

Andreas Schütze und Nikolai Helwig

Sensorik und Messtechnik für die Industrie 4.0

Sensors, instrumentation and measurement science for “Industrie 4.0”

DOI 10.1515/teme-2016-0047

Eingang 31. Oktober 2016; überarbeitet 14. Dezember 2016;
angenommen 14. Dezember 2016

Zusammenfassung: Dieser Beitrag betrachtet zunächst allgemein die Bedeutung von Sensorik und Messtechnik für die Industrie 4.0 und versucht, den nach wie vor schwammigen Begriff Industrie 4.0 für den Bereich Sensorik und Messtechnik als Sensor 4.0 zu konkretisieren. Anschließend wird kurz die Erwartungshaltung aus Sicht der Industrie 4.0 an moderne Sensorik und Messtechnik reflektiert, bevor der heutige Stand der Technik und die weitere Entwicklung skizziert werden. Konkrete Beispiele smarterer Sensor- und Messsysteme für die Industrie 4.0 aus dem Bereich hochintegrierter magnetischer Sensoren sowie Anwendungen wie dem Condition Monitoring komplexer Anlagen auf Basis verteilter Sensoren verdeutlichen das Potential und die noch anstehenden Herausforderungen. Gerade das Condition Monitoring als Voraussetzung für eine zustandsbasierte Wartung von Systemen, aber auch für ein autonomes Aushandeln von Fertigungsprozessen muss neben dem Zustand von Prozess und Maschine auch mögliche Sensorausfälle bzw. die aktuelle Fertigungsgenauigkeit berücksichtigen. Hierzu zählt auch eine erweiterte Betrachtung der Messunsicherheit für statistische bzw. allgemein datenbasierte Auswertemodelle, da bei diesen u. a. gezielt Korrelationen in komplexen Systemen ausgenutzt werden, um den Zustand einzelner Komponenten bewerten zu können.

Schlüsselwörter: Industrie 4.0, Smart Sensor, Condition Monitoring, datenbasierte Auswertemodelle, erweiterte Messunsicherheitsbetrachtung.

Abstract: This contribution will first address the relevance of sensors, instrumentation and measurement science for “Industrie 4.0” and will try to substantiate the somewhat fuzzy term “Industrie 4.0” for the field of sensors and

measurement science by defining a Smart Sensor (“Sensor 4.0”). Expectations for new applications of sensors and measurement systems in the field of “Industrie 4.0” are briefly reflected as well as the current state-of-the-art and future trends in sensors and instrumentation. Specific examples are given for smart sensors and measurement systems for industrial applications, especially highly integrated magnetic sensors and sensor networks for condition monitoring of complex industrial systems. Both demonstrate the potential and also future challenges. Condition monitoring as basis for condition based maintenance of industrial systems, but also for autonomous negotiation of manufacturing processes has to take potential sensor faults and the current manufacturing precision into account in addition to the condition of the process and the machine. In this context, measurement uncertainty has to be reflected further, especially for statistical and generally data-based evaluation models. For these, correlations in complex systems are specifically used to determine the state of individual components.

Keywords: “Industrie 4.0”, smart sensor, condition monitoring, data-based evaluation models, extended measurement uncertainty.

1 Einleitung

Wann immer von Industrie 4.0 und den dafür erforderlichen Voraussetzungen die Rede ist, fällt früher oder später der Begriff Sensorik – ebenso bei allen anderen Megatrends wie Smart Home, Autonomes Fahren, Smart Cities oder Active Assisted Living. Sensorik und die damit untrennbar verknüpfte Messtechnik schaffen nämlich die Voraussetzungen, das Gold des Digitalisierungszeitalters, die Daten, zu schürfen und daraus auch die unerlässlichen Informationen zu gewinnen, ohne die eine moderne Technik, Wirtschaft und Gesellschaft nicht funktionieren könnte. Schaut man sich die Entwicklung in der Sensorik und Messtechnik in den letzten Jahrzehnten an, dann wird auch schnell klar, dass zwar einerseits durch Industrie 4.0 neue Herausforderungen und Erwartungen an die Sensorik und Messtechnik gerichtet werden, diese aber auch maßgeblich dazu beigetragen haben, dass wir heute an der

Andreas Schütze: Universität des Saarlandes – Lehrstuhl für Messtechnik, Fachrichtung Systems Engineering, Campus A5.1, Raum 2.33, 66123 Saarbrücken, E-Mail: schuetze@lmt.uni-saarland.de

Nikolai Helwig: Zentrum für Mechatronik und Automatisierungstechnik gGmbH – Sensorik und Aktorik, 66121 Saarbrücken

Schwelle zur nächsten industriellen Revolution stehen. Industrie 4.0 ist hier im Sinne eines gemeinsamen Konzeptes von Politik und Wirtschaft zur Verbesserung der Wettbewerbsfähigkeit zu verstehen [1], weitgehend synonym wird vielfach auch der Begriff Industrial Internet-of-Things (IIoT) [2] verwendet. In der Sensorik ist bereits seit langem der Trend zu Smart Sensors aufgegriffen worden, mit Zielsetzungen wie verbesserter Performanz, Miniaturisierung, stärkerer Integration und multiparametrischer Erfassung, aber eben auch eigenständiger Intelligenz und sicherer Vernetzung [3, 4]. Intelligente Sensorsysteme ermöglichen z. B. eine Selbstidentifizierung und Eigendiagnose bis hin zu Selbstkonfiguration, -kalibrierung und -reparatur. Analog zur Industrie 4.0 kann man daher heute vom Sensor 4.0 sprechen, ein Begriff der insbesondere vom Vorsitzenden der AMA [5] Peter Krause geprägt und inzwischen mehrfach aufgegriffen wurde [6]. Analog zu den vier Phasen der industriellen Entwicklung wird dabei unterschieden zwischen rein mechanischen Messwertaufnehmern (z. B. eine Vidie-Dose für die Druckmessung, die bereits Mitte des 19. Jahrhunderts eingeführt wurde) als Sensor 1.0, elektrischen Sensoren (z. B. klassische Dehnungsmessstreifen ab 1938) als Sensor 2.0, den heute weit verbreiteten elektronischen Sensoren (z. B. ein elektronisch temperaturkompensierter Drucksensor, verfügbar seit den 1970ern) als Sensor 3.0 und schließlich dem Sensor 4.0, auch als

Smart Sensor bezeichnet. Letzterer verfügt gegenüber den elektronischen Sensoren über weiterreichende interne Fähigkeiten, z. B. zur Erfassung und Verknüpfung mehrerer Parameter und zur Selbstdiagnose, aber auch über erweiterte Kommunikationsfähigkeiten, um nicht nur Messwerte ausgeben, sondern das Messsystem auch parametrieren zu können. Abbildung 1 zeigt die historische Entwicklung im Überblick, aus der auch ersichtlich ist, wie eng die Entwicklung in der Sensorik mit der Entwicklung der Industrialisierung allgemein verknüpft ist. Diese dynamische Entwicklung im Bereich der Sensorik hin zu komplexen Messsystemen ist auch schön an den Beiträgen zum AMA Innovationspreis abzulesen [7].

