

Roland Jochem
Maurice Meyer *Hrsg.*

Rethinking Quality – Wandel des Qualitätsmanagements durch Digitalisierung und Künstliche Intelligenz

Bericht zur GQW-Jahrestagung 2024
in Berlin



Rethinking Quality – Wandel des Qualitätsmanagements durch Digitalisierung und Künstliche Intelligenz

Roland Jochem · Maurice Meyer
Hrsg.

Rethinking Quality – Wandel des Qualitätsmanagements durch Digitalisierung und Künstliche Intelligenz

Bericht zur GQW-Jahrestagung 2024
in Berlin

 Springer Vieweg

Hrsg.

Roland Jochem
Institut für Werkzeugmaschinen und
Fabrikbetrieb
Technische Universität Berlin
Berlin, Deutschland

Maurice Meyer
Institut für Werkzeugmaschinen und
Fabrikbetrieb
Technische Universität Berlin
Berlin, Deutschland

ISBN 978-3-658-47212-2 ISBN 978-3-658-47213-9 (eBook)
<https://doi.org/10.1007/978-3-658-47213-9>

Die Deutsche Nationalbibliothek verzeichnet diese Publikation in der Deutschen Nationalbibliografie; detaillierte bibliografische Daten sind im Internet über <https://portal.dnb.de> abrufbar.

Springer Vieweg

© Der/die Herausgeber bzw. der/die Autor(en), exklusiv lizenziert an Springer Fachmedien Wiesbaden GmbH, ein Teil von Springer Nature 2025

Das Werk einschließlich aller seiner Teile ist urheberrechtlich geschützt. Jede Verwertung, die nicht ausdrücklich vom Urheberrechtsgesetz zugelassen ist, bedarf der vorherigen Zustimmung des Verlags. Das gilt insbesondere für Vervielfältigungen, Bearbeitungen, Übersetzungen, Mikroverfilmungen und die Einspeicherung und Verarbeitung in elektronischen Systemen.

Die Wiedergabe von allgemein beschreibenden Bezeichnungen, Marken, Unternehmensnamen etc. in diesem Werk bedeutet nicht, dass diese frei durch jede Person benutzt werden dürfen. Die Berechtigung zur Benutzung unterliegt, auch ohne gesonderten Hinweis hierzu, den Regeln des Markenrechts. Die Rechte des/der jeweiligen Zeicheninhaber*in sind zu beachten.

Der Verlag, die Autor*innen und die Herausgeber*innen gehen davon aus, dass die Angaben und Informationen in diesem Werk zum Zeitpunkt der Veröffentlichung vollständig und korrekt sind. Weder der Verlag noch die Autor*innen oder die Herausgeber*innen übernehmen, ausdrücklich oder implizit, Gewähr für den Inhalt des Werkes, etwaige Fehler oder Äußerungen. Der Verlag bleibt im Hinblick auf geografische Zuordnungen und Gebietsbezeichnungen in veröffentlichten Karten und Institutionsadressen neutral.

Springer Vieweg ist ein Imprint der eingetragenen Gesellschaft Springer Fachmedien Wiesbaden GmbH und ist ein Teil von Springer Nature.

Die Anschrift der Gesellschaft ist: Abraham-Lincoln-Str. 46, 65189 Wiesbaden, Germany

Wenn Sie dieses Produkt entsorgen, geben Sie das Papier bitte zum Recycling.

Vorwort

In einer Zeit des technologischen Fortschritts, globaler Krisen sowie sich verändernder Kundenerwartungen muss Qualität neu gedacht werden. Das traditionelle Qualitätsmanagement, welches jahrzehntelang auf bewährten Prozessen und Methoden basierte, unterliegt einer fundamentalen Transformation. Der alleinige Fokus auf Produkte ist längst unzureichend, um die Vielfältigkeit des Qualitätsmanagements in Unternehmen abzubilden. Vielmehr muss Qualität ganzheitlich im Wertschöpfungsnetzwerk verankert werden. Zentraler Treiber der Vernetzung ist die umfassende Digitalisierung der industriellen Produktion mit ihrer zunehmenden Datenverfügbarkeit über die verschiedenen Wertschöpfungsstufen und Lebenszyklusphasen hinweg. In diesem Zusammenhang eröffnet Künstliche Intelligenz völlig neue Möglichkeiten, die Art und Weise, wie Qualität gemessen, überwacht und verbessert wird, zu revolutionieren. Der Wandel des Qualitätsmanagements durch Digitalisierung und Künstliche Intelligenz geht jedoch über die bloße Implementierung neuer Technologien hinaus. Digitalisierung, Datenanalytik und Künstliche Intelligenz erweitern die Potenziale des Qualitätsmanagers und erfordern die umfassende Entwicklung neuer Kompetenzen. Alles in allem bedarf es daher neuer Leitbilder, Strategien und Abläufe im Qualitätsmanagement, um auch in Zukunft erfolgreich und wettbewerbsfähig zu bleiben.

Die diesjährige Tagung der Gesellschaft für Qualitätswissenschaft e. V. (GQW) fand folgerichtig unter dem Motto „Rethinking Quality – Wandel des Qualitätsmanagements durch Digitalisierung und Künstliche Intelligenz“ statt und wurde in Kooperation mit dem Fachgebiet Qualitätswissenschaft der Technischen Universität Berlin ausgerichtet. Die Auseinandersetzung mit aktuellen Handlungsfeldern, Trends und Herausforderungen im Qualitätsmanagement sowie der Austausch von Erfahrungen und Best Practices waren zentrale Bestandteile der zweitägigen Tagung im Oktober 2024 in Berlin.

Im vorliegenden Tagungsband sind die im Rahmen der Tagung eingereichten und begutachteten Beiträge zusammengestellt. Auch in diesem Jahr gelang es erneut, eine große Bandbreite an Themen abzudecken, mit besonderem Fokus auf die Digitalisierung sowie den Wandel des Qualitätsmanagements. So fokussieren

gleich mehrere Beiträge den Einsatz von Künstlicher Intelligenz in der Automobilindustrie, u. a. im Bereich der akustischen Qualitätsprüfung, der Ursachenanalyse und der intelligenten Entscheidungsunterstützung. Weiterhin wird aufgezeigt, wie sich KI-Algorithmen im Zuge von Reklamationen zur automatisierten Klassifizierung oder zur Klärung von Haftungsfragen nutzen lassen. Zudem wird die Anwendung von Künstlicher Intelligenz zur Segmentierung von Schweißnähten erläutert und es wird dargelegt, wie ein smartes Fehlermanagementsystem für kleine und mittlere Unternehmen systematisch entwickelt werden kann. Unter umwelttechnischen Gesichtspunkten werden die konventionelle und additive Fertigung verglichen. Ebenso werden die Digitalisierung der Agrar- und Ernährungswirtschaft als auch die Pflanzenvitalität im Thüringer Wald aufgegriffen. Nicht zuletzt werden die Substitution konventioneller Aktorik durch intelligente Werkstoffe, die Untersuchung von Degradationsfaktoren in der Wasserstoffproduktion und neue gesetzliche Anforderungen im Bereich KI-basierter Medizinprodukte thematisiert. Abgerundet wird dieser Tagungsband schließlich durch Beiträge aus den Bereichen der Produktentwicklung und Remote-Arbeit.

Unser Dank gilt allen Teilnehmerinnen und Teilnehmern sowie insbesondere den Autorinnen und Autoren, welche die vorliegenden Beiträge erarbeitet und präsentiert haben. Einen besonderen Dank möchten wir darüber hinaus allen Gutachterinnen und Gutachtern aussprechen, die durch ihre sorgfältige und kritische Bewertung der Beiträge maßgeblich zur Qualität dieses Tagungsbandes beigetragen haben.

Berlin
Oktober 2024

Prof. Dr.-Ing. Roland Jochem
Maurice Meyer, M. Sc.

Fachgebiet Qualitätswissenschaft
Technische Universität Berlin

Inhaltsverzeichnis

Quality Intelligence – Wege zur Entwicklung eines intelligenten Qualitätsmanagements in der Produktion	1
Marcos Padrón Hinrichs, Nils Klasen, Tobias Schulze, Felix Sohnus, und Robert H. Schmitt	
1 Einleitung	2
2 Historische Entwicklung des Qualitätsmanagements in produzierenden Unternehmen	2
3 Das Aachener Qualitätsmanagement-Modell zur Ausrichtung der qualitätsrelevanten Informationsflüsse und Aktivitäten in Unternehmen	3
4 Das Internet of Production als Befähiger eines intelligenten Qualitätsmanagements	5
5 Potenziale der künstlichen Intelligenz für effizientere Qualitätsschleifen in der Produktion	7
6 Predictive Quality und Quality Diagnosis am Beispiel eines Blisterverpackungsprozesses	8
7 Zusammenfassung und Ausblick	15
Literatur	17
Potenziale und Herausforderungen von KI-basierten akustischen Qualitätsprüfungen in der Automobilproduktion	19
Roman Strasser und Robert Refflinghaus	
1 Motivation und Zielsetzung	20
2 Theoretischer Hintergrund	21
3 Methodische Vorgehensweise	26
4 Ergebnisse	26
5 Zusammenfassung & Ausblick	35
Literatur	36

