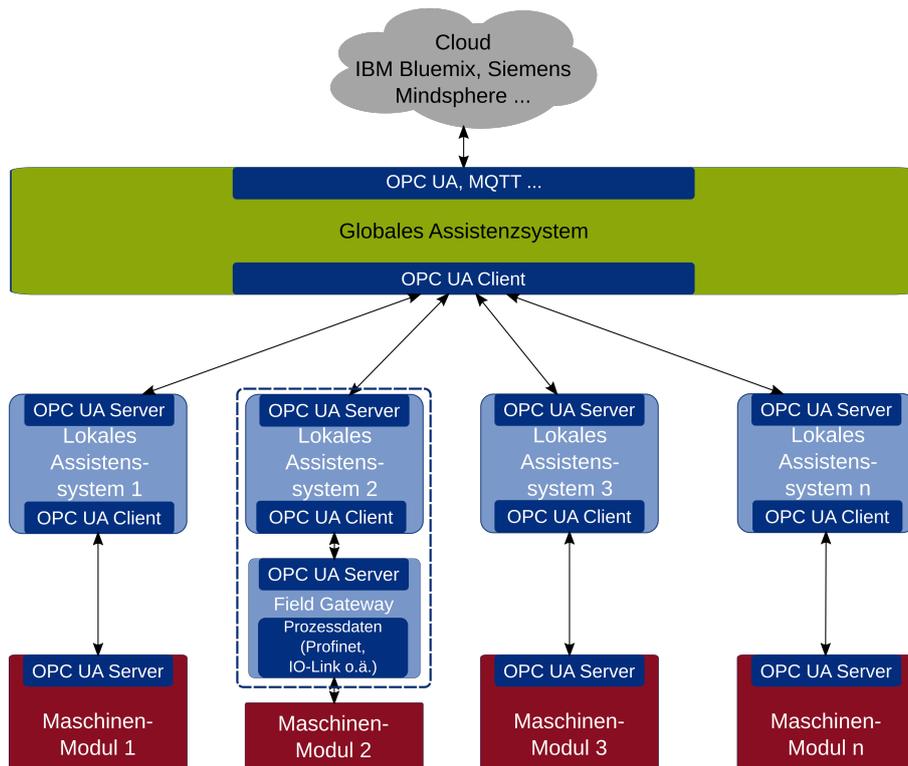


Abbildung 8: Vernetzung der Analyseassistenten

Die bereits beschriebene Aufteilung der Diagnoseassistenten in Ebenen des Low-Level- und High-Level-Learnings lässt sich auch aus der typischen Struktur eines Maschinen- oder Anlagenparks begründen. So sind die Low-Level-Diagnoseassistenten räumlich den zu überprüfenden Anlagen bzw. Maschinen zugeordnet, während die High-Level-Diagnoseassistenten den Low-Level-Diagnoseassistenten übergeordnet sind und einen Überblick über den gesamten Maschinen- bzw. Anlagenpark haben und somit die kausalen Zusammenhänge der einzelnen Anlagen kennt. Diese Struktur und die Pfade der Interaktion zwischen den einzelnen Diagnoseassistenten ist in Abbildung 8 verdeutlicht. Zur Durchführung der einzelnen Analyseaufgaben, müssen den genannten maschinellen Lernmethoden des Low-Level- bzw. High-Level-Learnings die Anlagen- bzw. Analysedaten sinnvoll zugeführt werden. Dafür werden den lokalen Assistenzsystemen des Low-Level-Learnings die Anlagen- bzw. Maschinendaten für die Analyse zur Verfügung gestellt und dem globalen Assistenzsystem des High-Level-Learnings die Analyseergebnisse der lokalen Assistenzsysteme. Für die Durchführung der Analysen wurden im Arbeitspaket 3 Umgebungen und Schnittstellen für die Analy-

seassistenten untersucht. Dabei hat das IMMS den Fokus auf Industrie-4.0-konforme Techniken zur Zukunftssicherheit des Assistenzsystems gelegt.

4.4.1 AP 3.1: Aufbau einer Ablaufumgebung für Assistenzsysteme im I4.0 Umfeld

Aufbauend auf den Anforderungen aus Standardisierung und Normung im Umfeld von Industrie 4.0 (AP2.4) und den Anforderungen der beteiligten Firmen im projektbegleitenden Ausschuss wird eine konkrete Ablaufumgebung aufgebaut. Dabei wird einerseits auf die Einbindung der Schnittstellen für Industrie-4.0-konforme Kommunikation geachtet und andererseits die gefundene Systematik für die Bereitstellung der Algorithmen umgesetzt. Die implementierte Ablaufumgebung wird in AP4.1 in den Demonstrator integriert. Eine Umgebung die aktuell sowohl für die Realisierung der Industrie-4.0-konformen Kommunikation als auch zur Integration der Algorithmen auf eingebetteten Systemen sowie auf leistungsstärkeren Systemen genutzt werden kann ist *python*. So gibt es Frameworks zur Integration der Kommunikationsschnittstelle OPC UA (*python-OPC UA*) und der maschinellen Lernalgorithmen (*scikit-learn*).

Ergebnisse	Aufgebaute Ablaufumgebung zur Integration der Algorithmen und zur Vernetzung der Analyseassistenten. Weiterhin die integrierten individuellen Verwaltungsschalen je Analysemethode zum Datenaustausch und zur näheren Beschreibung der Analysemethoden (Assets). Sicherstellung des Einsatzes der Analyseassistenten auf Embedded Plattformen, wie Raspberry PI oder HARTING MICA
Personaleinsatz	FE 1 (INA): HPA A: 0,00 PM HPA B: 0,00 PM FE 2 (IMMS): HPA A: 2,35 PM HPA B: 1,65 PM
Erfüllungsgrad	100 %

4.4.2 AP 3.2: Aufbau einer Serviceschnittstelle zur Vernetzung von Assistenzsystemen

Um die Daten verschiedener Assistenzsysteme miteinander zu verknüpfen, ist es notwendig, die Daten möglichst parallel von den verschiedenen Systemen zu erhalten. Dies ist umso schwieriger, wenn die beteiligten Teilsysteme unabhängige Funktionen aufweisen. Deshalb kommt der (Service-)Schnittstelle für den Datenaustausch eine große Bedeutung zu. In diesem Arbeitspaket soll die beispielhafte Umsetzung den Nachweis der Tragfähigkeit des Konzepts erbringen.