Diese Bedeutung der Sensorik und Messtechnik schlägt sich auch in den wirtschaftlichen Daten der Branche wieder, die seit gut 12 Jahren ein hohes Umsatzwachstum von über 6% p. a. und einen stetigen Ausbau der Arbeitsplätze im gleichen Zeitraum von fast 40% vorweisen kann basierend auf den regelmäßigen Umfragen der AMA unter ihren knapp 500 Mitgliedern. Besonders vorbildlich präsentiert sich die Branche zudem in der Forschung und Entwicklung. Die überwiegend mittelständischen Unternehmen investieren durchschnittlich zehn Prozent des Umsatzes in F&E. Damit zählt die Branche zu den besonders innovativen Industriezweigen und ist attraktiver Arbeitgeber für junge Physiker und Ingenieure.

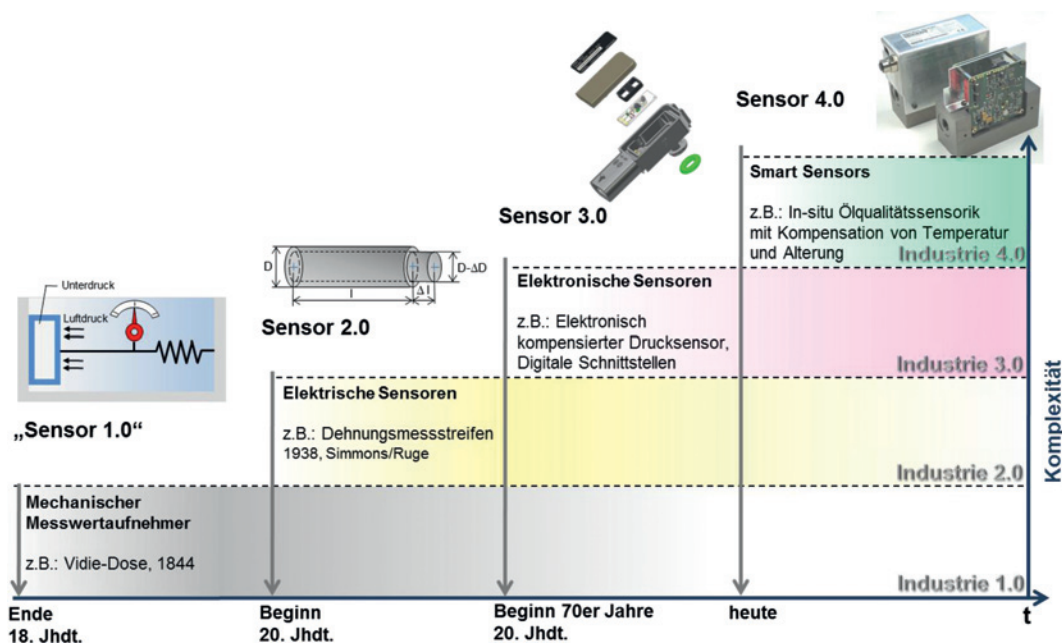


Abbildung 1: Historische Entwicklung vom „Sensor 1.0“ (der ohne elektrisches Ausgangssignal kein Sensor im Sinne der allgemein üblichen Definition ist) zum Smart Sensor, dem Sensor 4.0 (angelehnt an Peter Krause, Vorsitzender des AMA e. V.).

2 Stand der Technik und aktuelle Trends

Als ein starker Trend ist der Einsatz aktiver Messprinzipien zu verzeichnen, die in vielen Sensorelementen und -systemen eingesetzt werden, z. B. bei Hall-Sensoren (s. u.), magnetoresistiven Strom- und Feldsensoren (Kompensationsprinzip zur Unterdrückung von Temperatureinflüssen) [8], mikromechanischen Beschleunigungs- (auch hier Kompensationsbetrieb) und Drehratensensoren (Ausnutzung des Corioliseffekts durch aktive Schwingungsanregung), ebenfalls Coriolis-basierten Durchflusssensoren bis hin zu chemischen Sensoren, bei denen durch Temperaturmodulation eine verbesserte Selektivität und Sensitivität erzielt wird [9, 10]. Gleichzeitig wird aber auch ein weitergehendes Potential zur Selbstdiagnose erschlossen, was heute ebenfalls bereits vielfältig ausgenutzt wird, z. B. im Automobilbereich [11]. Dies betrifft nicht nur die Inertialsensorik, die durch interne Anregung auf korrekte Funktion überprüft werden kann, sondern z. B. auch die Lambdasonde, bei der die Zeitkonstante für das Aufheizen bis zur Betriebstemperatur ausgewertet wird, um Fehler, z. B. einen Bruch der Keramik, zu erkennen. Gerade für sicherheitskritische Anwendungen ist eine Selbstdiagnose des Sensorsystems von großer Bedeutung, da manche Anwendungen, z. B. in der Branderkennung, im Vergiftungs- oder Explosionsschutz mit Gassensoren ansonsten gar nicht erschlossen werden können. Hier erlaubt der dynamische Betrieb z. B. auch die Erkennung einer Sensorvergiftung [12].

Als konkretes Beispiel für den heutigen Stand der Sensorik soll hier ein integrierter Hall-Sensor dienen, der in großen Stückzahlen verkauft und in vielen Bereichen eingesetzt wird. Während diese Sensoren nach außen noch der ursprünglichen, einfachen Hall-Platte ähneln, einem rein analogen Sensor mit Stromspeisung und Spannungssignal zur Messung des Magnetfeldes, sind diese intern inzwischen wesentlich komplexer aufgebaut. Bereits seit langem wird das sog. spinning current Prinzip eingesetzt, bei dem die Anschlüsse für Stromspeisung und Hallspannungsmessung periodisch vertauscht werden, um verschiedenste Störeinflüsse (Geometriefehler, ungleichmäßige Dotierung der Hall-Schicht, mechanische Spannungen oder Temperaturverteilungen) auszugleichen, die ansonsten zu einem hohen Offset und damit einer nur eingeschränkten Messauflösung führen würden [13]. Allerdings verbleibt ein Restoffset, der zudem temperaturabhängig ist. Mittels einer auf dem Hallsensor-Chip integrierten Anregungsspule kann der Offset auch im eingebauten Zustand bestimmt werden. Integriert man

zudem eine kleine Heizung auf dem Chip, so lässt sich auch der Temperaturkoeffizient (TK) des Offsets bestimmen und damit kann der gemessene Offset und dessen Änderung mit der Temperatur linear korrigiert werden. Bestimmt man Offset und dessen TK bei verschiedenen Temperaturen über den gesamten Betriebstemperaturbereich des Sensors, kann der Offset schließlich so gut nachgeführt und elektronisch korrigiert werden, dass die effektiv erzielbare Auflösung um mehr als eine Größenordnung von ± 1 mT auf ± 50 μ T verbessert wird. Da der Sensor aus Kostengründen aber nur über einen AD-Wandler verfügt, können Chiptemperatur und Hallsignal nicht exakt gleichzeitig bestimmt werden. Daher wird das thermische Verhalten des Chips über mehrere Verzögerungsglieder mit unterschiedlichen Zeitkonstanten simuliert. Zudem wird über eine mehrfache Messung abgeschätzt, ob sich während dieser Selbstkalibrierung nicht das anliegende externe Feld verändert, was ansonsten zu einer fehlerhaften Bestimmung des Offsets führen würde. Nähere Details, auch zur Erweiterung auf mehrdimensionale Messung für 3D-Sensoren, finden sich in [13]. Man erkennt leicht, dass selbst ein scheinbar simpler Hallsensor den gewünschten Messwert intern über einen komplexen Prozess ermittelt, was letztlich auch zu einer sehr komplexen Bestimmung der Messunsicherheit führt, wenn man das komplette System und die unterschiedlichen Einflüsse durch ein strikt physikalisches Modell beschreiben wollte. Hier liegt daher eine Bewertung der Messunsicherheit mittels statistischer Methoden nahe.