Anwendung von Causal-Discovery-Algorithmen zur Root-Cause-Analyse in der Fahrzeugmontage	39
Lucas Poßner, Lukas Bahr, Leonard Röhl, Christoph Wehner, und Sophie Gröger	
1 Einleitung	40
2 Stand der Technik	41
3 Methoden	44
4 Ergebnisse	51
5 Diskussion	55
6 Fazit und Ausblick	56
Literatur	57
Vergleich von KI-Algorithmen zwecks automatisierter Klassifizierung von Reklamationen	61
Christian Böhmer, Nadine Schlüter, und Manuel Löwer	
1 Einführung	62
2 Reklamationsmanagement als Disziplin	62
3 KI in Wirtschaft und Industrie	63
4 Evaluation der KI-Algorithmen	69
5 Fazit und Ausblick	71
Literatur	73
Substituierung konventioneller Aktorik durch intelligente Werkstoffe: Erprobung der technischen Zuverlässigkeit von aktiv gekühlten Formgedächtnis-Aktoren	77
Marcel Schmidt, Philipp Heß, und Stefan Bracke	
1 Einleitung	78
2 Grundlagen der Formgedächtnistechnologie	78
3 Erprobung von Formgedächtnisaktoren	82
4 Analyse der Versuchsdaten	84
5 Zusammenfassung und Ausblick	96
Literatur	97
Untersuchungen beschleunigender Degradationsfaktoren von Elektrolyseurkomponenten in der Wasserstoffproduktion unter dem Einfluss erneuerbarer Energielasten	101
Jannis Pietruschka, Benno Büttner, und Stefan Bracke	
1 Motivation	102
2 Methodik und Vorgehen	103
3 Stand der Technik und Forschung	105
4 Prototypische Umsetzung und Simulationsergebnisse	111
5 Fazit	118
Literatur	119

Vergleichende Prozesskettenuntersuchung der konventionellen und additiven Fertigung eines Demonstratorbauteils unter umwelttechnischen Aspekten 123
Lennart Grüger, Tim Sebastian Fischer, Elisa Korb, und Sebastian Härtel

1 Einleitung 123
2 Stand der Forschung 124
3 Vergleich der Prozessketten – Ergebnis & Diskussion 131
4 Fazit. 139
5 Limitation und Ausblick 140
Literatur. 141

Definition von Grenzen zur multispektralen Überwachung der Pflanzenvitalität. 143
Martin Richter, Maik Rosenberger, und Gunther Notni

1 Motivation. 143
2 Stand der Technik 144
3 Untersuchungen & Ergebnisse 147
4 Zusammenfassung der Ergebnisse und Bewertung. 152
Literatur. 153

Qualitätsmerkmal Nachhaltigkeit – Treiber für die Digitalisierung und den Wandel von Kunden-Lieferanten-Beziehungen in der Agrar- und Ernährungswirtschaft. 155
Stephanie Krieger-Güss, Brigitte Petersen, Hans-Dieter Philipowski, Benjamin Fehrenbach, und Annabelle Kunz

1 Einleitung 156
2 Methodische Vorgehensweise 157
3 Ergebnisse. 159
4 Schlussfolgerung und Ausblick. 166
5 Fazit. 169
Literatur. 170

Qualitätsmanagement 4.0: Entwicklungen zur KI-gestützten Entscheidungsunterstützung in der Automobilmontage. 171
Andreas Schoch, Sebastian Beckschulte, Robert Refflinghaus, und Robert H. Schmitt

1 Einleitung 172
2 Stand der Forschung 173
3 KI-gestützte Entscheidungsunterstützung in der Automobilmontage am Beispiel der Dichtheitsprüfung 178
4 Herausforderungen bei der Implementierung von KI-gestützten Empfehlungssystemen in der Produktion 184
5 Zusammenfassung und Ausblick 185
Literatur. 186

Anwendung von KI zur automatischen Segmentierung von Schweißnähten im Wire Arc Additive Manufacturing	189
Minh Thanh Vu, Frank Segel, und Sophie Gröger	
1 Einleitung	190
2 Stand der Technik	190
3 Segmentierung von Schweißnähten	195
4 Ermittlung der merkmalsbasierten Parameter	200
5 Zusammenfassung und Ausblick	205
Literatur	205
Systematische Entwicklung eines smarten Fehlermanagementsystems in der Produktion für KMU	209
Turgut Refik Caglar, Elena Andrushchenko, Lennart Müller-Stein, und Roland Jochem	
1 Einleitung	210
2 Bedarfsanalyse für produzierende KMU	211
3 Stand der Technik	213
4 Systematische Entwicklung des smarten Fehlermanagementsystems ...	217
5 Fazit	225
Literatur	226
NLP-gestützte Reklamationsanalyse zur effizienten Ermittlung von Haftungsverantwortlichkeiten	231
Insa Lemke und Nadine Schlüter	
1 Einleitung	232
2 Stand der Technik und Herausforderungen in der Reklamationsbearbeitung	232
3 Grundlagen für die Entwicklung	234
4 Technische Umsetzung des AIGeWert-Algorithmus	239
5 Diskussion	245
6 Fazit und Ausblick	246
Literatur	247
KI-basierte (IVD-)Medizinprodukte – Neue gesetzliche Anforderungen an das Qualitäts- und Risikomanagement im Zusammenspiel der MDR/IVDR und des EU AI Acts	249
Ozan Aykurt, Pauline Kaufmann, Folker Spitzenberger, und Wen-Huan Wang	
1 Einleitung	250
2 Materialien und Methodik	251
3 Anforderungen an ein QMS für KI-basierte Medizinprodukte	252
4 Anforderungen an ein RMS für KI-basierte Medizinprodukte	256
5 Entwicklung und Umsetzung eines regulatorischen Konzepts für ein QMS und RMS im Zusammenspiel der MDR/IVDR und des EU AI Acts	261
6 Zusammenfassung und Ausblick	265
7 Abkürzungen	266
Literatur	267

Einflussbasierte Klassifizierung technischer Risiken in der frühen Phase der Produktentwicklung 269
 Ghislain Davy Nganso Yanghu , Konrad Walder, und Ralf Woll

1 Einleitung 270
 2 Anforderungen an den Ansatz. 271
 3 Vorgehensweise des Ansatzes 272
 4 Praktische Anwendung 280
 5 Zusammenfassung. 284
 Literatur. 289

Virtuelle Produktentwicklung von Bekleidung – Potentiale und Herausforderungen. 293
 Ulrike Reinhardt

1 Einleitung 294
 2 Produktentwicklungsprozess in der Bekleidungswirtschaft. 295
 3 Digitaler Produktentwicklungsprozess und virtuelle Passformanalyse mittels 3D-Simulation 299
 4 Fazit und Ausblick 308
 Literatur. 309

Remote-Workshops vs. klassische Workshops – Ein Konzept zur Ermittlung und Steigerung des Qualitatsgrades und der Kreativitat 313
 Alina Marquet, Sumona Sen, Christoph Szedlak, Patrick Potters, und Bert Leyendecker

1 Einleitung und Hintergrund 314
 2 Literaturanalyse und Stand der Forschung 316
 3 Konzept und Vorgehensweise 318
 4 Fazit und Ausblick 322
 Literatur. 323



Quality Intelligence – Wege zur Entwicklung eines intelligenten Qualitätsmanagements in der Produktion

Marcos Padrón Hinrichs¹  , Nils Klasen¹ , Tobias Schulze¹ ,
Felix Sohnius¹ , und Robert H. Schmitt^{1,2} 

¹ Werkzeugmaschinenlabor WZL der RWTH Aachen University, Aachen, Deutschland

marcos.padron@wzl-iqs.rwth-aachen.de

² Fraunhofer Institut für Produktionstechnologie IPT, Aachen, Deutschland

Zusammenfassung. Die zunehmende Verfügbarkeit von Daten und die fortschreitende Entwicklung von Technologien ebnen den Weg für fortschrittliche Methoden der Datenanalyse, mitunter der künstlichen Intelligenz (KI). Welche neuen Möglichkeiten bieten diese Entwicklungen für das Qualitätsmanagement und das vollumfängliche Ausschöpfen des vorliegenden Datenpotentials? Ziel dieses Beitrags ist es, die historische Entwicklung des Qualitätsmanagements darzustellen und zukünftige Entwicklungsrichtungen aufzuzeigen. Basierend auf dem Aachener Qualitätsmanagement-Modell (ACQMM) als Rahmenwerk und der Infrastruktur des Internet of Production (IoP) werden neue Wege für ein intelligentes und handlungsorientiertes Qualitätsmanagement vorgeschlagen, die durch strukturiertes Fehlerdatenmanagement entlang des Produktlebenszyklus unterstützt werden. Es wird ein Einblick in das Potential eines prädiktiven Qualitätsmanagements zur Steigerung der Resilienz in produzierenden Unternehmen gegeben. Hierzu gehören Methoden der prädiktiven Qualität in Kombination mit erklärbarer KI für eine kosteneffiziente und verbesserte Prozesssteuerung. Des Weiteren wird ein Ansatz vorgestellt, um den Aufwand der Datenbereitstellung, -aufbereitung und der Modellbildung zu reduzieren. Das ACQMM bietet dabei einen Rahmen zur Definition, Steuerung und Umsetzung dieser Anwendungen, unter Berücksichtigung der Anforderungen relevanter Interessengruppen.