Für den Datenaustausch zwischen den und für die Vernetzung der Diagnoseassistenten werden Methoden und Verfahren sowie Techniken von Industrie 4.0 eingesetzt. Zum einen werden die Daten und Informationen für die einzelnen Diagnoseassistenten in einer Verwaltungsschale nach der Struktur einer Verwaltungsschale der Plattform Industrie 4.0 verwendet, zum anderen kommunizieren die Diagnoseassistenten mittels OPC UA und somit Industrie-4.0-konform.

Durch die Verwendung dieser Industrie-4.0-Techniken lassen sich nicht nur die zu analysierenden Daten zwischen den Assistenzsystem austauschen, sondern ebenfalls Metadaten wie zum Beispiel Informationen zu den eingesetzten Algorithmen, Datentypen oder physikalische Einheiten der übertragenen Daten. Mit der Verwendung der Verwaltungsschale werden die Diagnosassistenten außerdem zu Industrie-4.0-Komponenten [38]. Die Struktur der Verwaltungsschale ist den Ergebnissen des Open-Source-Projekts „openAAS“ und den Anforderungen der Plattform Industrie 4.0 nachempfunden. Somit ist die Kompatibilität zu Systemen, die nach diesem Schema eine Verwaltungsschale erhalten haben, sichergestellt [12, 37].

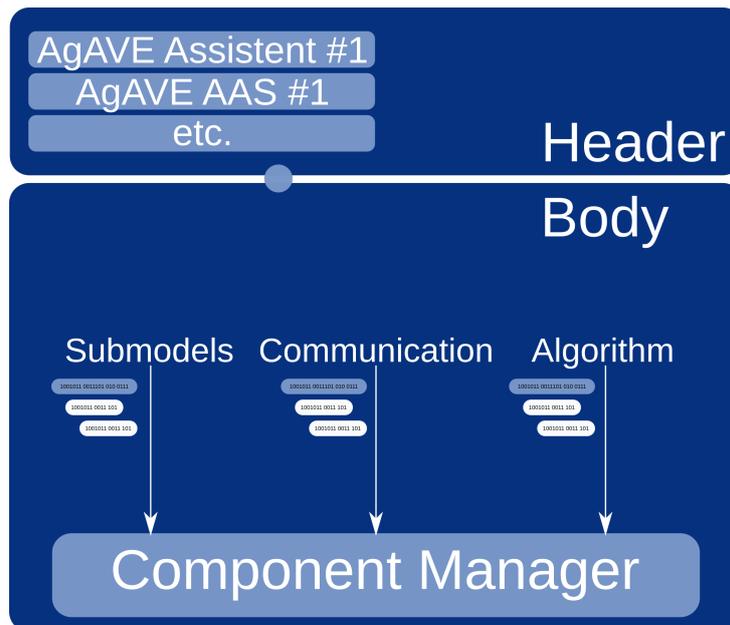


Abbildung 9: Struktur der Verwaltungsschale

Die grundlegende Struktur einer Industrie-4.0-Verwaltungsschale ist in Abbildung 9 verdeutlicht. Sie setzt sich aus einem Header und einem Body zusammen. Im Header werden alle organisierenden Merkmale zum jeweiligen Asset und der Verwaltungsschale selbst gehalten. Somit verfügt die Verwaltungsschale zu jederzeit über weiterführende Informationen zum verbundenen Asset. Als Beispiel können neben Informationen zur Identifikation der Verwaltungsschale selbst auch Informationen zum Asset, wie bspw. eine ID oder Beschreibung des Assets verfügbar sein. Die Verwaltungsschale für Diagnoseassistenten greift diese Struktur auf und ist an die Anforderungen der *AgAVE* Analyseassistenten angepasst worden. Wie vorgesehen sind alle organisierenden Merkmale im Header hinterlegt. Dieser besitzt die strukturierenden Elemente: „AAS-ID“, „Asset (Asset-ID und Asset-Description)“, „Manufacturer-ID“ und „Serialnumber“. Die „AAS-ID“ ist dabei die Identifikationsmöglichkeit der Verwaltungsschale selbst. Sie wird durch das Objekt „Asset“ einem Gegenstand von Wert, dem Asset, zugeordnet. Somit ist die Verwaltungsschale mit dem Asset verbunden. Die „Asset-ID“, die „Asset-Description“, als auch die „Manufacturer-ID“ und die „Serialnumber“ sind Elemente, die das Asset genauer beschreiben.

Die Informationen, die für die Analyse in den einzelnen Diagnoseassistenten benötigt sind, werden im Body hinterlegt. Er ist durch die Elemente „Algorithm“, „Inputs“ und „Outputs“ strukturiert. Unter „Algorithm“ finden sich Elemente, die den eingesetzten Algorithmus für die Datenanalyse näher beschreiben. Das Objekt „Inputs“ strukturiert

dabei alle Eingangsvariablen. Hier werden die zu analysierenden Parameter, wie Anlagen- bzw. Maschiendaten, platziert. Das Objekt „Outputs“ strukturiert die Analyseergebnisse der jeweiligen Lernschicht, die für weitere Verarbeitungsschritte auf einer anderen Ebene bereitgestellt werden können. Für den Datenaustausch als auch die Umsetzung der Verwaltungsschale wird wie bereits erwähnt OPC UA eingesetzt. Mit OPC UA ist es möglich, neben der Übertragung von Daten auch eine Semantik zu übertragen, durch die es vereinfacht wird, die ausgetauschten Daten zu interpretieren. So ist es durch die sogenannten Properties möglich beispielsweise eine Variable genauer zu beschreiben. Dabei ist der Datentyp der Variable beim Datenaustausch ebenso übertragen worden wie eine mögliche Angabe zur Maßeinheit.

