

Schlussbericht vom 30.06.2022

zu IGF-Vorhaben Nr. 21181N

Thema

Nutzbarmachung subjektiver Qualitätskriterien durch Kombination von Smart Devices und Machine Learning (KOMBI)

Berichtszeitraum

FQS-Forschungsgemeinschaft Qualität e.V.

Forschungsvereinigung

01.04.2020 - 31.03.2022

Forschungseinrichtung(en)

Fraunhofer-Institut für Produktionstechnologie IPT

Gefördert durch:

Kurzfassung

Innerhalb der Qualitätssicherung in produzierenden Unternehmen erfolgen optische Sichtprüfungen noch heute überwiegend manuell, bei denen Mitarbeiter subjektive Entscheidungen treffen. Ein wesentlicher Nachteil dieser subjektiven Qualitätsprüfungen ist, dass die Zuverlässigkeit der Qualitätsbeurteilung von der Erfahrung des Mitarbeiters abhängt. Aktuelle Ansätze zur Automatisierung optischer Prüfungen ersetzen manuelle Sichtprüfungen, anstatt auf diesen aufzubauen. Dabei existiert eine Reihe von potenziellen Systemen für automatisierte optische Prüfverfahren. Diese sind oftmals mit einer hohen Investition verbunden und somit besonders für kleine und mittlere Unternehmen (KMU) nicht wirtschaftlich einsetzbar. Für KMU ergeben sich daraus zwei zentrale Herausforderungen bei manuellen Sichtprüfungen. Zum einen müssen ungelernte Mitarbeiter bei manuellen Sichtprüfungen zur Umgehung des Fachkräftemangels befähigt werden. Zum anderen werden vorhandene Daten und Informationen sowie der Einsatz neuer Technologien nicht genutzt.

Daher bestand das Ziel des »KOMBI«-Projektes in der Objektivierung subjektiver Qualitätskriterien. Dieses Ziel wurde zum einen durch die Bereitstellung einer Werkerassistenz über Smart Devices zur objektiven Qualitätsbewertung der subjektiven Kriterien anhand visualisierter Klassifikationshilfen erreicht. Zum anderen dienen die während der Qualitätsbewertung generierten Daten der auf die Werkerassistenz aufbauende Automatisierung der Sichtprüfung mittels Machine Learning (ML)-Algorithmen. Die zentralen Ergebnisse stellen die Teillösung bestehend aus Werkerassistenz mit integrierter Entscheidungslogik und die Teillösung der Automatisierungslösung dar. Beide Teillösungen ergeben die »KOMBI«-Gesamtlösung, deren Konzepte und Prototypen als Leitfaden in Form eines Softwaretools bereit- und Unternehmen zur Verfügung gestellt wurde. Anhand bereitgestellter Anwendungsfälle und Daten der Unternehmen des projektbegleitenden Ausschusses (PA), wurde die »KOMBI«-Gesamtlösung realisiert. Deep Learning (DL)-Modelle wurden in Benchmarks ausgewählt und in ein Belief Rule Base Expert System (BRBES) zur Entscheidungsunterstützung integriert. Dieses wurde in ein Front- und Backend, realisiert mit den Frameworks und Plattformen React, Flask und Docker, eingebettet und so nutzbar gemacht.

Das Fraunhofer-Institut für Produktionstechnologie IPT entwickelte die »KOMBI«-Gesamtlösung während der Projektlaufzeit vom 01.04.2020 bis zum 31.03.2022 in enger Kooperation mit einem projektbegleitenden Ausschuss sowie mit der Forschungsgemeinschaft Qualität FQS.

Profitierende KMU sind Anwender sowie Befähiger-Unternehmen der Werkerassistenz und der Automatisierungslösung. Anwenderunternehmen steigern die Qualität der optischen Sichtprüfung durch die Objektivierung, was zu verringertem Ausschuss und Nacharbeit führt. Insbesondere KMU profitieren durch geringe Investitionen in die kombinierbaren Teillösungen. Dem Fachkräftemangel wird sowohl durch die Einfachheit der Endlösungen als auch durch den flexibleren Einsatz der Mitarbeiter begegnet. Befähiger-KMU können basierend auf den Erkenntnissen aus »KOMBI« marktreife Softwaresysteme entwickeln.

Das Ziel des Forschungsvorhabens »KOMBI« wurde erreicht.

Danksagung

Das IGF Vorhaben »KOMBI – Nutzbarmachung subjektiver Qualitätskriterien durch Kombination von Smart Devices und Machine Learning« wurde durch das Bundesministerium für Wirtschaft und Klimaschutz aufgrund eines Beschlusses des Deutschen Bundestages gefördert.