Schlüsselwörter: Quality Intelligence · Aachener Qualitätsmanagement-Modell · Internet of Production · Künstliche Intelligenz · Predictive Quality · Quality Diagnosis · Quality Transfer

1 Einleitung

Die durch die technologische Entwicklung vorangetriebene Digitalisierung und die Entwicklungen auf dem Gebiet der künstlichen Intelligenz (KI) haben neue Möglichkeiten für industrielle Anwendungen eröffnet. Mit dem Aufkommen von Industrie 4.0 und der Entwicklung hin zu einer resilienteren Industrie 5.0, rücken neue Paradigmen für die Produktion stärker in den Mittelpunkt dieser dynamischen Veränderungen [1]. Angesichts dessen positioniert sich das Qualitätsmanagement als zentrale Funktion zur Sicherstellung der Erfüllung von Anforderungen bestehender und neuer Interessengruppen in Unternehmen [2]. Um die zukünftige Entwicklung des Qualitätsmanagements im Kontext von KI und digital getriebenen Datenmodellen zu beleuchten, wird ein Rückblick auf die historische Entwicklung des Qualitätsmanagements gegeben. Die Bedeutung eines Ordnungsrahmens für qualitätsrelevanten Aktivitäten in Unternehmen zur Anpassung an dynamische Bedingungen und zukünftige Entwicklungen wird anschließend anhand des *Aachener Qualitätsmanagement-Modells* (ACQMM) dargestellt. Die Vision des *Internet of Production* (IoP) ergänzt diesen Rahmen als Dateninfrastruktur für die Entwicklung fortschrittlicher Datenanwendungen. Auf dieser Basis werden Entwicklungsmöglichkeiten für ein intelligentes Qualitätsmanagement aus einer methodischen Perspektive anhand eines Beispiels für eine Datenanalyseanwendung in der Produktion aufgezeigt. Abschließend werden mögliche zukünftige Entwicklungsrichtungen für qualitätsbezogenen KI-Anwendungen dargelegt.

2 Historische Entwicklung des Qualitätsmanagements in produzierenden Unternehmen

Im Laufe der Zeit hat sich das Qualitätsmanagement kontinuierlich weiterentwickelt, um den Anforderungen des sich wandelnden Produktionsumfelds gerecht zu werden. In diesem Zusammenhang ist die Entwicklung des Qualitätsmanagements eng mit dem stetigen Fortschreiten der Industrialisierung verbunden [3, 4]. Mit der Mechanisierung der Produktion und dem Aufkommen der Massen- und Fließbandfertigung zu Beginn des 20. Jahrhunderts prägten reaktive Ansätze zur Prüfung und Aussortierung von fehlerhaften Bauteilen das industrielle Qualitätsverständnis [3]. Die Einführung der Qualitätssteuerung basierend auf statistischen Modellen in den 1920er Jahren unterstreicht die Bedeutung von Daten für das Qualitätsmanagement in den frühen industriellen Phasen. Diese Entwicklung hat den Wechsel von einem rein reaktiven zu einem steuernden Qualitätsansatz vorangetrieben. [5, 6]

Zu Beginn der 1950er Jahre gewannen präventive Ansätze des Qualitätsmanagements an Bedeutung, die auf die Vermeidung von Kosten in den früheren Phasen der Produktentstehung abzielten [3]. Parallel dazu wurde ein systematisches Vorgehen als Basiswerkzeug zur kontinuierlichen Verbesserung in Prozessen entwickelt, welches als Deming- oder *Plan-Do-Check-Act-Zyklus* (PDCA) bekannt ist [5]. Der Begriff Total Quality Management (TQM) prägte in den 1980er Jahren das Verständnis eines ganzheitlichen und integrativen Qualitätsmanagementkonzeptes als Aufgabe aller Bereiche und Mitarbeitenden im Unternehmen [7]. Jahre später führte Motorola

die Six Sigma-Methode und den ihr zugrunde liegenden systematischen Ansatz *Define-Measure-Analyze-Improve-Control* (DMAIC) ein, um die Produkt- und Servicequalität zu verbessern und die Kundenzufriedenheit zu erhöhen [8].

Unter dem Begriff *Industrie 4.0* wurde erstmals im Jahre 2011 eine digitalisierungsgetriebene Vision der Bundesregierung für den Industriestandort Deutschland vorgestellt [7]. Durch die Vernetzung eingebetteter Systeme in der Produktion ergeben sich für das Qualitätsmanagement neue Herausforderungen und Potenziale [3]. Der technologische Fortschritt erfordert und ermöglicht die Erweiterung bestehender Qualitätsmanagementmethoden in produzierenden Unternehmen, um Daten mit fortschrittlichen Ansätzen, mitunter aus dem Bereich der KI, zu analysieren. Prädiktive Analysen ermöglichen es, Ereignisse oder Werte mit einer Eintrittswahrscheinlichkeiten vorherzusagen, während präskriptive Analysen es ermöglichen, auf der Grundlage der daraus folgenden Erkenntnisse automatisch Entscheidungen und Maßnahmen abzuleiten. [9] Letzteres ermöglicht die autonome Reaktion auf Veränderungen und Störungen im Produktionsumfeld und kann somit maßgeblich zur Entwicklung einer höheren Resilienz beitragen. Die Entwicklung der Qualität im Laufe der Zeit hin zu einem zukunftsorientierten und resilienten Qualitätsmanagement ist in Abb. 1 zusammengefasst.

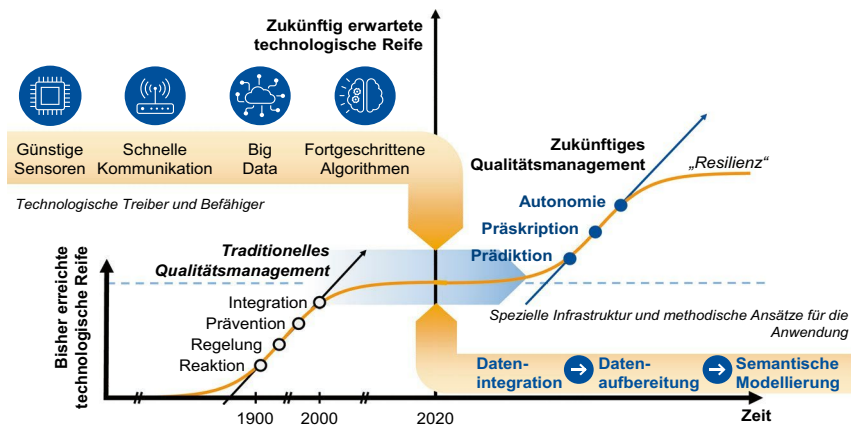


Abb. 1. Evolution der Qualität in produzierenden Unternehmen [10].

3 Das Aachener Qualitätsmanagement-Modell zur Ausrichtung der qualitätsrelevanten Informationsflüsse und Aktivitäten in Unternehmen

Die historische Entwicklung des Qualitätsmanagements hat die Notwendigkeit aufgezeigt, einen ganzheitlichen und datenbasierten Ansatz zur Sicherung der Qualität in Unternehmen zu verfolgen. Zur systematischen Ausrichtung der organisatorischen Strukturen anhand eines Ordnungsrahmens wurde das *Aachener Qualitätsmanagement-Modell*

(ACQMM) entwickelt. Das Modell verfolgt das Ziel, die qualitätsbezogenen Aufgaben in einem Unternehmen aus den drei Perspektiven des Marktes, des operativen Betriebes und der Unternehmensführung darzustellen. Die hieraus hervorgehende Definition der unternehmerischen Qualität beschreibt diese als den „Überdeckungsgrad von Marktanforderungen (Marktperspektive), Unternehmensausrichtung (Führungsperspektive) und Unternehmensfähigkeiten (Betriebsperspektive)“. [3]

Angesichts der zunehmenden Digitalisierung und der damit verbundenen Datenverfügbarkeit kann das ACQMM zur ganzheitlichen und wettbewerbsorientierten Erfassung, Verwaltung und Nutzung von qualitätsrelevanten Informationen sowie zur Anpassung der Aktivitäten bei sich ändernden Anforderungen und Rahmenbedingungen genutzt werden. Im multidimensionalen Qualitätsverständnis reichen diese Anforderungen von der reinen Erfüllung funktionaler Produktspezifikationen über die subjektive Kundenwahrnehmung bis hin zu Kriterien der Nachhaltigkeit. [2]

Aus der zuerst genannten Perspektive wird der Markt als der Ausgangspunkt aller qualitätsbezogenen Aktivitäten betrachtet. Der Markt unterliegt dem Wandel der Zeit, sodass an Ausgangs- und Endpunkt der Unternehmensleistung unterschiedliche Märkte vorliegen. In diesem Kontext wird unter dem Begriff des Markts die Gesamtheit aller Interessengruppen verstanden, die an einer Leistungserbringung des Unternehmens interessiert sind. Die Marktperspektive fokussiert daher auf die Produktqualität als den Grad, in dem die Spezifikationen der Unternehmensleistung und die Marktanforderungen abgedeckt werden. Aus dieser Perspektive sind die unternehmensinternen Abläufe auf die Schnittstellen zum Markt möglichst effektiv und effizient abzustimmen. Die Gestaltung und Weiterentwicklung dieser Abläufe, der Unternehmensausrichtung und der Unternehmensfähigkeiten erfordert die Einnahme der Führungsperspektive. Die Führungsperspektive stellt die Systemqualität in den Mittelpunkt. Zur Unterstützung und Umsetzung der qualitätsschöpfenden Prozesse und Abläufe bedarf es Unterstützungsleistungen in Form von Ressourcen und Diensten. Aus der Betriebsperspektive werden die Umsetzung der von der Führungsperspektive definierten Ziele und die dazu erforderlichen Prozesse adressiert. Dabei liegt der Fokus auf der Prozessqualität. [3]

Im Verständnis des Modells wird die Aufnahme von am Markt gebildeten Forderungen an Produkte oder Leistungen durch alle qualitätsschöpfenden Prozesse und Aktivitäten der Leistungserbringung eines Unternehmens bewirkt. Dieses Element wird mit dem Begriff *Quality Stream*, in dem die Gesamtheit aller unmittelbar qualitätsschöpfenden Aktivitäten und Qualitätsbeiträge gebündelt werden, bezeichnet. Die Aktivitäten, denen das Qualitätsmanagement Rechnung tragen muss, reichen von der Produktentwicklung über die Fertigung, und die Auftragsabwicklung bis hin zu allen nachgelagerten Vertriebsaktivitäten eines Unternehmens. Innerhalb des *Quality Streams* umfasst eine *Quality Forward Chain* sämtliche unmittelbar qualitätsschöpfenden Prozesse zur Erbringung einer materiellen oder immateriellen Leistung sowie alle Aktivitäten, Werkzeuge und Methoden zur präventiven und reaktiven Gestaltung der Qualität einer Unternehmensleistung. Diese Leistungen werden nicht als Materialfluss verstanden, sondern als Träger von Eigenschaften, die auf die Kundenzufriedenheit und damit auf die Qualitätswahrnehmung abzielen. Als Element der Informationsrückkopplung im *Quality Stream* dient die *Quality Backward Chain* als

ständiges Überwachungselement zwischen dem gewünschten Zustand einer Unternehmensleistung in Bezug auf Anforderungsänderungen entlang der Lebenszyklen. Die *Quality Backward Chain* beinhaltet rückwärtsgerichtete Qualitätsdaten und -informationen, einschließlich Bewertungen der am Markt abgesetzten Leistungen sowie Erkenntnisse über Fehler und Risiken in Produktions- oder Nutzungsphasen. [3] Das ACQMM und seine Elemente sind in Abb. 2 dargestellt.