Ergebnisse	Definierte (Service)-Schnittstelle inkl. beispielhafter Umsetzung. So werden die Analyseassistenten durch eine Individuelle Verwaltungsschale und OPC UA vernetzt. Weiterhin wurden individuell anpassbare und modulare Analyseassistenten der Low-Level- und High-Level-Ebene geschaffen.
Personaleinsatz	FE 1 (INA): HPA A: 0,00 PM HPA B: 0,00 PM FE 2 (IMMS): HPA A: 2,04 PM HPA B: 0,84 PM
Erfüllungsgrad	100 %

4.4.3 AP 3.3: Untersuchungen zu Prozessverlagerung in Cloudarchitekturen

Die Möglichkeit der Abarbeitung von Services in einer Cloudarchitektur nicht direkt am Prozess ermöglicht die Einsparung von Ressourcen und die Zentralisierung von Diensten. Jedoch dürfen die Latenzen und die daraus resultierenden Effekte für die Services nicht außer Acht gelassen werden. In diesem AP soll untersucht werden, welchen Einfluss Latenzen auf die Abarbeitung der Algorithmen und die Ergebnisse der hybriden Automaten haben. Ein weiterer Schwerpunkt ist die Untersuchung der Auswirkungen auf die Kausalitätshypothesen, da hier die Auswertungen mehrerer Systeme zusammen fließen.

In Abstimmung mit dem projektbegleitenden Ausschuss wurde dieses Arbeitspaket nicht bearbeitet, da der PA den Fokus auf einem funktionalen Demonstrator und somit

dem Nachweis der Funktionalität des Verfahrens sah. Die Aufwände für den Aufbau der Ablaufumgebung und der Serviceschnittstelle(n) sowie des einsatzfähigen Demonstrators waren, aufgrund ihrer Komplexität, umfangreicher als vorher angenommen und wurden daher umgeplant.

Ergebnisse	Keine
Personaleinsatz	FE 1 (INA): HPA A: 0,00 PM HPA B: 0,00 PM FE 2 (IMMS): HPA A: 0,00 PM HPA B: 0,00 PM
Erfüllungsgrad	0 %

4.4.4 AP 3.4: Ableitung eines Vorschlages für die Erfassung von Maintanancedaten

Die Ergebnisse aus den Untersuchungen und Tests in den verschiedenen Arbeitspaketen werden in diesem AP zusammengefasst. Dabei werden die gewonnenen Erkenntnisse in einem Konzept zur Erfassung von Maintenance-Daten und der Information der Anwender über kausale Zusammenhänge gebündelt, so dass daraus Schlüsse für das eigene Handeln der KMU gezogen werden können.

In Abstimmung mit dem projektbegleitenden Ausschuss wurde dieses Arbeitspaket nicht bearbeitet, da der PA den Fokus auf einem funktionalen Demonstrator und somit dem Nachweis der Funktionalität des Verfahrens sah. Die Aufwände für den Aufbau der Ablaufumgebung und der Serviceschnittstelle(n) sowie des einsatzfähigen Demonstrators waren, aufgrund ihrer Komplexität, umfangreicher als vorher angenommen und wurden daher umgeplant.

Ergebnisse	Keine
Personaleinsatz	FE 1 (INA): HPA A: 0,00 PM HPA B: 0,00 PM FE 2 (IMMS): HPA A: 0,00 PM HPA B: 0,00 PM
Erfüllungsgrad	0 %

4.5 Arbeitspaket 4: Projektmanagement und Ergebnistransfer

4.5.1 AP 4.1: Demonstrator

In der SmartFactoryOWL, die unter anderem vom Fraunhofer IOSB-INA betrieben wird, wurde ein Demonstrator der Projektresultate platziert. Dieser Demonstrator ist an das Versatile Production System (siehe Abbildung 10) angeschlossen. Das Versatile Production System dient als Beispielprozess, an dem die Algorithmik der Anlage erprobt wurde. Es besteht aus den vier verschiedenen Modulen *Delivery*, *Storage*, *Dosing* und *Production*. In dem System fallen mehr als 200 verschiedene, sowohl kontinuierliche als auch diskrete Signale an.

Während des Betriebs der Produktionsanlage überwacht das Assistenzsystem das Anlagenverhalten. Die Daten der einzelnen Module werden gesammelt und entsprechend an die jeweiligen lokalen Diagnoseassistenten übergeben. Die lokalen Diagnoseassistenten vergleichen die aktuellen Werte mit den jeweils gelernten Modellen des fehlerfreien Anlagenverhaltens und generieren auf dieser Basis ihre jeweilige Prädiktion. Diese Prädiktion wird an den globalen Assistenten übergeben, der mittels der hinterlegten Entscheidungsregeln entscheidet, ob das aktuelle Anlagenverhalten zulässig ist, oder ein Fehler vorliegt. Bei Vorliegen eines Fehlers wird dem Anlagenoperator die entsprechende Entscheidungsregel präsentiert, die ihn nachvollziehen lässt, welches Modul Auslöser für den Fehler war.

Liegt nun, beispielsweise bei dem Modul *Delivery*, ein Fehler in Form eines verstopften Rohres vor, liefern die lokalen Assistenten, die an diesem Modul eingesetzt sind, Informationen über Abweichungen vom Fehlverhalten. Eine entsprechende Entscheidungsregel liefert auf Basis dieser Informationen das Resultat, dass ein Fehler vorliegt. Mithilfe der Entscheidungsregel kann der Fehler auf das Modul *Delivery* zurückgeführt werden.