Die Forschungsstelle, das Fraunhofer-Institut für Produktionstechnologie IPT, bedankt sich ganz herzlich

- Bei der FQS, der AiF und dem BMWK für die Förderung des Forschungsprojektes und Unterstützung vor, während und nach der Projektlaufzeit.
- Bei den Unternehmen des projektbegleitenden Ausschusses für die Unterstützung der Forschungsarbeiten, durch die Bereitstellung von Anwendungsfällen, Proben und Dokumenten aus der Sichtprüfung, und für die aktive Mitarbeit im projektbegleitenden Ausschuss.

adQuas human resources GmbH

AiSight GmbH

Aurubis Stolberg GmbH & Co. KG

Calsitherm Verwaltungs GmbH

CSP GmbH & Co. KG

e.GO Mobile AG

ELABO GmbH

Güntert Präzisionstechnik GmbH

Hammerwerk Fridingen GmbH

IconPro GmbH

ISRA VISION AG

J. Schlenter Production GmbH

LBBZ-NRW GmbH

oculavis GmbH

Pham & Schild GmbH

Rhein-Getriebe GmbH

Schoeller Werk GmbH & Co. KG

Witzenmann GmbH

Inhalt

Thema.....	1
Berichtszeitraum.....	1
Forschungsvereinigung	1
Forschungseinrichtung(en).....	1
Kurzfassung	2
Danksagung	3
1. Ausgangssituation	5
1.1 Wissenschaftlich-technische und wirtschaftliche Problemstellung.....	8
2. Stand der Forschung und Entwicklung	9
3. Forschungsziel und Lösungsweg	12
3.1 Bearbeitungsschritte und Personaleinsatz	12
4. Verwendung der Zuwendung und Ergebnisse	17
4.1 Arbeitsdiagramm.....	17
4.2 Notwendigkeit und Angemessenheit der geleisteten Arbeiten.....	18
4.3 Arbeitspaket 1: Anforderungsermittlung	19
4.4 Arbeitspaket 2: Grobkonzeptionierung der »KOMBI-Gesamtlösung«.....	23
4.5 Arbeitspaket 3: Finale Konzeption der Entscheidungslogik und Implementierung der Werkerassistenz (Teillösung 1)	27
4.6 Arbeitspaket 4: Finale Konzeption und Implementierung der Automatisierungslösung (Teillösung 2)	41
4.7 Arbeitspaket 5: Gesamtimplementierung	53
4.8 Arbeitspaket 6: Validierung sowie Evaluation.....	60
4.9 Arbeitspaket 7: Dokumentation und Verbreitung sowie Transfer und laufende Nutzung.....	62
5. Wirtschaftliche Bedeutung der Forschungsergebnisse für KMU	63
6. Ergebnistransfer	66
6.1 Plan zum Ergebnistransfer in die Wirtschaft.....	66
7. Beteiligte Forschungsstellen.....	69
I Abkürzungsverzeichnis	70
II Abbildungsverzeichnis.....	71
III Tabellenverzeichnis.....	72
IV Literaturverzeichnis	73
Autoren	81

1. Ausgangssituation

Das industrielle Umfeld ist stark von einer zunehmenden Flexibilisierung und Adaptivität über alle Branchen hinweg geprägt. Im Maschinen- und Anlagenbau planen daher bereits 41 % der Unternehmen eine Fertigung von Produkten in der Stückzahl eins [1]. Durch die Variabilität der Produkte können sich die Anforderungen an die Qualitätsmerkmale häufig verändern und die Qualitätsbeurteilung ist so nicht ohne Weiteres reproduzierbar. Durch die steigende Individualisierung [2, 3] wird die ohnehin schon hohe Anzahl an manuellen Sichtprüfungen noch weiter erhöht [4]. Beurteilungen der Mitarbeiter erfolgen dabei subjektiv [5–7]. Ein wesentlicher Nachteil dieser subjektiven Qualitätsprüfungen ist, dass die Zuverlässigkeit der Qualitätsbeurteilung von der Erfahrung des Mitarbeiters abhängt, wobei geschulte Mitarbeiter Fehler zuverlässiger erkennen [7]. Dabei haben insbesondere KMU große Schwierigkeiten bei der Stellenbesetzung [8], worin laut DIHK auch das größte Geschäftsrisiko liegt [9]. Objektivität und Reliabilität der Messung sind also nicht gegeben. Hieraus entsteht ein Bedarf, Fachkräfte möglichst effizient einzusetzen und - wenn möglich - Aufgaben durch ungelernete Mitarbeiter durchführen zu lassen.

Aktuelle Ansätze zur Automatisierung optischer Prüfungen ersetzen heute manuelle Sichtprüfungen anstatt auf diesen aufzubauen [10]. Dabei existiert eine Reihe von potentiellen Systemen für automatisierte optische Prüfverfahren [11]. Diese sind oftmals mit einer hohen Investition verbunden und somit besonders für KMU nicht wirtschaftlich einsetzbar [12–14].