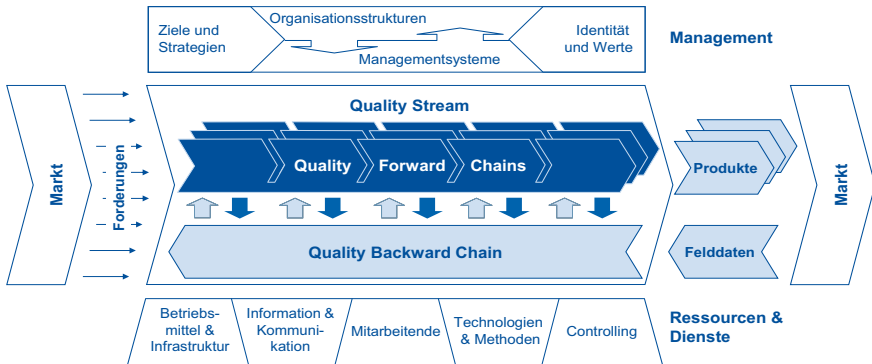


Abb. 2. Das Aachener Qualitätsmanagement-Modell (ACQMM) [3].

4 Das Internet of Production als Befähiger eines intelligenten Qualitätsmanagements

Moderne Produktionsprozesse zeichnen sich durch ein erhöhtes Ausmaß an Datenverfügbarkeit und Informationsflüssen aus. Gleichzeitig liegen diese Daten vielerorts in voneinander isolierten Datensilos vor. Innerhalb der Domänen der einzelnen Silos werden spezialisierte Datenmodelle entwickelt und zur Anwendung gebracht. Aus diesen Gegebenheiten resultiert die Notwendigkeit, eine uneingeschränkte domänenübergreifende Zugänglichkeit, Interpretierbarkeit und Vernetzung von Daten und Modellen zu ermöglichen. Die Vision des *Internet of Production*¹ (IoP) beschreibt einen technischen Implementierungsansatz zur Erschließung und Verwertung lebenszyklusübergreifender Daten produzierender Unternehmen zur Befähigung der domänenübergreifenden Kollaboration. [12]

Das IoP umfasst in horizontaler Richtung den Produktlebenszyklus von dem Entwicklungszyklus über den Produktionszyklus bis hin zum Nutzungszyklus. In vertikaler Richtung besteht das IoP aus vier Ebenen: *Rohdaten* und *Applikationssoftware* für

¹ Das Exzellenzcluster Internet of Production (IoP) wird durch die Deutsche Forschungsgemeinschaft (DFG) im Rahmen der Exzellenzstrategie des Bundes und der Länder gefördert – EXC-2023 Internet of Production – 390.621.612 [11].

die Datenbereitstellung und den Datenzugriff, *Middleware+* für das Management des Datenzugriffs, *Smart Data* für die datenbefähigte Wissensgenerierung, und *Smart Expert* für die anschließende Nutzung des gewonnenen Wissens. [12] Die Infrastruktur des IoP ist in Abb. 3 dargestellt.

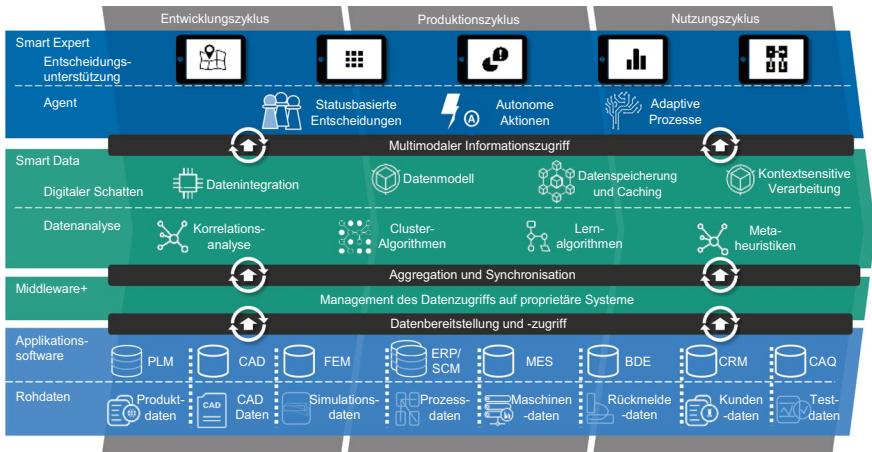


Abb. 3. Infrastruktur des Internet of Production (IoP) [12].

Die Infrastruktur des IoP schafft eine Datendurchgängigkeit entlang des *Quality Streams*, die kürzere Rückkopplungsschleifen innerhalb der *Quality Forward* und *Backward Chains* ermöglicht. Die kürzeren Rückkopplungsschleifen resultieren aus der Anwendung prädiktiver Analysen, befähigt durch die verbesserte Datenverfügbarkeit. Diese Datenverfügbarkeit unterstützt die Datenanalyse auf der *Smart Data* Ebene, welche als Entscheidungsunterstützung für die *Smart Expert* Ebene dienen.

Die Aufgabe eines zukunfts-fähigen und intelligenten Qualitätsmanagements ist es, die Anforderungen und Kriterien der Interessengruppen eines Unternehmens in quantifizierbare Ziele und Indikatoren zu übersetzen, um diese mit datengetriebenen Methoden zu verknüpfen [2]. Vernetzte Ressourcen erzeugen Daten, die durch Aggregation, Auswertung, Interpretation und Kontextualisierung in Informationen und Wissen zu Handlungsoptionen und konkreten Maßnahmen umgewandelt werden. Diese Verknüpfung unter dem Begriff der Intelligenz, sowohl im Sinne von Aufklärung als auch ähnlich den menschlichen Fähigkeiten, fördert den Wandel von Qualitätssicherungs- und -verbesserungsaktivitäten in der Produktion hin zu *Quality Intelligence*. Darunter wird die Schaffung von Transparenz über alle qualitätsrelevanten Zusammenhänge durch intelligente Werkzeuge verstanden. Auf technologischer Ebene werden intelligente Werkzeuge durch Methoden der KI gestützt.

5 Potenziale der künstlichen Intelligenz für effizientere Qualitätsschleifen in der Produktion

Historisch gesehen folgt das Qualitätsmanagement einem Prozess der systematischen kontinuierlichen Verbesserung, in dessen Verlauf zahlreiche Methoden entwickelt wurden. Einige dieser Methoden stoßen an ihre Grenzen, wenn es darum geht, die Komplexität moderner Produktionsprozesse abzubilden und effizientere Qualitätsschleifen zu unterstützen. Insbesondere in den frühen Phasen eines Produktionssystems stehen weniger empirische Daten über das Systemverhalten eines Produktionssystems zur Verfügung, die für die Qualitätssicherung und -verbesserung genutzt werden können. [13] Eine Auswahl an klassischen Methoden zur Unterstützung des Qualitätsmanagements von der Entwicklung bis zur Serienproduktion sowie mögliche Qualitätsschleifen entlang der Produkt- und Produktionssystemlebensphasen sind in Abb. 4 dargestellt.

Die dargestellten Qualitätsschleifen können durch Methoden aus dem Bereich der KI unterstützt und verkürzt werden, um genauere Vorhersagemodelle zu erstellen, die eine Antizipation von Maßnahmen sowie Ursachenanalysen ermöglichen. Mit zunehmender Datenverfügbarkeit, befähigt durch das IoP, bieten datenbasierte Modelle das Potenzial, Ereignissen systematisch vorzugreifen und prädiktiv und präskriptiv zu steuern. Zudem bieten KI-Methoden Möglichkeiten, die begrenzte Datenverfügbarkeit in frühen Phasen, aber auch in späteren Phasen eines Produktionsprozesses zu nutzen [14].

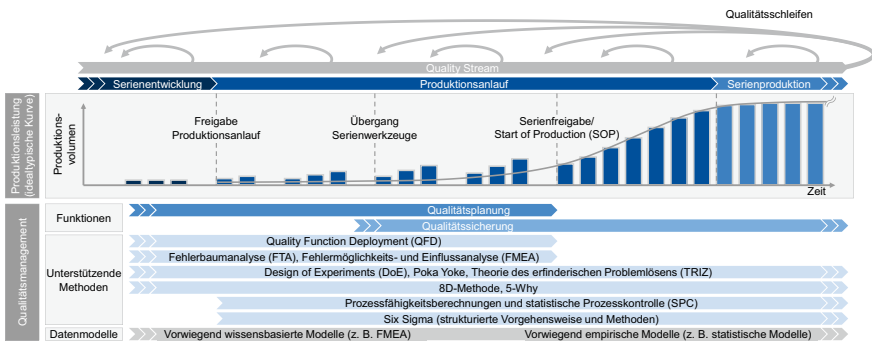


Abb. 4. Auswahl an klassischen Methoden des Qualitätsmanagements entlang der Produkt- und Produktionssystemlebensphasen in Anlehnung an [13].