Ergebnisse	Demonstrator in der Forschungsstelle 1
Personaleinsatz	FE 1 (INA): HPA A: 6,20 PM HPA B: 0,00 PM FE 2 (IMMS): HPA A: 1,26 PM HPA B: 0,87 PM
Erfüllungsgrad	85 %



Abbildung 10: Abbildung des Versatile Production System in der SmartFactoryOWL

4.5.2 AP 4.2: Dokumentation der Resultate

Die Dokumentation der im Projekt entwickelten Resultate wurden zum Einen, im Rahmen dieses Abschlussberichtes veröffentlicht. Außerdem wurden die in Abschnitt 7 vorgestellten Maßnahmen zur Dokumentation und Veröffentlichung durchgeführt.

Ergebnisse	Projektdokumentation und Publikationen
Personaleinsatz	FE 1 (INA): HPA A: 1,25 PM HPA B: 0,00 PM FE 2 (IMMS): HPA A: 0,80 PM HPA B: 0,27 PM
Erfüllungsgrad	90 %

4.5.3 AP 4.3: Projektmanagement und Transfer zu Projektpartnern

Die im Abschnitt 7 durchgeführten Maßnahmen wurden im Rahmen dieses Arbeitspaketes durchgeführt.

Ergebnisse	Projektfortschritt und informierte Projektpartner
Personaleinsatz	FE 1 (INA): HPA A: 0,00 PM (Durchführung parallel zu anderen AP) HPA B: 0,00 PM (Durchführung parallel zu anderen AP) FE 2 (IMMS): HPA A: 0,00 PM (Durchführung parallel zu anderen AP) HPA B: 0,00 PM (Durchführung parallel zu anderen AP)
Erfüllungsgrad	95 %

5 Verwendung der Zuwendung

5.1 Fraunhofer IOSB-INA

- wissenschaftlich-technisches Personal (Einzelansatz A.1 des Finanzierungsplans)
 - 25,60 PM HPA-A
- Geräte (Einzelansatz B des Finanzierungsplans)
 - Nein
- Leistungen Dritter (Einzelansatz C des Einzelfinanzierungsplans)
 - Nein

5.2 IMMS GmbH

- wissenschaftlich-technisches Personal (Einzelansatz A.1 des Finanzierungsplans)
 - 13,27 PM HPA-A
 - 12,97 PM HPA-B
- Geräte (Einzelansatz B des Finanzierungsplans)
 - Nein
- Leistungen Dritter (Einzelansatz C des Einzelfinanzierungsplans)
 - Nein

6 Notwendigkeit und Angemessenheit der geleisteten Arbeit

Wie im Antrag beschrieben, adressierte das Projekt *AgAVE* die vorwettbewerbliche Erforschung und Entwicklung eines Assistenzsystems, das in verteilten Anlagen eingesetzt werden kann. Damit das entwickelte Assistenzsystem dabei insbesondere für KMU anwendbar ist, wurde Schwerpunkte bei der Entwicklung auf die Übertragbarkeit auf beliebige modulare Produktionsanlagen sowie herstellerunabhängige Kommunikationsstandards gelegt. Insbesondere KMU verfügen im Allgemeinen nicht über die finanziellen Mittel, um eine solche Forschungs- und Entwicklungsleistung durchzuführen.

Die Arbeiten wurden wie im Antrag beschrieben durchgeführt und transferiert. Sie waren daher für die Durchführung des Projektes notwendig und angemessen. Die Notwendigkeit und Angemessenheit der Arbeiten wurde auch in den regelmäßigen Sitzungen des projektbegleitenden Ausschusses sichergestellt. Das Projekt wurde erwartungsgemäß im Februar 2019 erfolgreich abgeschlossen.

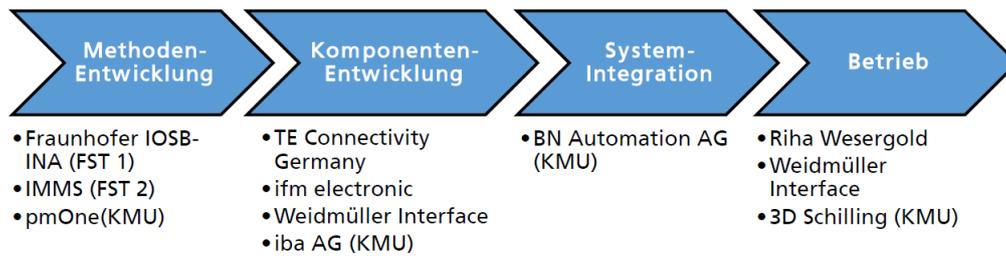


Abbildung 11: Einordnung des projektbegleitenden Ausschusses entlang der Wertschöpfungskette

7 Transfer der Ergebnisse

7.1 Ergebnistransfer in die Wirtschaft

Das entwickelte Assistenzsystem führt zu einer erhöhten Anlagenverfügbarkeit durch die Reduzierung von Ausfällen und die Verringerung von Stillstandszeiten. Die Kosten für Anlagenausfälle und -stillstände stellen insbesondere für KMU ein großes wirtschaftliches Risiko dar. Daher ist das entwickelte Assistenzsystem insbesondere für KMU interessant: Es erkennt anomales Anlagenverhalten und teilt dem Anlagenbetreiber frühzeitig mögliche Fehlerursachen mit.