3 Erwartungen und Trends durch Industrie 4.0

Die oben skizzierten Trends in Sensorik und Messtechnik werden seitens der Industrie 4.0 Community gerne aufgegriffen und haben maßgeblich dazu beigetragen, dass die Vision von der sich selbst optimierenden Fertigung und von kooperierenden, autonomen Robotern heute in greifbare Nähe rückt. Versucht man die weiteren Erwartungen an Sensorik und Messtechnik zu bündeln, dann stehen offenbar folgende Aspekte im Vordergrund:

- Größere Zuverlässigkeit und höhere Genauigkeit, eigentlich wie immer!
- Bessere Vernetzung und Informationsübermittlung; allerdings hat sich noch kein klarer Busstandard etabliert und auch die Abstraktion von Daten auf die eigentlich gesuchte Information ist noch unklar.

- Höhere Abtastrate für mehr (Meta-)Information; durch die Erfassung nicht nur von einzelnen Messwerten, sondern auch ihrer systematischen oder statistischen Schwankungen können zusätzliche Informationen gewonnen werden. Allerdings erfordert dies dann Signalvorverarbeitung im Sensor, um nicht die übergeordneten Ebenen mit einer Fülle an Daten mit geringem Informationsgehalt zu belasten (siehe auch Abschnitt 4).
- Flexible Konfigurierbarkeit, vor allem, aber nicht nur im Hinblick auf Messrate und -auflösung

Vor allem die oben bereits angesprochenen Trends zu einer umfassenderen Bewertung und erweiterten Funktionalität des Smart Sensors durch Selbstüberwachung und -konfiguration bis hin zu einer Selbstkalibrierung – in Summe auch als Self-X-Funktionalität bezeichnet [14] – stellen dabei einen deutlichen Mehrwert für die übergeordneten (Produktions-)Systeme dar. Man beachte, dass dabei nicht nur erweiterte digitale Funktionen betrachtet werden, sondern durchaus auch Ansätze wie eine rekonfigurierbare analoge Elektronik (field programmable analog array, FPAA). Auch für das unten näher betrachtete Beispiel des Condition Monitorings komplexer Anlagen ist die korrekte Funktion der Sensoren von entscheidender Bedeutung, wobei dort allerdings auch die Korrelation im System für die Erkennung von Fehlern ausgenutzt werden kann – diese Funktion muss dann auf einer höheren Ebene im System realisiert werden.

Weitere Trends, die durch das Paradigma Industrie 4.0 initiiert oder zumindest weiter gestärkt werden, sind:

- Messung als Service: damit verbunden ist ein Paradigmenwechsel, weil nun Messwerte verkauft werden und nicht mehr die Messgeräte. Man beachte, dass dann die (aktuelle, online bestimmte) Messunsicherheit den Preis des Messwerts mit bestimmen wird.
- Verfolgbarkeit einzelner Bauteile, bis hin zu Schrauben, Zahnradern: diese weitergehende Kenntnis erlaubt z. B. ein Toleranzmanagement in der Montage bei der Integration von Baugruppen [15] und ist auch notwendig für ein umfassendes Condition Monitoring, da nur so die Auswirkung einzelner Prozessschritte auf das Endergebnis umfassend erfasst und berücksichtigt werden kann.
- Selbstlernende Systeme: grundsätzlich kann durch Ausnutzen von Korrelationen zwischen Sensoren, aber auch für externe Störeinflüsse eine Überwachung der korrekten Funktion im Sinne einer System-Selbstdiagnose erfolgen auf der Basis von Machine Learning [16]. Allerdings ist offen, ob hier unüberwachte Verfahren ausreichen, oder ob, wie im Ab-

schnitt 4 gezeigt, überwachte Verfahren benötigt werden, d. h. eine Kenntnis des aktuellen Zustands für das Anlernen der Systeme.

- Semantik zur Analyse komplexer Systeme: eine über die rein datenbasierte Bewertung hinausgehende Interpretation der Bedeutung der Messwerte bietet vielfältige Chancen, z. B. zur Plausibilisierung von Messdaten und zur Angabe von Wahrscheinlichkeiten für (Fehler-)Ursachen. Man beachte, dass bereits seit 2005 im W3C, dem World Wide Web Consortium, an einer Semantic Sensor Network Ontology gearbeitet wird, um Messdaten und Bedeutungen zu repräsentieren [17].

Am letzten Beispiel ist erkennbar, dass die Bedeutung der Sensorik und Messtechnik auch von anderer Seite frühzeitig erkannt wurde, allerdings manche Entwicklungen parallel und unabhängig voneinander erfolgen. Leider wird die Messunsicherheit im Kontext der semantischen Technologien bisher gar nicht beachtet, obwohl gerade dafür eine weitergehende Beschreibung sinnvoll wäre.

4 Condition Monitoring mit statistischer Modellbildung

Das Potential von Sensorsignalauswertung auf Basis rein statistischer Modelle soll hier skizziert werden am Beispiel des Projekts iCM-Hydraulik [18]. In diesem Projekt wurde an Hand eines hydraulischen Modellsystems bestehend aus Primärkreislauf mit variabler Last und Sekundärkühlkreislauf die Erkennung typischer Schadenszustände der Anlage (interne Pumpenleckage, verzögertes Ventil-schaltverhalten, Druckverlust im Blasenspeicher, abnehmende Kühlleistung) nur aus den Daten der Prozesssensoren (Druck, Durchfluss, Temperatur, elektr. Leistung) untersucht.

Abbildung 2 zeigt einen Überblick über den gewählten Ansatz: das hydraulische System wurde mit insgesamt 17 physikalischen und virtuellen (z. B. Wirkungsgrad, berechnet aus elektrischer Eingangs- und hydraulischer Ausgangsleistung) Sensoren ausgestattet, die mit bis zu 100 Hz ausgelesen wurden. Mit der Anlage wurde ein periodischer Prozess mit einem Arbeitszyklus von 1 min Dauer simuliert, was in der Praxis z. B. einer Presse in einem industriellen Prozess entsprechen würde. Über jeden Arbeitszyklus wurden so insgesamt rund 50 000 Rohdatenwerte erfasst, die als hochdimensionaler Messvektor interpretiert wurden. Eine mehrstufige Dimensionsreduktion über Signalvorverarbeitung, Merkmalsextraktion