Trotz der Vorteile fortschrittlicher Datenanalysemethoden in der Produktionsumgebung wird ihr volles Potenzial häufig nicht ausgeschöpft. Besonders bei der Unterstützung der Entscheidungsfindung zur Ableitung von Maßnahmen gibt es noch ungenutzte Möglichkeiten. [15] Das Fehlermanagement als systematischer Ansatz, der eine Reihe von Aufgaben zur Identifizierung, Korrektur und Maßnahmen zur nachhaltigen Verhinderung und Vermeidung sowie Minderung von internen und externen Fehlern im Produktionsumfeld verstanden wird, kann als Rahmen für die

gezielte Nutzung von KI zur Verbesserung von Prozessen dienen [16]. Der folgende Anwendungsfall veranschaulicht die Verwendung von prädiktiven Modellen zur Vorhersage der Qualität in einem Produktionsprozess. Anschließend werden Analysen durchgeführt, um die Ursachen auftretender Produktfehler auf der Grundlage des Modells zu ermitteln. Das gezeigte Beispiel soll verdeutlichen, wie lokale Qualitätsschleifen entlang des *Quality Streams* die Prozessqualität vorausschauend und diagnostisch verbessern können.

6 Predictive Quality und Quality Diagnosis am Beispiel eines Blisterverpackungsprozesses

In dem folgenden Beispiel wird ein realer Prozess für die Verpackung von Haushaltsartikeln mittels einer Blistermaschine betrachtet. Der Prozess beginnt mit dem Erhitzen eines Kunststoffes, der anschließend über eine produktabhängige Form gestreckt wird. Im abgekühlten Zustand dient diese Kunststoffhaube als Träger für den Artikel. Das zu verpackende Produkt wird eingelegt und durch einen Blister versiegelt. Die fertige Blisterpackung wird ausgeschnitten und für den Versand vorbereitet. Die Maschine hat eine Taktung von etwa 20 Blistern pro Minute. Um sicherzustellen, dass keine unvollständig verschlossenen Verpackungen in den Versand gehen, unterliegen alle Produkte im Anschluss an die Verblisterung einer Sichtprüfung. Hierbei beobachtet ein Mitarbeiter die von der Maschine ausgegebenen Produkte und greift im Falle einer Qualitätsabweichung ein. Historische Daten zeigen, dass etwa 2 % der Produkte den Verpackungsprozess fehlerbehaftet verlassen und nachgearbeitet werden müssen. Die häufigsten Fehlerbilder sind eine unvollständige Versiegelung des oberen Materials sowie fehlerhaft positionierte Produkte im Blister. Bisher konnten keine prozesseitigen Gründe für die auftretenden Fehler identifiziert werden.

Im Rahmen eines Pilotprojekts werden verfügbare Maschinendaten genutzt, um die bestehenden händische Qualitätskontrollen durch präventive Maßnahmen zu ersetzen. Hierbei kommen Modelle aus dem Bereich der KI zum Einsatz, die es ermöglichen, Aussagen über die Qualitätsmerkmale der Produkte basierend auf Prozessinformationen zu treffen. Des Weiteren wird untersucht, inwiefern durch Algorithmen aus dem Bereich der erklärbaren KI (engl. *Explainable AI*) Fehlerursachen im Prozess aufgedeckt werden können. Die ermittelten Ursachen sollen genutzt werden, um den Prozess dauerhaft zu optimieren und den initialen Ausschuss von 2 % zu reduzieren.

Vorgelagert an die Modellbildung wurden die Maschinendaten aufgenommen und aufbereitet. Über eine OPC-UA Schnittstelle werden die zeitlich aufgelösten Informationen zu Position und Geschwindigkeit der Stanze (Trennvorgang des fertig verschlossenen Blisters), das Drehmoment des Stanzmotors, ein Zählwert der bei jedem Stanzzyklus inkrementiert wird sowie ein dazugehöriger Zeitstempel empfangen (siehe Abb. 5). Des Weiteren ist für historische Produkte die Information vorhanden, ob die Blisterverpackungen in der Sichtkontrolle des zuständigen Mitarbeitenden einen Fehler aufgewiesen haben oder nicht. Beide dieser Informationsquellen (Maschinendaten sowie Qualitätsdaten) können über den jeweiligen Zeitstempel produktbezogen miteinander verknüpft werden.

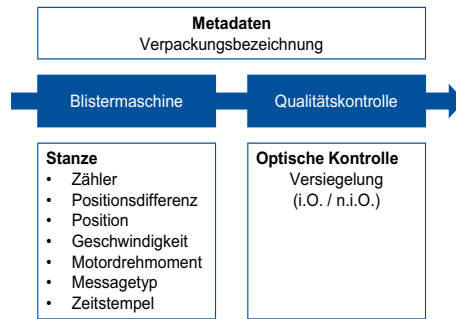


Abb. 5. Übersicht der Daten des Blisterverpackungsprozesses.

Insgesamt stehen zur Analyse 20.159 Datenpunkte von 994 Produkten zur Verfügung von denen 20 Produkte fehlerhaft verschlossen sind. Abb. 6a und Abb. 6b zeigen beispielhaft die zeitlichen Verläufe des Motordrehmoments und der Stanzgeschwindigkeit. Während das Drehmoment den Maximalwert beim Verschluss des Blisters aufweist, ist zu diesem Zeitpunkt die Geschwindigkeit der Stanze minimal. In Abb. 6c ist die Stanzposition (Winkel) über die Zeit dargestellt. Es ist erkennbar, dass sich die Stanze konstant mit der Zeit bewegt. Die Einfärbung der Punkte illustriert das steigendes und anschließend fallendes Motordrehmoment aus Abb. 6a.

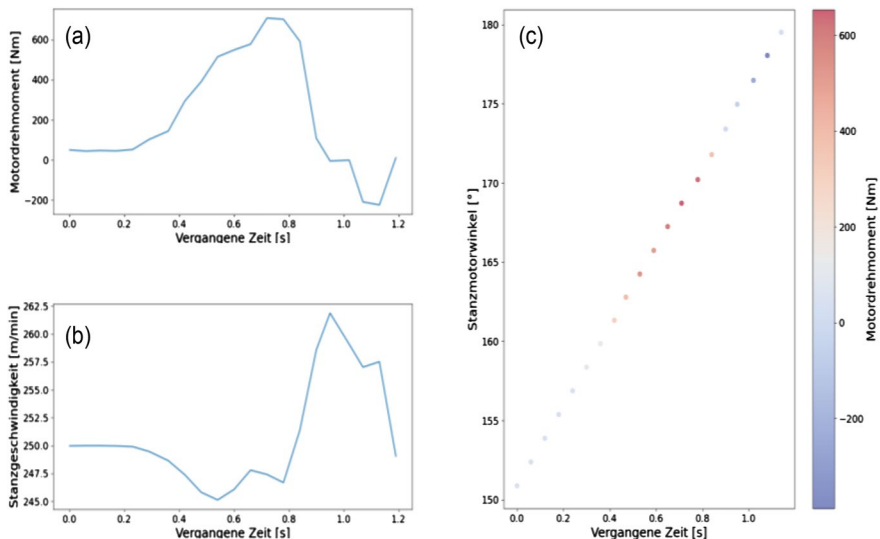


Abb. 6. Explorative Datenanalyse des Motordrehmoments und Stanzgeschwindigkeit der Blistermaschine.

6.1 Predictive Quality: Datenbasierte Vorhersagen zur Produkt- und Prozessqualität

Die gesammelten Daten der Blistermaschine wurden durch verschiedene Vorverarbeitungsprozesse gefiltert und bereinigt, um die Qualität der Datengrundlage sicherzustellen. Dazu gehört das Entfernen von Ausreißern und die Imputation fehlender Werte. Die Schritte sind entscheidend, um die Genauigkeit und Zuverlässigkeit der nachfolgenden Analyse und Modellbildung zu gewährleisten [17]. Um die Zeitreihendaten für das Training des Vorhersagemodells nutzbar zu machen, werden im Vorhinein Merkmale aus den Messreihen extrahiert [18]. Hierzu wird die öffentlich verfügbare Bibliothek *tsfresh*² genutzt, die Mittelwerte, Maximalwerte, Minimalwerte, Quantile und viele weitere Kennzahlen zu Verfügung stellt. Sowohl die Bereinigung des Datensatzes als auch die Extraktion von Merkmalen für das Modelltraining finden in der Schnittstelle von *Middleware+* zu der *Smart Data* Ebene des IoP statt (siehe Abb. 3).