Die Unternehmen des projektbegleitenden Ausschusses (siehe Abbildung 11) konnten durch ihre beratende und steuernde Tätigkeiten bereits zu Laufzeiten des Projektes die Anwendbarkeit des zu entwickelnden Konzeptes sicherstellen. Die Einrichtungen Fraunhofer IOSB-INA sowie das IMMS wirkten im Projekt als durchführende Forschungsstellen und wurden bei der *Methodenentwicklung* von pmOne unterstützt. Beratend aus dem Bereich der *Komponentenentwicklung* wirkten die Firmen TE Connectivity Germany, ifm electronic, Weidmüller Interface sowie die iba AG. Im Bereich der *Systemintegration* wirkte die BN Automation AG mit. Für den Bereich *Betrieb* berieten die Firmen Riha Wesergold, Weidmüller Interface sowie 3D Schilling.

In den folgenden Abschnitten werden zunächst die Möglichkeiten zur voraussichtlichen industriellen Umsetzung der Ergebnisse diskutiert, anschließend wird das durchgeführte Transferkonzept vorgestellt.

7.2 Aussagen zur voraussichtlichen industriellen Umsetzung der FuE-Ergebnisse nach Projektende

Die erzielten Ergebnisse entlang *AgAVE* zielen insbesondere auf mögliche Produkte hin, die einerseits im Rahmen einer Neuentwicklung oder Neuanschaffung einer Produktionsanlage vom Hersteller oder Systemintegrator integriert werden können. Realisierbar wäre aber auch ein Retrofit des vorhandenen Anlagenparks, in dem das Assistenzsystem durch Vernetzung mit den Produktionsanlagen in die Lage versetzt wird deren Produktionsdaten zu empfangen und zu analysieren. Die vorhandenen Anlagen können durch das Assistenzsystem im Rahmen der Vernetzung auch Zugang zu Industrie-4.0-Netzwerken erhalten. Dabei kann das Assistenzsystem als sogenanntes Fieldgateway fungieren, indem es bspw. Profinetdaten nach OPC UA übersetzt. Besonders in diesem Bereich liegt ein erheblicher wirtschaftlicher Nutzen auch für kleine und mittlere Unternehmen, da sie ihren vorhandenen Anlagenpark so auch entlang von Industrie-4.0-Netzwerken nutzen können. Durch die standardisierte Industrie-4.0-konforme Kommunikationsschnittstelle OPC UA ist nicht nur die einfache Einbindung in bereits vorhandene Systeme möglich, auch die Weitergabe der Daten an nachfolgende Systeme wie z.B. MDE/BDE/MES ist problemlos realisierbar. Der Nutzen der Projektergebnisse für die Unternehmen besteht einerseits in der Analyse Ihrer bestehenden Produktionsanlagen hinsichtlich der Abläufe, aber auch hinsichtlich der Fehlersuche und -behebung und somit schließlich der Vermeidung von Stillstandszeiten. Damit erhalten die Unternehmen Verfahrensgrundlagen zur Entwicklung neuer Produkte oder Services, Fertigungsanlagen während der Produktion zu überwachen, Veränderungen zu erkennen und angemessen entsprechend der Analyseergebnisse zu reagieren. Dies ermöglicht den Unternehmen schon vor dem Ausfall der Maschinen Anzeichen eines möglichen Ausfalls zu erkennen und so eine flexible vorbeugende Wartung durchführen zu können. Damit trägt die erarbeitete Lösung sowohl zur Erhöhung der Produktivität als auch zur Maschinendiagnose bei.

Somit sind die erzielten Ergebnisse die Grundlage für eine Produktentwicklung, wobei sie an die entsprechenden Anforderungen anzupassen sind, da aufgrund des vorwettbewerblichen Charakters des Forschungsprojektes das Analyseverfahren nachzuweisen war. So wurde entlang von *AgAVE* deutlich, dass für das Aufsetzen und Integrieren der zu untersuchenden Assistenzsysteme erhebliche Optimierungen in Bezug auf die zu überwachenden Produktionsprozesse durchgeführt werden müssen. Trotzdem wurde im Projekt darauf Wert gelegt, dass der Einstieg in die Integration

solcher Assistenzsysteme z.B. in Maschinensteuerungen so leicht wie möglich gestaltet werden kann. So wurde es durch den Einsatz von freien Softwarelösungen, wie den Open-Source-Modulen bzgl. der Analysen und der Vernetzung möglich die entsprechenden Softwaremodule ohne kostenintensive Lizenzierungen in entsprechende Lösungen zu integrieren oder entsprechende Services anbieten zu können. Weiterhin wurde entlang des Projektes darauf geachtet, dass die Analysemethoden auf leistungsschwächeren eingebetteten Systemen lauffähig sind. So konnten die Einstiegshürden bzgl. der Leistungsfähigkeit der Analysehardware gering gehalten werden. Eine Integration in Maschinensteuerungen oder in MDE/BDE/MES-Systeme ist somit nach den entsprechenden Anpassungen und Optimierungen durchführbar. Daher wird ein Zeithorizont von sechs bis zwölf Monaten für eine Integration einzelner Analysemodule in bestehende Produkte seitens der Forschungseinrichtungen als realistisch eingestuft. Wohingegen eine komplette Produktentwicklung unter den geschilderten Voraussetzungen der Optimierung und Anpassung an die entsprechenden Produktionsprozesse und -anlagen vermutlich nicht unter einer Projektlaufzeit von zwei Jahren zu realisieren sein wird.