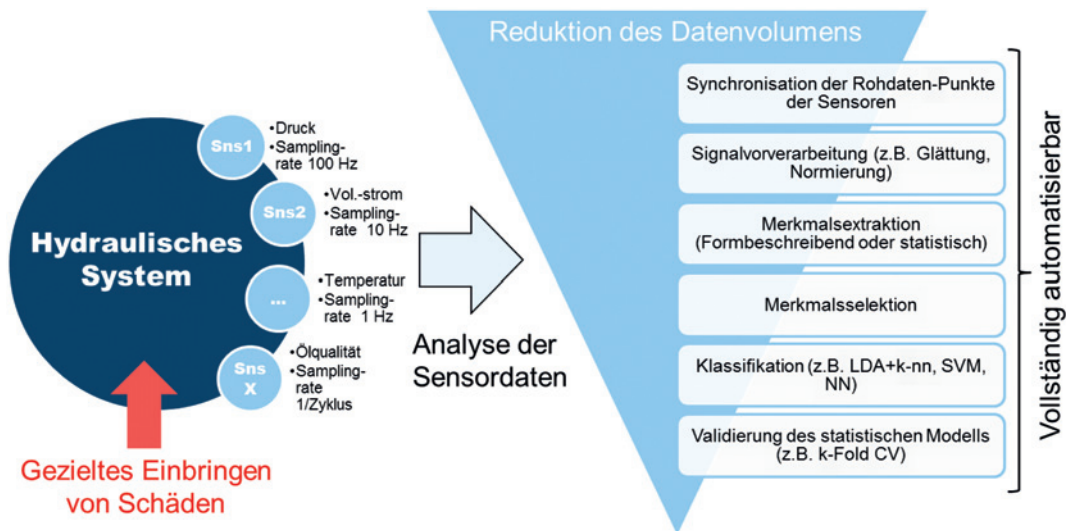


Abbildung 2: Überblick über das Projekt iCM-Hydraulik. Aus den Prozesssensoren wurden je Arbeitszyklus (1 min Dauer) 50 000 Rohwerte ausgelesen, die anschließend durch Korrelation mit den gezielt eingebrachten Schadenszuständen für die Erstellung eines statistischen Modells genutzt wurden. Wichtig war hierbei, dass die Signalauswertung, insbesondere die zwingend erforderliche Dimensionsreduktion, vollständig automatisierbar war, um das Konzept leicht auf andere Fälle übertragen zu können.

und Merkmalsselektion führte schließlich zu einer linearen Diskriminanzanalyse (LDA) [19], mit der eine Klassifizierung, d. h. eine Vorhersage des Schadenstyps und -schweregrads, ermöglicht wird. Die Klassifizierung kann unter Nutzung unterschiedlicher Methoden erfolgen, z. B. k nächste Nachbarn (k-nn), aber auch mittels Support Vector Machines (SVM) oder neuronalen Netzen (NN). Man beachte, dass die ersten beiden Schritte ohne Kenntnis des aktuellen Zustands erfolgen (unüberwachte Verfahren), während für die Merkmalsselektion, die in diesem Fall primär über die Pearson-Korrelation der Merkmale mit den Schadenszuständen erfolgte, und die LDA-Projektion die Kenntnis des jeweiligen Schadenszustands erforderlich ist (überwachte Verfahren) [20]. Im Projekt erfolgte also zunächst eine Trainingsphase, in der alle Schadenszustände miteinander kombiniert wurden. Das vollständige Training erfordert einige 1000 Arbeitszyklen und benötigt daher ca. 3 Tage, vor allem wegen des recht langsamen Einschwingens auf die neue Betriebstemperatur bei Änderung des Kühlerwirkungsgrades. Der komplette Trainingsdatensatz umfasst damit ca. 120 Mio. Rohdatenwerte. Allerdings konnte später bei der Live-Demonstration des Systems auf der Hannover Messe 2015 gezeigt werden, dass bereits im Laufe eines Messtages die meisten Fehlerzustände ausreichend genau gelernt werden können. Eine umfassende Validierung, z. B. mittels k-fold cross validation (k-fold CV), schließt die Erstellung des statistischen Modells ab und stellt sicher, dass trotz des hochdimensionalen Eingangsdatensatzes und der überwachten Verfahren kein Übertrainieren (Overfitting) erfolgt [20].

Für die Merkmalsextraktion wurden primär statistische Methoden genutzt. Dazu wurde der Arbeitszyklus in 13 Abschnitte unterteilt und für jeden Sensor in jedem Abschnitt die ersten vier statistischen Momente (Mittelwert, Standardabweichung, Schiefe und Wölbung) berechnet, was numerisch sehr effizient implementiert werden kann. Dennoch ist die Extraktion der Sekundärmerkmale der bei weitem rechenaufwändigste Schritt der gesamten Trainingsphase, benötigt aber für die untersuchten Messreihen auf einem Standard-PC lediglich einige Minuten. Die Merkmalsselektion an Hand der Korrelation zu den Fehlerzuständen ist rechnerisch extrem effizient, ebenso die Berechnung der LDA-Projektion, die schließlich in eine zweidimensionale Darstellung der Schadenszustände mündet, siehe Abbildung 3. Beide Schritte zusammen benötigen nur Bruchteile von Sekunden. Noch schneller erfolgt die Klassifikation eines neuen Arbeitszyklus, d. h. die Berechnung der im Training selektierten Merkmale, ihre Projektion in den LDA-Zustandsraum und die abschließende Klassifizierung mittels k nächster Nachbarn. Die Leistungsfähigkeit des Ansatzes ist in Abbildung 3 gezeigt: jeder Schadenszustand kann unabhängig vom restlichen Zustand der Anlage mit hoher Genauigkeit klassifiziert werden, z. B. der Kühlerwirkungsgrad mit besser als 10% (zur Simulation wurde der Kühler mit einem gepulsten Signal angesteuert, der Prozentwert gibt das Tastverhältnis, also den duty cycle, an). Die Projektion von Testdaten, die nicht bei der Erstellung des Modells genutzt wurden (offene Symbole) zeigt, dass das Modell tatsächlich eine korrekte Bewertung unbekannter Zustände erlaubt und selbst