Der vorbereitete Datensatz wird für das Training mehrerer Modelle des maschinellen Lernens innerhalb der *Smart Data* Ebene des IoP verwendet, um den Algorithmus mit der höchsten prädiktiven Genauigkeit zu bestimmen. Für die Vorhersage der Bauteilqualität wurden verschiedene Modelle trainiert: *Regression*, *K-Nearest Neighbors (KNN)*, *Entscheidungsbaum*, *Random Forests*, *Extremely Randomized Tree*, *Support Vector Machines (SVM)* und *Multilayer Perceptron (MLP)*. *Regression* modelliert Beziehungen zwischen abhängigen und unabhängigen Variablen und eignet sich hauptsächlich für lineare Zusammenhänge. *KNN* basiert auf Ähnlichkeitsmessungen, wobei die *K* nächsten Nachbarn zur Vorhersage herangezogen werden. *Entscheidungsbäume* teilen die Daten rekursiv basierend auf Attributwerten, sind jedoch anfällig für Überanpassung. *Random Forests* kombinieren mehrere Entscheidungsbäume und bieten Robustheit gegen Überanpassung durch Mittelung der Ergebnisse. Die *Extremely Randomized Trees* sind eine spezifische Variante der *Random Forests*, mit zusätzlicher Zufälligkeit in der Vernetzungsstruktur einzelner Bäume zur weiteren Stärke der Modellrobustheit. *SVMs* finden die optimale Trennlinie zwischen Klassen und sind effektiv bei hohen Dimensionalitäten und nicht-linearen Trennungen. *MLPs*, eine Art künstlicher neuronaler Netze, modellieren komplexe nicht-lineare Zusammenhänge und sind leistungsfähig bei Aufgaben mit hoher Datenkomplexität. [19]

Nach der Implementierung, dem Training und der Evaluierung dieser Modelle mit der Python-Bibliothek *scikit-learn*³ (sklearn) zeigt sich, dass die Modelle eine vergleichbare Güte bezüglich der Vorhersagegenauigkeit der Bauteilqualität aufweisen. Im Folgenden wird der trainierte Entscheidungsbaum genutzt, um auf Basis der verfügbaren Prozessinformationen Prognosen über die Bauteilqualität zu generieren.

Um das Modell in der laufenden Produktion anwendbar zu machen, wird eine Schnittstelle für den Maschinenbedienenden in Form eines Unterstützungssystems ge-

² <https://tsfresh.readthedocs.io>.

³ <https://scikit-learn.org/>

schaffen (*Smart Expert*, IoP). Das System (z. B. ein Dashboard) ist über eine API mit dem Backend (*Flask*⁴) verknüpft, das beim Eintreffen neuer Prozessdaten automatisch Prognosen für die Bauteilqualität durchführt. Bei Abweichungen der Qualitätsmerkmale vom Sollwert wird der Maschinenbedienende über ein Alarmsystem über die Abweichung informiert.

Im Vergleich zur herkömmlichen Qualitätskontrolle lässt sich anhand der Konfusionsmatrix (siehe Abb. 7) erkennen, dass das Vorhersagemodell keine Einbußen hinsichtlich der Qualitätsbewertung aufweist. Eine Verpackung wurde fälschlicherweise als nicht richtig verschlossen prädiziert. Diese Fälle können in der Realanwendung einer händischen Bewertung durch einen Mitarbeitenden unterzogen werden, sodass sie nicht zwangsläufig als Ausschuss deklariert werden. Übergeordnet ist festzustellen, dass die Anwendung des Vorhersagemodells im dargestellten Beispiel zielführend ist. Besonders bedeutend ist hierbei die Reduktion der manuellen Prüfaufwände.

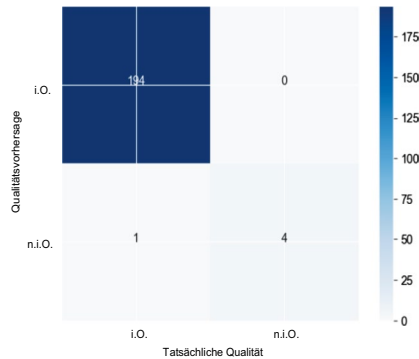


Abb. 7. Konfusionsmatrix des trainierten Vorhersagemodells (Entscheidungsbaum).

Die virtuelle Qualitätskontrolle ermöglicht die Verkürzung der Qualitätsschleifen entlang des *Quality Streams*. Da die Qualitätskontrollen nicht mehr an Mitarbeitende gebunden sind, sondern automatisiert auf Basis vorhandener Maschinendaten durchgeführt werden können, kann die Anzahl der Qualitätsschleifen signifikant erhöht werden. Dies führt zu einer schnelleren und kontinuierlicheren Überwachung der Produktionsqualität, wodurch Unregelmäßigkeiten schneller erkannt und behoben werden können.

⁴ <https://flask.palletsprojects.com/>

6.2 Quality Diagnosis: Ableitung diagnostischer Erkenntnisse aus Daten und Prozessmodellen

Die reine Vorhersage der Qualität ermöglicht ebenso wie physische Qualitätskontrollen kein Verständnis über die Ursache von Fehlern. Dieses ist allerdings essenziell, um Fehler abzustellen und somit die resultierende Qualität zu erhöhen. [20] Bisher geschieht dies im Rahmen der *Quality Backward Chain* mit traditionellen Methoden zur Ermittlung von Fehlerursachen wie beispielsweise dem 8D-Report. Diese Methoden unterstützen Fachexperten bei der systematischen Ursachenanalyse und Ableitung von Korrekturmaßnahmen. Gegebenenfalls ist hierfür eine gezielte Datenaufnahme erforderlich, die ebenso wie die Analyse selbst mit hohen personellen und zeitlichen Aufwänden verbunden ist.

Moderne Methoden der Datenanalyse für die Fehlerursachenanalyse zielen darauf ab, diese Aufwände durch die Strukturierung und Auswertung bestehender Daten zu reduzieren und Experten durch zusätzliche datenbasierte Erkenntnisse zu unterstützen. Ein Beispiel ist die Auswertung der für die Qualitätsvorhersage trainierten Modelle mit Methoden der erklärbaren KI. Von besonderem Interesse für die Qualitätsvorhersage sind die modell-agnostischen Methoden, da sie für verschiedene Arten von Modellen des maschinellen Lernens gleichartige Informationen liefern. Diese Methodeigenschaft ist von besonderer Bedeutung, um verschiedene Modelle miteinander zu vergleichen und somit den besten Modelltyp für den vorliegenden Prozess auszuwählen. [21] Die grundlegende Funktionsweise eines Großteils dieser Methoden ist die Folgende: Dem Modell werden gezielt modifizierte Eingangsdaten zur Verfügung gestellt, für die dieses anschließend Prognosen erstellt. Durch die statistische Auswertung dieser Prognosen können Aussagen über die vom Modell gelernten Zusammenhänge in den ursprünglichen Daten getätigt werden. Neben der Ermittlung der Stärke des generellen Einflusses jedes Prozessparameters auf die Qualitätsvorhersage ist es möglich aufzuzeigen, wie eine Veränderung seines Wertes die Vorhersage beeinflusst. [21, 22, 23, 24]

Der Entscheidungsbaum, der für die Analyse verwendet wurde, stützt sich hauptsächlich auf das maximale Motordrehmoment, um Vorhersagen zu treffen. In Abb. 8a ist der Einfluss der Eingangsgrößen auf die Prognose des Modells abgebildet. Längere Balken entsprechen einem größeren Einfluss. Die genauen Werte der Wichtigkeit sind dabei nicht entscheidend.

Wenn das Motordrehmoment über etwa 540 Nm liegt, geht das Modell davon aus, dass die Verpackung korrekt verschlossen ist. Liegt es jedoch unter diesem Wert, nimmt das Modell an, dass es ein Problem mit der Versiegelung gibt (siehe Abb. 8b).

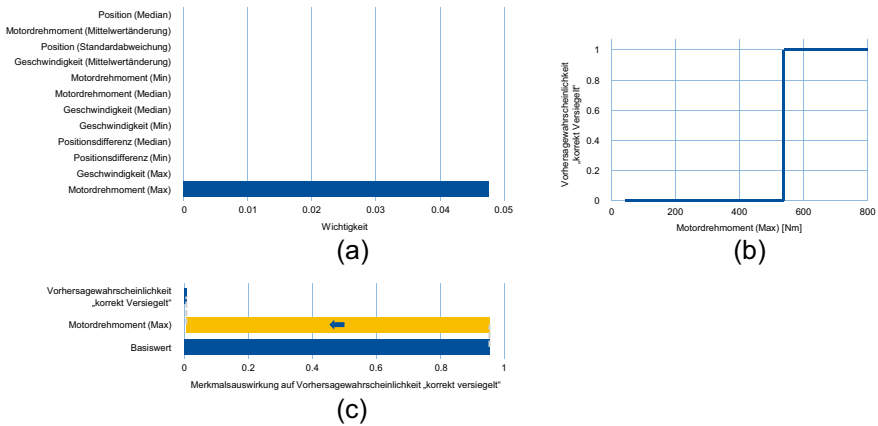


Abb. 8. Anwendung der erklärbaren KI auf den Entscheidungsbaum.

Die lokalen Methoden der erklärbaren KI helfen dabei zu verstehen, wie das Modell in einem bestimmten Fall zu seiner Vorhersage kommt [23, 24]. In diesem Fall geht es darum vorherzusagen, ob die Versiegelung einer einzelnen Verpackung korrekt ist.

Bei einer beispielhaften Verpackung, die fehlerhaft versiegelt ist und bei der das Qualitätsvorhersagemodell eine Wahrscheinlichkeit von 0 für eine korrekte Versiegelung angibt, zeigt sich, dass das maximal gemessene Motordrehmoment von 513 Nm ausschlaggebend für die Vorhersage war. Die Werte der anderen Eingangsgrößen hatten keinen Einfluss auf die Vorhersage (Abb. 8c). Der Einfluss der einzelnen Eingangsgrößen wird dabei vom Basiswert ausgehend dargestellt, der den Mittelwert der Wahrscheinlichkeit für eine korrekt versiegelte Packung über alle Verpackungen hinweg repräsentiert. Anschließend werden vorzeichenbehaftet die Auswirkungen der einzelnen Merkmale addiert. So ergibt sich abschließend die Prognose des Modells.