7.3 Einschätzung zur Realisierbarkeit des vorgeschlagenen und aktualisierten Transferkonzepts

Das im Projektantrag geplante Transferkonzept wurde folgendermaßen durchgeführt:

Maßnahme A: Wertschöpfungskette und Knowhow-Transfer

Nr.	Ziel	Rahmen	Zeitraum	FE
A1	Sicherstellung der Abdeckung der Wertschöpfungskette	Sitzungen bei den Partnern mit Vorstellung der aktuellen Ergebnisse	<ul style="list-style-type: none"> • Kickoff mit Teilnahme des PA am 16.03.2017 • Treffen des PA am 20.09.2017 • Treffen des PA am 14.03.2018 • Treffen des PA am 20.09.2018 • Abschlusstreffen des PA am 12.02.2019 	1 & 2

A2	Klärung von Problemen bzw. schnelle Absicherung von möglichen Vorgehensweisen	Telefonkonferenzen	<ul style="list-style-type: none"> • regelmäßig im Abstand von zwei Wochen und sofort bei Bedarf • Projekttreffen der FE 1 & 2 vom 31.05.2017 bis 01.06.2017 • Projekttreffen der FE 1 & 2 vom 30.01.2018 bis 31.01.2018 • Projekttreffen der FE 1 & 2 vom 17.05.2018 bis 18.05.2018 • Projekttreffen der FE 1 & 2 vom 19.09.2018 • Projekttreffen der FE 1 & 2 vom 05.12.2018 bis 06.12.2018 	1 & 2
----	---	--------------------	---	-------

A3	Durchführung von Feldtests/Praxisversuchen	<ul style="list-style-type: none"> • Überprüfung der Anwendbarkeit der erzielten Forschungsergebnisse bei 3DSchilling • Überprüfung der Anwendbarkeit der erzielten Forschungsergebnisse anhand von Daten von Weidmüller 	<ul style="list-style-type: none"> • nach Projektlaufzeit geplant • Januar 2019 	1 & 2
----	--	--	---	-------

Anmerkung zu A3.1: Es wurden mit 3D-Schilling mehrere Gespräche zum testweisen Einsatz des AgAVE-Systems geführt. Aufgrund der laufenden Produktion wurden anvisierte Termine abgesagt. Die Projektpartner gehen aber davon aus, den Test noch im Jahr 2019 bei 3D-Schilling durchführen zu können.

Maßnahme B: Vorträge und Veröffentlichungen auf Konferenzen

Nr.	Konferenz	Zielgruppe	Zeitraum	FE
	<i>Automation</i>			
B1	WFCS 2019: 15th IEEE International Workshop on Factory Communication Systems	Experten für Automation	Mai 2019	1 & 2
B2	Embedded World 2019	Experten für eingebettete Systeme	Februar 2019	1 & 2
	<i>Informatik</i>			

B3	ICAART 2019: 11th International Conference on Agents and Artificial Intelligence	Experten für künstliche Intelligenz	Februar 2019	1 & 2
B4	International Conference on Industrial Informatics	Experten für Informatik in der industriellen Anwendung	zunächst zurückgestellt	

Maßnahme C: Veröffentlichungen in Magazinen, Journals und anderen Zeitschriften

Nr.	Veröffentlichung	Zielgruppe	Zeitraum	FE
C1	atp Edition	Experten für Automation	Einreichung angenommen, Veröffentlichung in Q3 2019	1 & 2
C2	Computer & Automation	Experten für Automation	Einreichung nicht mehr geplant	1 & 2

Anmerkung zu C2: Für die ATP-Veröffentlichung wurde das Verlagsrecht für 24 Monate an den Verlag abgetreten. Die Projektpartner gehen nicht mehr davon aus, dass danach seitens der Computer & Automation noch großes Interesse an den Projektergebnissen besteht. Deshalb halten die Projektpartner diese Veröffentlichung für nicht mehr realisierbar.

Maßnahme D: Vorstellung der Ergebnisse in Gremien und Standardisierungsorganisationen

Nr.	Gremium	Zielgruppe	Maßnahme	FE
-----	---------	------------	----------	----

D1	ZVEI	Firmen aus der Automation	<ul style="list-style-type: none"> • Vorstellung Projekt im ZVEI Mitglieder-gremium Automation 14.09.2017 • Vorstellung des Projekts im ZVEI Mitglieder-gremium Automation 04.10.2018 	1 & 2 1
D2	Plattform Industrie 4.0	Firmen aus der Automation	Platzierung von Demonstratoren in Lemgo und Ilmenau auf der Industrie-4.0-Landkarte eingereicht, Eintragung in 2019 erwartet	1 & 2

D3	Kompetenzzentrum Mittelstand 4.0 NRW (IOSB ist Projektpartner)	Mittelständische Unternehmen	<ul style="list-style-type: none"> • Demonstrator am Versatile Production System der SmartFactoryOWL • Vorstellung Projekt im Rahmen der Regionalkonferenz der Mittelstand-4.0-Kompetenzzentren in Aachen 18.09. und 19.09.2017 • Vorstellung des Projektes 05.09.2018 • weiterhin regelmäßige Vorstellung auch nach Projektende geplant 	<p style="text-align: right;">1</p> <p style="text-align: right;">1</p> <p style="text-align: right;">1</p> <p style="text-align: right;">1</p>
----	--	------------------------------	--	---

D4	Mittelstand 4.0 Kompetenzzentrum Ilmenau (IMMS ist Projektpartner)	Mittelständische Un- ternehmen	<ul style="list-style-type: none"> <li data-bbox="997 302 1324 616">• Vorstellung Pro- jekt im Rahmen des Sensorik- Stammtisches „Sensoren und Industrie 4.0“ am 17.08.2017 <li data-bbox="997 660 1324 929">• Vorstellung Projekt im Rahmen des Workshops „Vom Sensor zur Industrie 4.0 - Komponente“ am 24.08.2017 <li data-bbox="997 974 1324 1288">• Vorstellung Projekt im Rahmen der Regionalkonferenz der Mittelstand-4.0- Kompetenzzentren in Aachen 18.09. und 19.09.2017 <li data-bbox="997 1332 1324 1646">• Vorstellung Projekt im Rahmen des Workshops „Vom Sensor zur Industrie- 4.0-Komponente / OPC-UA“ am 30.08.2018 	<p style="text-align: center;">2</p> <p style="text-align: center;">2</p> <p style="text-align: center;">2</p> <p style="text-align: center;">2</p>
----	---	-----------------------------------	---	---