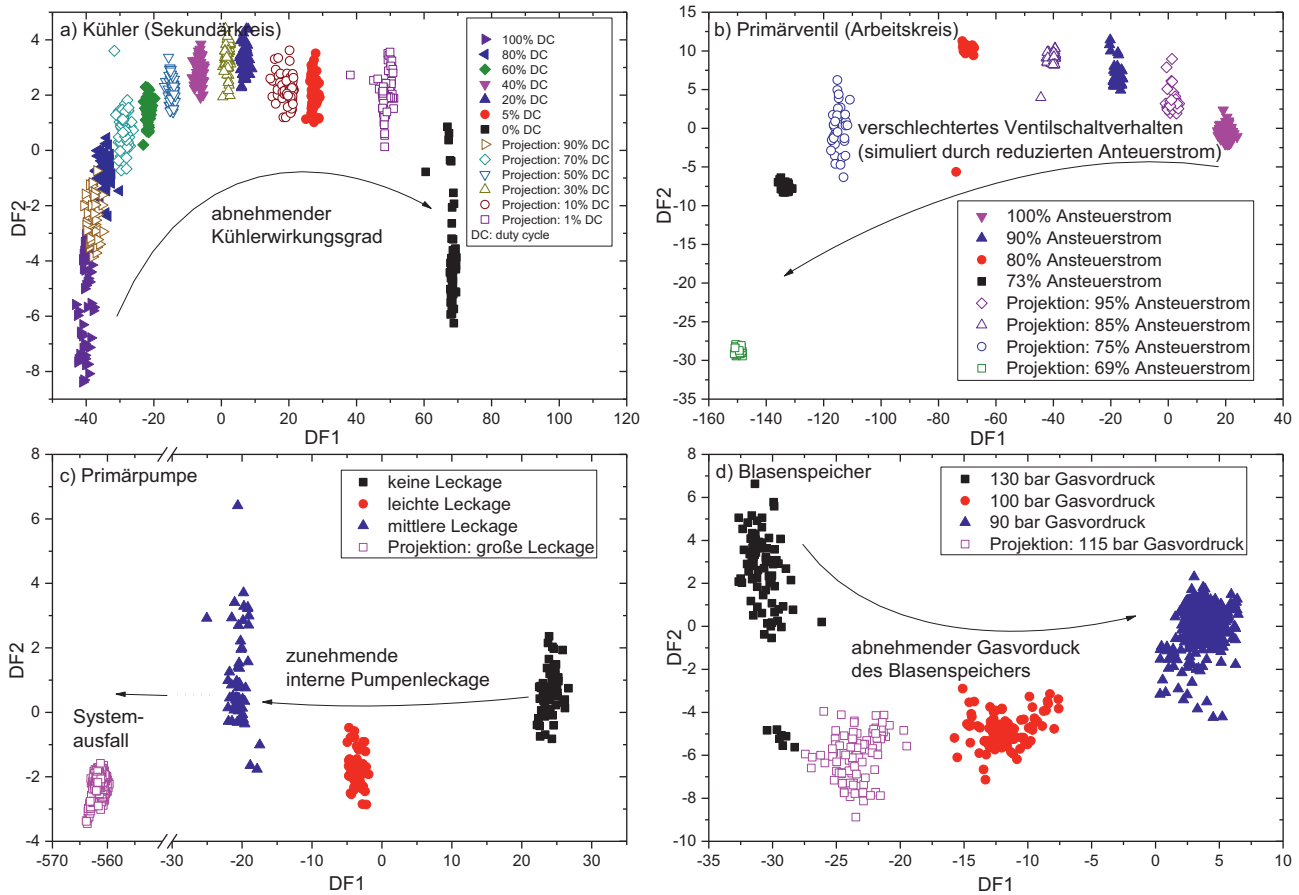


Abbildung 3: LDA-Projektion von Trainingsdaten (ausgefüllte Symbole) und Testdaten (offene Symbole) der vier simulierten Schadenszustände (abnehmende Kühlleistung, verzögertes Ventilschaltverhalten, interne Pumpenleckage, Druckverlust im Blasen Speicher). Man erkennt, dass nach jedem Arbeitszyklus der Anlagenzustand umfassend bewertet werden kann, nach [22].

eine Extrapolation (Projektion von Zuständen außerhalb des Trainingsspektrums) in Grenzen möglich ist.

In weiteren Untersuchungen konnte zudem gezeigt werden, dass sich das Training von einer Anlage auf eine zweite, gleich aufgebaute Anlage prinzipiell übertragen lässt. Allerdings muss der Ursprung der LDA-Projektionen, also der Gutzustand, jeweils manuell angepasst werden, was einer kurzen Kalibrierphase bei Inbetriebnahme entspricht [21]. Angesichts dieser im Vorfeld nicht erwarteten Leistungsfähigkeit des datenbasierten Modells wurde untersucht, wie sich Sensorfehler auf das Klassifizierungsergebnis auswirken. Dazu wurden auf allen Sensorkanälen nachträglich Offset, Drift, Rauschen sowie einzelne Signalaussetzer in den Datensätzen simuliert und damit der aktuelle Zustand klassifiziert. Wenig überraschend verschlechterte sich die Erkennung des Anlagenzustands drastisch, insbesondere für die Überwachung der Primärpumpenleckage und des Blasen Speichervordrucks. Um eine automatische Erkennung von Sensorfehlern zu ermöglichen, wurden daraufhin die Sensorfehler als Zielgrößen

definiert und mit dem identischen Vorgehen automatisiert eine Erkennung der Sensorfehler trainiert. Dabei zeigte sich, dass zum einen die simulierten Sensorfehler wieder mit hoher Zuverlässigkeit, unabhängig vom sonstigen Anlagenzustand, erfasst werden können, siehe Abbildung 4, und zwar noch bevor sie zu einer Fehlklassifizierung des Anlagenzustands führen [22]. Eine korrekte Bewertung des Anlagenzustands ist in vielen Fällen dennoch weiterhin möglich, indem der oder die als fehlerhaft erkannten Sensor(en) von der Auswertung ausgeschlossen werden. Selbst wenn als Worst-Case Szenario die für die Auswertung wichtigsten Sensoren als defekt erkannt und daher aus der Auswertung herausgenommen werden, können jeweils bis zu fünf Sensoren ausfallen bzw. fehlerhaft sein und dennoch wird für die Anlagenzustände eine korrekte Klassifikationsrate von über 80% erzielt [22]. Allerdings musste auch festgestellt werden, dass die Erkennungsgenauigkeit drastisch abnimmt, wenn sich die Hydrauliköl-Temperatur im System deutlich ändert, d. h. entweder muss der Trainingsprozess erweitert werden, um

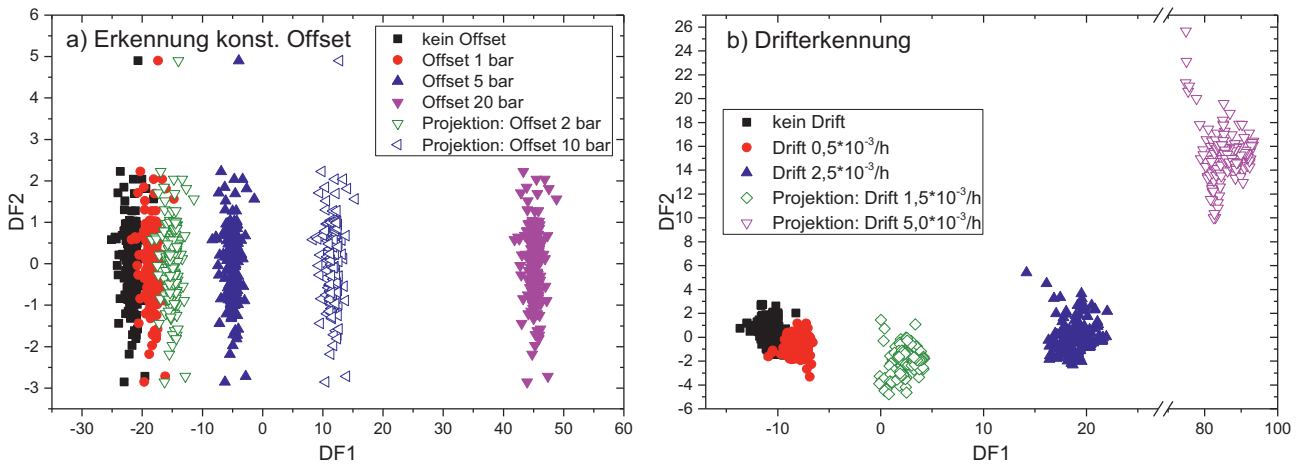


Abbildung 4: LDA-Projektion von Trainingsdaten (ausgefüllte Symbole) und Testdaten (offene Symbole) zur Erkennung von Sensorfehlern, hier Offset und Drift. Mit demselben Ansatz wie für die Anlagenzustandsklassifizierung gelingt wieder eine genaue Bewertung der Sensorfehler, so dass fehlerhafte Sensoren von der Auswertung ausgeschlossen werden können, nach [22].