In einfachen Anwendungsfällen wie dem vorliegenden Beispiel können Entscheidungsbäume leicht ausgewertet werden, ohne dass die Verwendung erklärbarer KI erforderlich ist. Wird das Problem jedoch komplexer, kann der Entscheidungsbaum schnell unübersichtlich werden und ist dann nicht mehr ohne weiteres interpretierbar. [24]

Zu Demonstrationszwecken wurde mit dem Extremely Randomized Tree ein weiteres Vorhersagemodell auf dem gleichen Datensatz trainiert. Dieses Modell weist im vorliegenden Anwendungsfall dieselbe Modellgüte wie der Entscheidungsbaum auf. Die Anwendung von erklärbarer KI zeigt jedoch, dass dieses Modell grundlegend andere Charakteristika der Daten für seine Prognosen heranzieht.

Konkret sind das Minimum der Positionsdifferenz und in geringerem Maße das Minimum des Motordrehmoments (Abb. 9a). Laut der Auswertung des Modells trägt eine minimale Positionsdifferenz von unter $-0,122$ mm stark zu einer Vorhersage als ein korrekt verschlossener Blister bei (Abb. 9c). Ein minimales Motordrehmoment von über 31 Nm hat ebenfalls einen Einfluss, aber dieser ist deutlich schwächer (Abb. 9d).

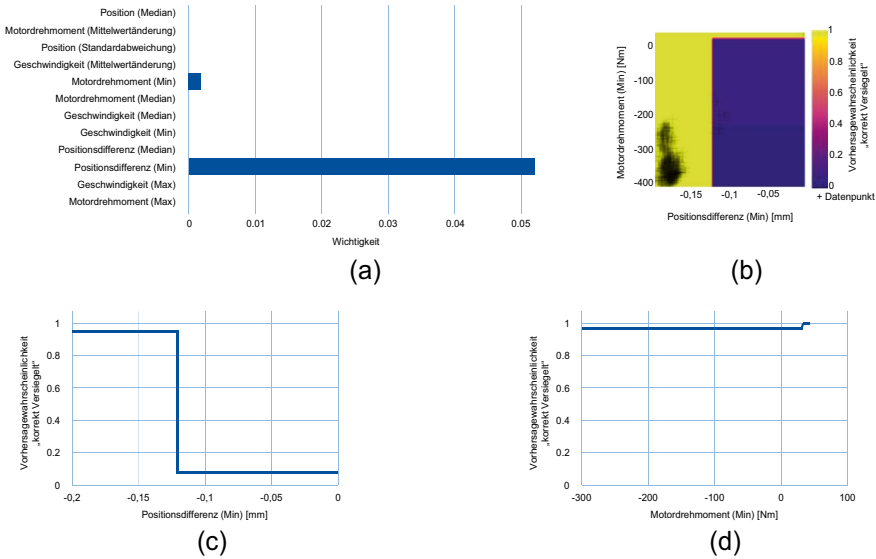


Abb. 9. Anwendung der erklärbaren KI auf das trainierte Extremely Randomized Tree Vorhersagemodell.

Einige Methoden der erklärbaren KI wie beispielsweise die *Accumulated Local Effects* ermöglichen es, den Einfluss von Wechselwirkungen zwischen mehreren Eingangsgrößen auf die Modellvorhersage zu betrachten [22, 24]. Bei dem auf *Extremely Randomized Trees* basierten Vorhersagemodell zeigt sich, dass für niedrige Minima der Positionsdifferenz die Vorhersage generell auf einen korrekt versiegelten Blister hinausläuft. Das gilt auch, wenn der Wert des minimalen Motordrehmoments nicht negativ ist. In allen anderen Fällen prognostiziert das Qualitätsvorhersagemodell einen fehlerhaft verschlossenen Blister (siehe Abb. 9b). Auf Grundlage von Expertenwissen über den untersuchten Prozess kann das aus physikalischer Sicht passendste Modell ausgewählt werden.

Die Informationen, die durch erklärbare KI gewonnen werden, sind besonders hilfreich für eine effizientere Fehlerursachenanalyse, wenn bisher unbekannte Zusammenhänge zwischen den Prozessparametern und dem vorhergesagten Qualitätsmerkmal identifiziert werden. Dadurch können aufwendige Datenerhebungen teilweise entfallen. Sobald die Fehlerursachen gefunden sind, können Maßnahmen abgeleitet werden, um den Prozess nachhaltig zu verbessern.

6.3 Quality Transfer: Übertragung qualitätsrelevanter Erkenntnisse auf andere Produkte und Prozesse

In den vorherigen Kapiteln wurde im Rahmen des Anwendungsbeispiels gezeigt, wie physische Qualitätskontrollen durch KI-Modelle unterstützt werden. Des Weiteren wurde das darauf aufbauende Potential von Methoden der erklärbaren KI dargestellt.

Aus betriebswirtschaftlicher Sicht eines Unternehmens ist der Einsatz solcher Methoden nur dann gewinnbringend, wenn der Aufwand der Datenbereitstellung, -aufbereitung und der Modellbildung den der physischen Qualitätskontrollen unterschreitet. Dies ist besonders bei variantenvielfältiger Produktion häufig nicht der Fall. Da ein trainiertes Vorhersagemodell ausschließlich innerhalb der Datendomäne, in der es trainiert wurde, aussagekräftig ist, führen bereits leichte Anpassungen an dem Produkt oder Prozess zur Ungültigkeit. In diesem Falle ist ein Neutraining des Modelles nötig. Die hierfür benötigten Trainingsdaten müssen dem Prozess durch physische Qualitätskontrollen entnommen werden.

Um den Aufwand der physischen Qualitätskontrollen bei wechselnder Produkt- oder Prozessdomäne zu senken, kommen Methoden des Transfer Learning zum Einsatz. Transfer Learning ermöglicht die Wiederverwendung eines vortrainierten Modells für eine neue, aber verwandte Aufgabe. Dies reduziert den Datenbedarf und die Zeit für das Nachtrainieren der Modelle erheblich, da bereits vorhandenes Prozess- bzw. Produktwissen genutzt wird [25]. Im Fall einer variantenreichen Produktion können vortrainierte Modelle auf ähnliche Prozesse oder Produkte angewendet und durch spezifisches Fine-Tuning an die neuen Anforderungen angepasst werden. Die Notwendigkeit bei wechselnder Domäne Modelle von Grund auf neu zu erstellen entfällt. Dieser Aspekt bietet ein großes Einsparungspotential bei der Datenbeschaffung und -aufbereitung. Durch die Wiederverwendung eines vortrainierten Modells und das Anwendungsfallabhängige Fine-Tuning kann die Zeit zur prozessübergreifenden Entwicklung eines neuen prädiktiven Modells erheblich verkürzt werden [26]. Zudem steigert bereits bei Verwendung trivialer Transfermethoden die Wiederverwendung erlernter Zusammenhänge aus vergleichbaren Anwendungsfällen die Modellgenauigkeit [27]. Modelle, die durch Transfer Learning entwickelt wurden, profitieren von den generalisierten Merkmalen des ursprünglichen Modells, was zu einer höheren Genauigkeit und Zuverlässigkeit bei der Vorhersage der Bauteilqualität führt [28]. Durch die Reduktion des Datenbedarfs und die Beschleunigung der Modellentwicklung werden die Kosten für die Implementierung und Wartung von Modellen des maschinellen Lernens erheblich reduziert.

7 Zusammenfassung und Ausblick

Das Qualitätsmanagement ist von jeher an die industrielle und technologische Entwicklung gebunden. Mit dem Aufkommen von KI-gestützten Technologien eröffnen sich neue Möglichkeiten für das Qualitätsmanagement. Die zunehmende Datenverfügbarkeit unterstützt fortgeschrittene Analyse zur Vorhersage von Qualitätsmerkmalen und zur Definition von Handlungsmaßnahmen auf der Grundlage von Modellen.

Das *Aachener Qualitätsmanagement-Modell* kann als Ordnungsrahmen zur Ausrichtung von Unternehmenseinheiten und qualitätsrelevanten Aktivitäten auf die Anforderungen von Interessengruppen von Unternehmen instrumentalisiert werden. Es kann als Leitfaden für die Umstrukturierung von Aktivitäten und relevanten Informationsflüssen verwendet werden. Die Infrastruktur des *Internet of Production* schafft eine Datendurchgängigkeit, die den Einsatz von prädiktiven und präskriptiven

Analysen und damit kürzere Rückkopplungsschleifen entlang des *Quality Streams* befähigt.

Der Begriff *Quality Intelligence* wird als Schaffung von Transparenz über alle qualitätsrelevanten Zusammenhänge mit Hilfe von KI-Methoden zur Qualitätssicherung und -verbesserung in der Produktion definiert. *Predictive Quality* ermöglicht die datenbasierte Vorhersage von Produkt- und Prozesseigenschaften, um Prüfumfänge zu reduzieren und Qualitätsverbesserungsmaßnahmen zu antizipieren. Darauf aufbauend können Methoden der erklärenden KI unterstützen, die Einflüsse von Prozessparametern besser zu verstehen. *Quality Diagnosis* ermöglicht es, aus Daten und Prozessmodellen diagnostische Erkenntnisse zu gewinnen.

Der Einsatz von *Predictive Quality* und *Quality Diagnosis* wurde am Beispiel eines Blisterverpackungsprozesses dargestellt. Beide Ansätze bieten Möglichkeiten, datenbasierte Erkenntnisse abzuleiten, um den Produktionsprozess dauerhaft zu verbessern. Darüber hinaus können bereits entwickelte Datenmodelle mittels Transfer Learning Methoden auf andere Produkte und Prozesse übertragen werden. Auf diese Weise kann *Quality Transfer* den Aufwand für physikalische Qualitätsprüfungen bei einem Wechsel der Produkt- oder Prozessdomäne reduzieren.