E3	Integration der Ergebnisse in die SmartFactoryOWL	Anknüpfung an die Anwendungen anderer Firmen (insbesondere KMU) die von den Ergebnissen profitieren	während des Projektes durchgeführt, stetige Demonstration der Ergebnisse	1
----	---	---	--	---

Anmerkung zu E1: Die Forschungspartner sind im ständigen Kontakt mit Industrievertretern, sowohl von klein- und mittelständigen Unternehmen als auch von größeren Unternehmen. Die Ergebnisse des Projektes AgAVE werden kontinuierlich vorgestellt und eine Zusammenarbeit mit interessierten Partnern angestrebt. Die Forschungspartner gehen davon aus, die Ergebnisse bis Ende 2020 bei mindestens einem interessierten Partner zu integrieren.

Anmerkung zu E2: Die Forschungspartner sind im ständigen Kontakt mit Industrievertretern, sowohl von klein- und mittelständigen Unternehmen als auch von größeren Unternehmen. Die Ergebnisse des Projektes AgAVE werden kontinuierlich vorgestellt und eine Zusammenarbeit mit interessierten Partnern angestrebt. Die Forschungspartner gehen davon aus, die Ergebnisse bis Ende 2020 bei mindestens zwei interessierten Partnern zu testen.

Maßnahme F: Gewinnung von Firmen für Anschlussprojekte

Nr.	Ziel	Rahmen	Zeitraum	FE
F1	Ein(e) im Projekt befristet eingestellte(r) wiss. Mitarbeiter(in) wechselt in eines der Unternehmen des PA	Übertragung des Projekt-Know-hows in ein Unternehmen des PA	noch nicht absehbar	
F2	Nutzung des Demonstrators in Lehre und Ausbildung	praxisorientierte Lehre für Industrie 4.0 in Lemgo und Ilmenau	während des Projektes aufgebaut, Nutzung seit Projektende	1 & 2

F3	Übernahme der Projektergebnisse in die Lehrveranstaltung der Studiengänge Technische Informatik und Data Science	forschungsorientierte Lehre in Lemgo	bereits während des Projektes erfolgt, Weiterführung kontinuierlich	1
F4	Gründung eines Start-Up	direkte Vermarktung der Projektergebnisse als Produkt	noch nicht absehbar	

Anmerkung zu F1: Zur Zeit findet sich an keiner der Forschungseinrichtung ein wissenschaftlicher Mitarbeiter, der einen Wechsel in ein Unternehmen des projektbegleitenden Ausschuss anstrebt.

Anmerkung zu F4: Die Gründung eines Start-Ups ist ein aufwendiger Prozess, der neben den vorwettbewerblichen Ergebnissen des AgAVE-Projektes weitere organisatorische Gegebenheiten erfordert. Zur Zeit plant keiner der Mitarbeiter, die an dem Projekt mitwirkten, den Karriereschritt hin zur Selbstständigkeit.

Literatur

- [1] A., Horch (Hrsg.): *Condition Monitoring of Control Loops*. Techniska hoegsk., 2000
- [2] AHMED, W.; HASAN, O.: *Towards Formal Fault Tree Analysis using Theorem Proving*. 2015
- [3] BAUER, M.: *Data-driven Methods for Process Analysis*, University College London, Diss., 2005
- [4] BCC RESEARCH: *Global Market for Smart Machines Expected to Reach \$15.3 Billion in 2019*. 2014
- [5] BOSCH REXROTH: *Open Core Engineering*. 2015
- [6] BUNDESMINISTERIUM FÜR BILDUNG UND FORSCHUNG (BMBF): *Forschung und Innovation für die Menschen. Die Hightech-Strategie 2025*. 2018
- [7] D., Eaton ; K., Murphy: Belief net structure learning from uncertain interventions. In: *Journal of Machine Learning Research* 1 (2007)
- [8] DEMETGUL, M.: Fault diagnosis on production systems with support vector machine and decision trees algorithms. In: *The International Journal of Advanced Manufacturing Technology* 67 (2012), Nr. 9, 2183–2194. <http://dx.doi.org/10.1007/s00170-012-4639-5>. – DOI 10.1007/s00170-012-4639-5. – ISSN 1433-3015
- [9] DICHT!: *Maschinenstillstand muss nicht sein*. 2016
- [10] DLR: *FEE - Frühzeitige Erkennung und Entscheidungsunterstützung für kritische Situationen im Produktionsumfeld: Entwicklung von Assistenzfunktionen zur Unterstützung von Anlagenbedienern in kritischen Situation*. 2014
- [11] EICKMEYER, Jens ; LI, Peng ; GIVEHCHI, Omid ; PETHIG, Florian ; NIGGEMANN, Oliver: Data Driven Modeling for System-Level Condition Monitoring on Wind Power Plants. In: *DX@ Safeprocess*, 2015, S. 43–50
- [12] ENERGIE (BMWi) ÖFFENTLICHKEITSARBEIT, Bundesministerium für Wirtschaft u.: *Plattform Industrie 4.0. Die Struktur der Verwaltungsschale*. 2016