Abbildung 5: Die Darstellung der Daten aus Abbildung 4a) als Histogramm über der ersten Diskriminanzfunktion zeigt, dass diese eine nahezu lineare Abbildung zur Bestimmung des Offsets darstellt und auch eine Abschätzung der Messunsicherheit für den Offset erlaubt. Diese ist konstant auch für die nicht zur Erstellung des Modells verwendeten Daten mit 2 bzw. 10 bar Offset.

auch Variationen der Öltemperatur z. B. durch Änderungen der Umgebungstemperatur berücksichtigen zu können, oder eine (genaue) Bewertung der Anlage kann nur erfolgen, wenn die übliche Betriebstemperatur vorliegt. Letzteres ist für industrielle Anwendungen sicher der sinnvollere Ansatz, zumal eine umfassende Zustandsbewertung jede Minute sicher in der Praxis unnötig ist, vor allem für eigentlich langsam ablaufende Verschleißprozesse.

Die Projektion in Abbildung 4a) kann auch etwas anders dargestellt werden, da offensichtlich die zweite Diskriminanzfunktion (DF2) ohnehin keine Bedeutung für die Klassifizierung hat. Plottet man also die Daten als Häufigkeitsverteilung über die erste Diskriminanzfunktion, so ergibt sich das in Abbildung 5 gezeigte Bild. Man erkennt, dass sich für alle Offsetwerte näherungsweise eine Normalverteilung mit konstanter Halbwertsbreite ergibt, d. h. man kann diese Projektion nicht nur als „Messung“ für den Offset eines Sensors nutzen, sondern damit zusätzlich die Standardmessunsicherheit für die Bestimmung des Offsets abschätzen. Man beachte, dass das auch für die

nicht bei der Erstellung des Modells genutzten Werte mit 2 und 10 bar Offset gilt. Eine ähnliche Darstellung für den Speichervordruck zeigt, dass der Einfluss der Öltemperatur letztlich zu einer erhöhten Messunsicherheit führt, siehe Abbildung 6.

Die gezeigten Beispiele demonstrieren eindrucksvoll das Potential einer datenbasierten Modellbildung zur Zustandsüberwachung komplexer Anlagen auf Basis der ohnehin vorhandenen Prozesssensoren. Damit lässt sich eine preiswerte und leistungsfähige Zustandsüberwachung realisieren, die sich zudem im Hinblick auf die Messunsicherheit wie eine echte Messung des Zustandes verhält, d. h. die Messunsicherheit ist über den gesamten Kalibrierbereich nahezu konstant, steigt aber, wenn zusätzliche Störeinflüsse hinzukommen, z. B. eine stärkere Variation der Umgebungstemperatur. Es muss allerdings festgestellt werden, dass für andere Zustände, im konkreten Fall insbesondere für die Vorhersage des Ventilschaltverhaltens, durchaus andere Beobachtungen gemacht wurden. Dabei wurden sich über den Kalibrierbereich ändernde

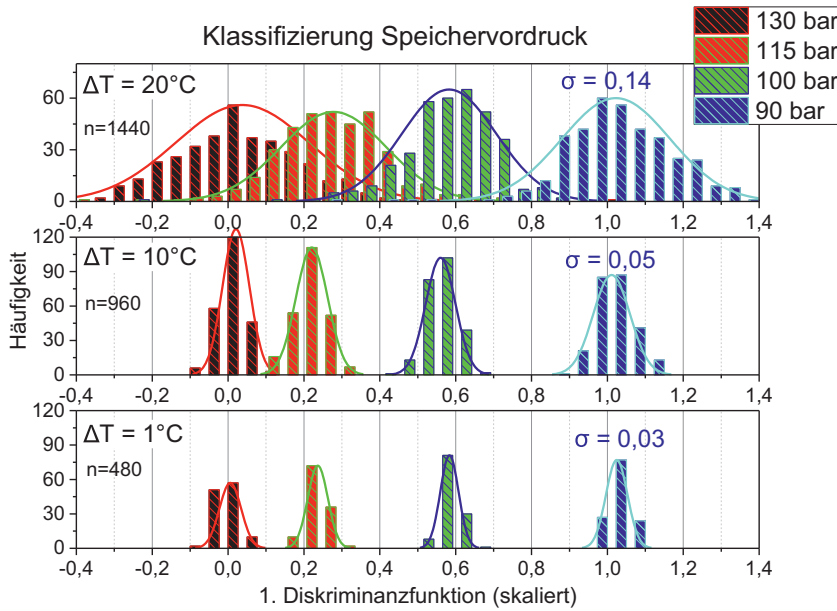


Abbildung 6: Histogramm der Daten zur Klassifizierung des Speichervordrucks über die 1. Diskriminanzfunktion. Hier wurde eine zusätzliche Skalierung vorgenommen (vgl. Abbildung 3d), um alle Daten bei 130 bar (Nominaldruck) auf 0 und die Daten bei 90 bar auf 1 zu zentrieren. Man erkennt, dass eine größere Streuung der Öltemperatur zu einer zunehmenden Messunsicherheit für die Bestimmung des Speichervordrucks führt.

Standardabweichungen festgestellt, was z. B. auf einen nicht-linearen Zusammenhang zwischen Diskriminanzfunktion und Fehlerzustand zurückzuführen sein könnte. Problematischer erscheint, dass für Testdaten, die nicht zur Erstellung des Modells genutzt wurden, keine Normalverteilung der Daten vorliegt, so dass also eine Interpretation als „Messung“ des Zustands mit abschätzbarer Messunsicherheit nur eingeschränkt möglich ist.

Die erfolgreichen Vorarbeiten im Projekt iCM-Hydraulik führten folgerichtig zur Etablierung eines Nachfolgeprojektes, bei dem die gewählten Ansätze erweitert werden sollen auf einen offenen Sensorsystembaukasten. Eingesetzt werden u. a. magnetoresistive Sensoren (AMR, GMR, TMR) als Signalgeber für Strom, Weg und Winkel [8], aber auch weitere Mikrosensoren, z. B. mikromechanische Sensoren für Vibration, Druck und Wärmestrahlung. Im Mittelpunkt des Projektes MoSeS-Pro [23] steht dabei ein Elektronikbaukasten, um die notwendige Signalvorverarbeitung und Merkmalsextraktion sensornah ausführen zu können, da hochfrequent mit bis zu einigen 100 MHz abgetastete Sensorsignale sonst die übergeordneten Ebenen überlasten würden. Zudem werden im Projekt neue Self-X-Ansätze erprobt sowie drahtlose Schnittstellen und Energy Harvesting zur einfachen Integration und Inbetriebnahme der Sensorsysteme.