Die aufgezeigten Ansätze unterstützen die Bildung von lokalen Qualitätsschleifen entlang des Produktlebenszyklus. Es besteht weiterer Forschungsbedarf für die Anwendung von Methoden, die den Einsatz von *Predictive Quality* und *Quality Diagnosis* in erweiterten Qualitätsschleifen ermöglichen, beispielsweise die Rückführung von Daten aus dem Feld über die *Quality Backward Chain* in die Entwicklung und die Produktion. Hierfür muss die notwendige Datenbasis geschaffen werden. Ein strukturiertes Fehlermanagement kann einen Ansatz bieten, um die Schnittstellen entlang des Produktlebenszyklus zu verbinden. Darüber hinaus kann dies den gezielten und effizienten Einsatz von KI-Methoden unterstützen. In diesem Zusammenhang nimmt die Bedeutung der Definition und Quantifizierung von Qualitätsmerkmalen am Markt, die als Qualitätsschleifen in den Produktionsprozess zurückgeführt werden, zu. Innerhalb dieser Qualitätsschleifen kann der Verlust von Informationen oder eine Übertragung auf Indikatoren zur Weiterverarbeitung durch KI-Methoden in der Produktion eine Herausforderung darstellen. Der Einsatz von KI-Anwendungen erfordert zudem Methoden zur messbaren Ermittlung des monetären Nutzens im Vergleich zu klassischen Methoden oder Ansätze, die eine Integration in Managementsysteme ermöglichen.

Aus technologischer Sicht besteht die Notwendigkeit, Methoden und Infrastrukturen zu erforschen, die die Varianz innerhalb der Modellgenauigkeit ausgleichen können. Die Erhöhung der Robustheit der Modelle gegenüber Schwankungen und Störungen kann eine Voraussetzung für die Entwicklung von Qualitätsschleifen auf Basis präskriptiver Modelle darstellen.

Danksagungen. Gefördert durch die Deutsche Forschungsgemeinschaft (DFG) im Rahmen der Exzellenzstrategie des Bundes und der Länder – EXC-2023 Internet of Production – 390621612

Literatur

1. Breque, M., De Nul, L., Petridis, A.: Industry 5.0: towards a sustainable, human centric and resilient European industry. European Commission Directorate-General for Research and Innovation, Brussels (2021)
2. Schmitt, R.H., Sohnius, F., Padrón, M., Günther, R., Keens, J., Buschmann, D., Trappmann, R., Hauptvogel, A., Jatzkowski, P., Lesmeister, F., Mertens, Y., Quito, F., Rauchenberger, J., Stinner, S.: Neues Qualitätsparadigma für eine nachhaltige Produktion. Empower Green Production. In: Schmitt, R.H. et al. (Hrsg.) Empower Green Production. Tagungsband zum Aachener Werkzeugmaschinen-Kolloquium AWK. Fraunhofer-Gesellschaft (2023)
3. Schmitt, R., Pfeifer, T.: Qualitätsmanagement: Strategien – Methoden – Techniken. Carl Hanser Verlag GmbH Co KG, München (2015)
4. Haardt, O.F.R., Altmaier, P.: Industrielle Revolution 4.0: eine historische Navigationshilfe. wbg Paperback, Darmstadt (2022)
5. Zollondz, H.-D.: Grundlagen Qualitätsmanagement: Einführung in Geschichte, Begriffe, Systeme und Konzepte. Wissenschaftsverlag, München: Oldenbourg (2011). <https://doi.org/10.1524/9783486712025>
6. Sommerhoff, B.: Die Entwicklung des Qualitätsmanagements im 20. und 21. Jahrhundert. In: T. Pfeifer et al. (Hrsg.) Handbuch Qualitätsmanagement. S. 15–37. Hanser, München (2021)
7. Hummel, T., Malorny, C.: Total Quality Management (TQM). In: Kamiske, G.F. (Hrsg.) Handbuch QM-Methoden: Die richtige Methode auswählen und erfolgreich umsetzen. S. 1–48. Hanser, München (2015)
8. Koch, S.: Einführung in das Management von Geschäftsprozessen: Six Sigma. Kaizen und TQM. Springer, Heidelberg (2011)
9. Schmitt, R.H., Kurzhals, R., Ellerich, M., Nilgen, G., Schlegel, P.: Predictive Quality – Data Analytics in produzierenden Unternehmen. In: Bergs, T. et al. (Hrsg.) Internet of Production – Turning Data into Value. Tagungsband zum Aachener Werkzeugmaschinen-Kolloquium AWK. Fraunhofer-Gesellschaft (2020)
10. Beckschulte, S., Klasen, N., Huebser, L., Schmitt, R.H.: Prädiktive Qualität in der Prozesslenkung: Neuronales Netz als SPC 4.0. Z. Wirtschaft. Fabrik. **116**(10), 662–666 (2021). <https://doi.org/10.1515/zwf-2021-0134>
11. EXC 2023: Internet of Production (IoP). <https://gepris.dfg.de/gepris/projekt/390621612>
12. Brecher, C., Klocke, F., Schmitt, R., Schuh, G.: Internet of Production für agile Unternehmen: AWK Aachener Werkzeugmaschinen-Kolloquium 2017, 18. bis 19. Mai. Werkzeugmaschinenlabor WZL der RWTH Aachen (2017)
13. Padrón Hinrichs, M., Schmitt, R.H.: Qualitätssicherung für die Serienfreigabe im Produktionsanlauf: Ein modellgestützter Ansatz zur Risikobewertung von validierungsrelevanten Produktionswechselwirkungen am Beispiel der Automobilindustrie. Z. Wirtschaft. Fabrik. **119**(4), 205–209 (2024). <https://doi.org/10.1515/zwf-2024-1045>
14. Klasen, N., Kumbhare, R., Joseph, D.A., Schönekehs, C., Witt, R., Schmitt, R.H.: Transfer learning for enabling quality predictions in small batch production, 18th CIRP International Conference on Intelligent Computation in Manufacturing Engineering (2024). (im Druck)
15. Beckschulte, S., Padrón Hinrichs, M., Pirrone, L., Grothkopp, M., Sohnius, F., Schmitt, R.H., Friedli, T.: Manufacturing Data Analytics Study 2023: Empirical Industry Study. Apprimus, Aachen (2023)
16. Wachter, C., Beckschulte, S., Padrón Hinrichs, M., Sohnius, F., Schmitt, R.H.: Strategies for Resilient Manufacturing: A Systematic Literature Review of Failure Management in Production. Procedia CIRP. **130** (2024) 1393–1402

17. Fan, C., Chen, M., Wang, X., Wang, J., Huang, B.: A Review on Data Preprocessing Techniques Toward Efficient and Reliable Knowledge Discovery from Building Operational Data. *Front. Energy Res.* **9** (2021). <https://doi.org/10.3389/fenrg.2021.652801>
18. Christ, M., Braun, N., Neuffer, J., Kempa-Liehr, A.W.: Time Series Feature Extraction on basis of Scalable Hypothesis tests (tsfresh – A Python package), *Neurocomputing*. 307–77 (2018), ISSN 0925–2312, <https://doi.org/10.1016/j.neucom.2018.03.067>
19. Boateng, E.Y., Otoo, J., Abaye, D.A.: Basic Tenets of Classification Algorithms K-Nearest-Neighbor, Support Vector Machine, Random Forest and Neural Network: A Review. *Journal of Data Analysis and Information Processing*. **8**(4), 341–357 (2020)
20. Buschmann, D., Schulze, T., Beckschulte, S., Schmitt, R.H.: Information requirements analysis for process-oriented decision support via predictive quality models in production, 57th CIRP Conference on Manufacturing Systems (2024)
21. Buschmann, D., Schulze, T., Beckschulte, S., Schmitt, R.H.: Information requirements analysis for process-oriented decision support via predictive quality models in production. *Procedia CIRP*. **130**, 1428–1434 (2024)
22. Friedman, J.H.: Greedy Function Approximation: A Gradient Boosting Machine. *Ann. Stat.* **5**, 1189–1232 (2001)
23. Lundberg, S. M., Lee, S.-I.: A Unified Approach to Interpreting Model Predictions. In: Guyon, I. et al. (Hrsg.) *Advances in Neural Information Processing Systems*. S. 4768–4777 Curran Associates, Inc. (2017)
24. Molnar, C.: *Interpretable Machine Learning: A Guide for Making Black Box Models Explainable* (2022)
25. Tsung, F., Zhang, K., Cheng, L., Song, Z.: Statistical transfer learning: A review and some extensions to statistical process control. *Qual. Eng.* **30**(1), 115–128 (2018). <https://doi.org/10.1080/08982112.2017.1373810>
26. Pan, S.J., Yang, Q.: A Survey on Transfer Learning. *IEEE Trans. Knowl. Data Eng.* **22**(10), 1345–1359 (2010). <https://doi.org/10.1109/TKDE.2009.191>
27. J. Wang, Y. Chen, H. Yu, M. Huang and Q. Yang, „Easy Transfer Learning By Exploiting Intra-Domain Structures,“ 2019 IEEE International Conference on Multimedia and Expo (ICME), Shanghai, China. 1210–1215 (2019). <https://doi.org/10.1109/ICME.2019.00211>
28. Li, X., Hu, Y., Li, M., Zheng, J.: Fault diagnostics between different type of components: A transfer learning approach. *Appl. Soft Comput.* **86**, 105950 (2020). <https://doi.org/10.1016/j.asoc.2019.105950>