- [13] EUROPEAN FACTORIES OF THE FUTURE RESEARCH ASSOCIATION: *Multi-Annual Roadmap for the Contractual PPP under HORIZONS 2020*. 2013
- [14] FERDOUS, R.; KHAN, F.; SADIQ, R.; AMYOTTE, P.; VEITCH, B.: *Handling data uncertainties in event tree analysis*. 2009
- [15] FRAUNHOFER IOSB: *Projekt AGATA: Analyse großer Datenmengen in Verarbeitungsprozessen*. 2012
- [16] FREY, C.W.: Diagnosis and monitoring of complex industrial processes based on self-organizing maps and watershed transformations. In: *Computational Intelligence for Measurement Systems and Applications, 2008. CIMSA 2008. 2008 IEEE International Conference on*, 2008, S. 87 –92
- [17] GRANGER, C. W. J.: Investigating Causal Relations by Econometric Models and Cross-spectral Methods. In: *Econometrica* 37 (1969), Nr. 3, 424-438. <http://www.jstor.org/stable/1912791>. – ISSN 00129682, 14680262
- [18] HARMELEN, F. VAN (HRSG.); LIFSCHITZ, V. (HRSG.): *Handbook of Knowledge Representation (Foundations of Artificial Intelligence)*. 2008
- [19] HARTING: *Direkte Datenverarbeitung an der Maschine mit dem Computing System MICA*. 2015
- [20] IPRODUCT: *iPRODUCT - Intelligente Prozessprognose basierend auf Big-Data-Analytics-Verfahren*. 2014
- [21] JABER, ALAA ABDULHADY AND BICKER, ROBERT: Industrial Robot Backlash Fault Diagnosis Based on Discrete Wavelet Transform and Artificial Neural Network. In: *American Journal of Mechanical Engineering* 4 (2016), Nr. 1, 21–31. <http://dx.doi.org/10.12691/ajme-4-1-4>. – DOI 10.12691/ajme-4-1-4. – ISSN 2328-4110
- [22] JOHN SOLDATOS: *Your Quick Guide to 5 Maintenance-as-a-Service (MaaS) Business Models of Predictive Maintenance*. 2018
- [23] KÜHNERT, Christian: *Data-driven Methods for Fault Localization in Process Technology*, Karlsruher Institut für Technologie (KIT), Diss., 2013

- [24] MAIER, Alexander: Online Passive Learning of Timed Automata for Cyber-Physical Production Systems. In: *The 12th IEEE International Conference on Industrial Informatics (INDIN 2014)*, Porto Alegre, Brazil, Jul 2014
- [25] MAIER, A.; NIGGEMANN, O.; VODEN CAREVIC, A.; JUST, R.; JAEGER, M.: *Anomaly Detection in Production Plants using Timed Automata*. In: *8th International Conference on Informatics in Control, Automation and Robotics*. 2011
- [26] MITTELSTAND 4.0-AGENTUR PROZESSE: *Digitale Wartung und Instandhaltung – Grundlagen und Anwendungsbeispiele*. 2016
- [27] NIGGEMANN, Oliver ; STEIN, Benno ; VODENCAREVIC, Asmir ; MAIER, Alexander ; BÜNING, Hans K.: Learning behavior models for hybrid timed systems. In: *Twenty-Sixth AAAI Conference on Artificial Intelligence*, 2012
- [28] *Measuring information transfer*. 2000
- [29] PLATTFORM INDUSTRIE 4.0: *Aspekte der Forschungsroadmap in den Anwendungsszenarien*. 2016
- [30] PROF. DR. CHRISTOPH IGL: *Ein Forschungsprojekt der Industrie 4.0 — APPsist*. 2014
- [31] RWTH AACHEN: *BigPro - Big-Data-Einsatz und eventbasierte Regelung zur Gestaltung von robusten Produktionssystemen*. 2014
- [32] SCHILLING, S. J.: *Contribution to Temporal Fault Tree Analysis without Modularization and Transformation into the State Space*. 2015
- [33] SEBASTIAN KASSELMANN, PROF. DR. MISCHA SEITER: *IPRI Forschungsprojekt "4.0 Ready" gestartet*. 2015
- [34] STEVE BRADBURY, BRIAN CARPIZO, MATT GENTZEL, DREW HORAH, JOEL THIBERT: *Digitally enabled reliability: Beyond predictive maintenance*. 2018
- [35] T.A. RUNKLER: *Data Analytics: Models and Algorithms for Intelligent Data Analysis*. Springer-Verlag New York Incorporated, 2012
- [36] UGECHI, C., OGBONNAYA, E., LILLY, M., OGAJI, S., AND PROBERT, S.: *Condition-based diagnostic approach for predicting the maintenance requirements of machinery*. 2009

- [37] V. FACHVERBAND AUTOMATION, ZVEI Zentralverband E. e.: *Open Source Projekt openAAS – mit offenen Standards Industrie 4.0 umsetzen*. 2017
- [38] V. FACHVERBAND AUTOMATION, ZVEI Zentralverband E. e.: *Welche Kriterien müssen Industrie-4.0-Produkte erfüllen?* 2018
- [39] VALERIO DILDA, MALTE HIPPE, LAPO MORI, OLIVIER NOTERDAEME, CHRISTOPH SCHMITZ, JORIS VAN NIEL: *Manufacturing: Analytics unleashes productivity and profitability*. 2017
- [40] VODENCAREVIC, Asmir ; MAIER, Alexander ; NIGGEMANN, Oliver: Evaluating learning algorithms for stochastic finite automata. In: *2nd International Conference on Pattern Recognition Applications and Methods (ICPRAM 2013); Barcelona, Spain, 2013*
- [41] VOIGT, T.; FLAD, S.; STRUSS, P: *Model-based fault localization in bottling plants*. 2015
- [42] WANG, T. ; ZHANG, G. ; ZHAO, J. ; HE, Z. ; WANG, J. ; PEREZ-JIMENEZ, M. J.: Fault Diagnosis of Electric Power Systems Based on Fuzzy Reasoning Spiking Neural P Systems. In: *IEEE Transactions on Power Systems* 30 (2015), May, Nr. 3, S. 1182–1194. <http://dx.doi.org/10.1109/TPWRS.2014.2347699>. – DOI 10.1109/TPWRS.2014.2347699. – ISSN 0885–8950
- [43] WORLD INTELLECTUAL PROPERTY ORGANIZATION: *WIPO Technology Trends 2019. Artificial Intelligence*. 2019