5 Fazit und Ausblick

Sensorik und Messtechnik sind zentrale Innovationstreiber, nicht nur für Industrie 4.0, sondern auch für weitere aktuelle Megatrends, die häufig mit Smart beschrieben werden, also Smart Factory, Smart Production, Smart Mobility, Smart Home, Smart City usw. Als Basis für intelligente Entscheidungen der Systeme ist natürlich das Wissen über den Zustand und die Randbedingungen erforderlich, das online und hochgenau über Sensoren zur Verfügung gestellt wird. Die Bedeutung der Sensorik und Messtechnik für die Industrie 4.0 wird in verschiedensten Aspekten gewürdigt und beschrieben [24–27] und gipfelt schon einmal in der Aussage „Industrie 4.0: Ohne Sensorsysteme geht nichts“ [28]. Bei aller Euphorie über den damit verbundenen Anstieg der Stückzahlen darf allerdings auch nicht unterschlagen werden, dass an manchen Stellen ein Paradigmenwechsel stattfindet, wie so oft in der digitalen Revolution. Ähnlich wie Uber und AirBnB komplett neue Geschäftsmodelle ermöglichen, geschieht dies bereits auch an manchen Stellen in der Sensorik. So liefert heute Google aus den Bewegungsdaten der Mobiltelefone die verlässlichsten Verkehrsdaten mit weit besserer Aktualität und Präzision als klassische Verkehrsüberwachungssysteme mit dedizierten Sensoren. Hier spielt die Vernetzung eine große Rolle, aber auch die schlichte Masse an Daten: zwar sind einzelne Bewegungsdaten wenig sinnvoll zur Bewertung von Verkehrsströmen, aber die Fusion einer Vielzahl von Bewegungsdaten liefert die gewünschte Information. Ähnliche Effekte sind ggfs. in der Zukunft für Umweltdaten zu erwarten, wenn Gassensoren in großen

Stückzahlen in Mobiltelefone integriert werden. Und natürlich sind Big Data und Data Mining auch wichtige Themen für die Produktion, insbesondere bei hohen Stückzahlen. Die Branche der Sensorik und Messtechnik und damit natürlich auch die Forschung müssen sich dieser Herausforderung stellen, um nicht eines Tages festzustellen, dass neue Standards nicht mehr von GMA, DKE und AMA, sondern vom Silicon Valley aus gesetzt werden.

Ein möglicher Weg, sich hier zu positionieren, könnte gerade im Bereich der Messunsicherheit liegen durch in den Smart Sensor integrierte Selbstkalibrierung auf Basis von Quantenstandards. Aber auch eine erweiterte Betrachtung der Messunsicherheit, gerade im Zusammenhang mit der Sensordatenfusion und statistischen Modellbildung, ist zwingend erforderlich, um die unbestrittenen Potentiale ausnutzen und die Erfolgsgeschichte der industriellen Produktion Made in Germany fortschreiben zu können. Das Thema einer umfassenden Zustandsbewertung komplexer Produktionssysteme – von der einzelnen Presse über das CNC-Zentrum bis hin zur kompletten Fabrik mit Montagetechnik und Prüfsystemen – kann dabei als eine Leitidee für die weitere Entwicklung der Sensorik und Messtechnik für die Industrie 4.0 dienen, weil hier unmittelbar die ökonomische Bedeutung klar wird, aber auch vielfältige neue Geschäftsmodelle erprobt werden können. Ein wichtiges Thema dabei ist auch die Datensicherheit und damit verbunden die Klärung der Frage, wem die Daten eigentlich gehören und wem sie wie zugänglich gemacht werden. Soll z. B. eine kritische Komponente einer Produktionsanlage mittels Condition Monitoring überwacht werden, so fallen die (Roh-)Daten in der Fabrik an, das Know-how zu ihrer Bewertung liegt aber i. d. R. beim Hersteller der Komponente. Eine vollständige Weiterleitung der Rohdaten aus der Fabrik zum Komponentenhersteller wird aber meist unerwünscht sein, weil sich daraus auch viele weitere Informationen ableiten lassen, z. B. die Produktionsstückzahlen. Ein funktionierendes Geschäftsmodell wird daher eine gewisse Vertrauensbasis benötigen, aber auch z. B. eine geeignete Abstrahierung der Daten aus der Komponente, um damit nur die Zustandsbewertung zu ermöglichen, aber keine weitergehenden Schlüsse über den Gesamtprozess. Noch komplexer wird dieses Bild, wenn verschiedene Komponenten- und Sensorhersteller im Sinne der oben skizzierten ganzheitlichen Condition Monitoring Ansätze involviert sind. Möglicherweise wird sich damit auch eine ganz neue Instanz im industriellen Bereich etablieren, nämlich neutrale Dienstleister, die für die vertrauliche Behandlung der Daten einerseits und die kompetente Auswertung andererseits eingebunden werden.

Literatur

1. siehe z. B. <http://www.plattform-i40.de> sowie <http://www.hightech-strategie.de/de/Industrie-4-0-59.php>.
2. siehe z. B. <http://www.iiconsortium.org>.
3. O. Gassmann, J. Kottmann: *Technologiemanagement in der Sensorik, Wissensmanagement* 8, 2002.
4. *Sensor-Trends 2014 – Trends in zukunftsorientierten Sensortechnologien*, AMA Fachverband für Sensorik (Hrsg.), 2010.
5. AMA Verband für Sensorik und Messtechnik e. V. (ursprünglich gegründet als Arbeitsgemeinschaft Messwertaufnehmer), <http://ama-sensorik.de/>.
6. D. Schaudel: *Sensor 4.0 für Industrie 4.0, Tagungsband 12. Dresdner Sensorsymposium 2015*, doi:10.5162/12dss2015/4.1.
7. <http://www.ama-sensorik.de/wissenschaft/ama-innovationspreis/>.
8. J. Marien, A. Schütze: *Magnetic Microsensors: Quo vadis?*, Proc. SENSOR 2009, Vol. II, 17–22 (2009), doi:10.5162/sensor09/v2/a6.1.
9. P. Reimann, A. Schütze: *Sensor Arrays, Virtual Multisensors, Data Fusion, and Gas Sensor Data Evaluation*, in: C.-D. Kohl, T. Wagner (eds.): *Gas Sensing Fundamentals*, Springer Series on Chemical Sensors and Biosensors, Volume 15, 2014, ISBN: 978-3-642-54518-4.
10. T. Baur, A. Schütze, T. Sauerwald: *Optimierung des temperaturzyklischen Betriebs von Halbleitersensoren*, tm – Technisches Messen, 82 (4), 187–195 (2015), doi:10.1515/teme-2014-0007.
11. T. Ochs: *Selbstüberwachung und online Verifizierung von Sensordaten im Kraftfahrzeug*, Übersichtsvortrag, 11. Dresdner Sensorsymposium 2013, 9.–11. Dezember 2013, Dresden.
12. M. Schüler, T. Sauerwald, A. Schütze: *A novel approach for detecting HMDSO poisoning of metal oxide gas sensors and improving their stability by temperature cycled operation*, Journal of Sensors and Sensor Systems 4, 305–311 (2015), doi:10.5194/jsss-4-305-2015.
13. M. Stahl-Offergeld: *Robuste dreidimensionale Hall-Sensoren für mehrachsige Positionsmesssysteme*, „Aktuelle Berichte aus der Mikrosystemtechnik – Recent Developments in MEMS“, Band 20, Shaker-Verlag, Aachen, 2011, ISBN: 978-3-8440-0303-1 (gleichzeitig Dissertation, Universität des Saarlandes, Fakultät Physik und Mechatronik).
14. M. Akmal Johar, A. König: *Case Study of an Intelligent AMR Sensor System with Self-x Properties*, in: A. Gaspar-Cunha, R. Takahashi, G. Schäfer, L. Costa (eds.): *Soft Computing in Industrial Applications*, 337–346, ISBN: 978-3-642-20504-0.
15. R. Müller, M. Esser: *Montagesystemgestaltung – Toleranzmanagement als Planungsbasis*, Vortrag, 3. Aachener Montage-Tagung, 16. März 2011, Aachen, online: http://www.wzlforum.de/cms/forum_repository/Vortrag_Prof_Müller.pdf.
16. J. Cachay, E. Abele: *Developing Competencies for Continuous Improvement Processes on the Shop Floor through Learning Factories – Conceptual Design and Empirical Validation*, Procedia CIRP, Vol 3, 638–643 (2012), doi:10.1016/j.procir.2012.07.109.
17. <https://www.w3.org/2005/Incubator/ssn/ssnx/ssn>.

18. Data-based intelligent condition monitoring for hydraulic systems – statistische Auswertung von Sensordaten für die intelligente Zustandsüberwachung von hydraulischen Maschinen, Projekt gefördert im EFI-Programm des Saarlandes, Unterauftrag der HYDAC Filter Systems GmbH, durchgeführt am Zentrum für Mechatronik und Automatisierungstechnik gGmbH (ZeMA), 2013–2015.
19. R. O. Duda, P. E. Hart, D. G. Stork: Pattern classification, 2nd edn. Wiley, New-York, 2000, ISBN: 978-0-471-05669-0.
20. N. Helwig, A. Schütze: Intelligentes Condition Monitoring mit automatisierter Merkmalsgenerierung und -bewertung, in: A. Schütze, B. Schmitt (Hrsg.): XXVIII. Messtechnisches Symposium des Arbeitskreises der Hochschullehrer für Messtechnik, Tagungsband, Shaker Verlag, Aachen (2014), ISBN: 978-3-8440-2994-9, S. 121–128, doi:10.5162/AHMT2014/P1.
21. N. Helwig, E. Pignatelli, A. Schütze: Condition Monitoring of a Complex Hydraulic System Using Multivariate Statistics, Proc. I2MTC-2015 - 2015 IEEE International Instrumentation and Measurement Technology Conference, paper PPS1-39, Pisa, Italy, May 11–14, 2015, doi:10.1109/I2MTC.2015.7151267.
22. N. Helwig, A. Schütze: Detecting and compensating sensor faults in a hydraulic condition monitoring system, Proc. SENSOR 2015, open access, doi:10.5162/sensor2015/D8.1.
23. Modulare Sensorsysteme für Echtzeit-Prozesssteuerung und smarte Zustandsbewertung für die Industrie 4.0 (MoSeS-Pro), gefördert durch das BMBF im Rahmen des Förderschwerpunkts „Sensorbasierte Elektroniksysteme für Anwendungen für Industrie 4.0 (SElekt I4.0)“, 2015–2018, für nähere Informationen siehe <http://www.moses-pro.de/>.
24. D. Imkamp, J. Berthold, M. Heizmann, K. Kniel, M. Peterek, R. Schmitt, J. Seidler, K.-D. Sommer: Herausforderungen und Trends in der Fertigungsmesstechnik – Industrie 4.0, tm – Technisches Messen, 83, 417–429 (2016), doi:10.1515/teme-2015-0081.
25. <http://www.elektroniknet.de/specials/sensoren-fuer-die-industrie-40/>.
26. K.-D. Sommer, A. Schütze: Smart sensors & networked digital measurement systems – Trends and challenges in industrial measurement and metrology, Keynote lecture, 46th Ann. Meas. Science Conf. 2016, Anaheim, USA, March 23–25, 2016.
27. R. Werthschützky, A. Schütze (Hrsg.): Sensor Technologien 2020, AMA Verband für Sensorik und Messtechnik e. V., 2017, im Druck.
28. H. Arnold, Chefredakteur Markt&Technik: siehe <http://www.elektroniknet.de/messen-testen/sonstiges/artikel/110776/>.

Autoreninformationen



Andreas Schütze

Universität des Saarlandes – Lehrstuhl für Messtechnik, Fachrichtung Systems Engineering, Campus A5.1, Raum 2.33, 66123 Saarbrücken

schuetze@lmt.uni-saarland.de

Andreas Schütze studierte Physik an der RWTH Aachen und promovierte in Angewandter Physik an der Justus-Liebig-Universität Gießen. Nach einer mehrjährigen Tätigkeit in der Wirtschaft wurde er 1998 als Professor für Sensorik und Mikrosystemtechnik an die FH Niederrhein berufen. Seit 2000 leitet er den Lehrstuhl für Messtechnik in der Fachrichtung Systems Engineering der Universität des Saarlandes. Seine Forschungsschwerpunkte sind intelligente chemische Messsysteme für die Gasphase und für Flüssigkeiten sowie Condition Monitoring mit datenbasierten Modellen. Er ist u. a. Koordinator mehrere internationaler Verbundprojekte, Vorsitzender des Wissenschaftsrates des AMA Verband für Sensorik und Messtechnik e. V., Vorstandsmitglied der f. m. s. - Forschungsgesellschaft für Messtechnik, Sensorik und Medizintechnik e. V. Dresden und Vorsitzender des fms/ProcessNet-Gemeinschaftsausschusses Sensoren und Sensorsysteme sowie Mitglied von IEEE und VDE. An der Universität des Saarlandes ist er einer der Gründer des Mikrotechnologie-Transferzentrums Mitranz und des Zentrums für Mechatronik und Automatisierungstechnik (ZeMA) GmbH. Er ist aktiv als Mitglied des Editorial Boards und Gutachter für verschiedene wissenschaftliche Zeitschriften (u. a. J Sensors and Sensor Systems, J of Sensors, Sensors & Actuators B, IEEE Sensors Journal) und Mitglied des Programmkomitees verschiedener Tagungen und Konferenzen. Er betreibt seit 2006 das Schülerlabor SinnTec und engagiert sich in der Nachwuchsförderung, insbesondere mit Themen aus dem Bereich Sensorik und Messtechnik.



Nikolai Helwig

Zentrum für Mechatronik und Automatisierungstechnik gGmbH – Sensorik und Aktorik, 66121 Saarbrücken

Nikolai Helwig studierte Mechatronik an der Universität des Saarlandes und ist seit 2013 wissenschaftlicher Mitarbeiter in der Abteilung Sensorik und Aktorik am Zentrum für Mechatronik und Automatisierungstechnik gGmbH (ZeMA), einem saarländischen Landesinstitut zur Förderung der anwendungsbezogenen Forschung, zur Ausbildung des ingenieurwissenschaftlichen Nachwuchses und zum Technologietransfer durch Kooperation mit der Wirtschaft. Sein Forschungsschwerpunkt liegt im Bereich Condition Monitoring mit statistischen Methoden, primär auf Basis automatisierbarer, überwachter Lernverfahren. Er war maßgeblich an den dem Forschungsprojekt iCM-Hydraulik beteiligt und ist Mitinitiator des BMBF-Projektes MoSeS-Pro, in dem er heute tätig ist.