Daher sind manuelle Sichtprüfungen im Besonderen für KMU weiterhin notwendig. Smart Devices (wie z. B. Smartphones, Tablets und Smart Glasses) in Kombination mit Machine Learning (ML) bieten leistungsstarke Tools zur Datenbereitstellung, Datenaufnahme und Datenanalyse. Sie sind vielversprechende Ansätze, um Mitarbeiter über Assistenzsysteme in Form von Apps bei ihrer Arbeit zu unterstützen [15–17] und werden in anderen Anwendungsfällen bereits erfolgreich in der Produktion genutzt.

Zusammenfassend ergeben sich für Unternehmen zwei zentrale Herausforderungen, denen sie bei manuellen Sichtprüfungen aktuell begegnen:

- Befähigung von ungelerten Mitarbeitern bei manuellen Sichtprüfungen zur Umgehung des Fachkräftemangels
- Effiziente Nutzung vorhandener Daten und Informationen sowie Einsatz neuer Technologien (Smart Devices) um kostengünstige Automatisierungslösungen zu ermöglichen.

Das Forschungsvorhaben »KOMBI« setzte, wie das Gesamtkonzept in Abbildung 1 zeigt, an diesen Punkten an. Das Hauptziel des Projektes ist

- die Objektivierung subjektiver Qualitätskriterien.
- Dieses Ziel sollte ermöglicht werden durch die Bereitstellung einer Werkerassistenz über Smart Devices zur objektiven Qualitätsbewertung der subjektiven Kriterien durch visualisierte Klassifikationshilfen sowie

- die Nutzung der während der Qualitätsbewertung generierten Daten zur Automatisierung der Qualitätsbewertung mittels ML-Modellen.

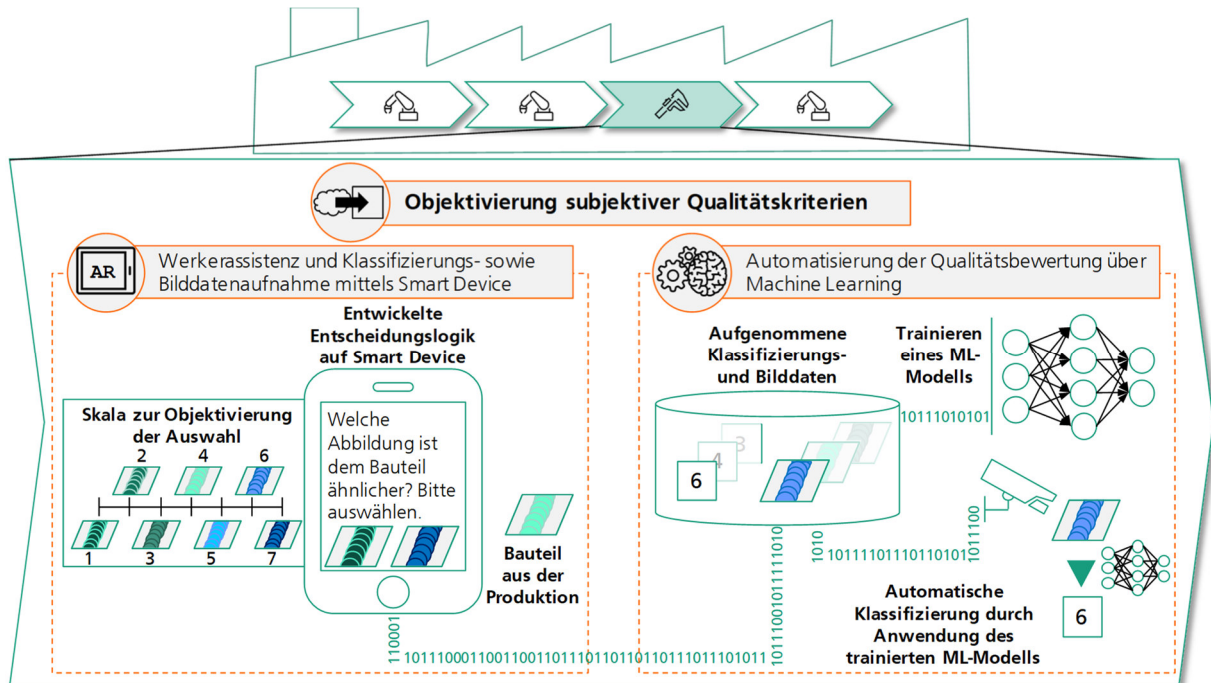


Abbildung 1: Gesamtkonzept des Forschungsvorhabens »KOMBI«; links: Werkerassistenz beispielhaft für die Bewertung von Schweißnähten; rechts: Automatisierung der Qualitätssicherung durch Machine Learning

Nachfolgend wird das zugrundeliegende Konzept detailliert vorgestellt. Für die manuelle Sichtprüfung sollte die subjektive Einschätzung von Experten in ein objektives Qualitätskonzept basierend auf definierten Messskalen überführt werden. Aufbauend auf diesen Messskalen werden manuelle Sichtprüfungen mit deutlich weniger oder keiner Erfahrung reproduzierbar. Darauf baut eine Entscheidungslogik auf, die subjektive Einschätzungen eines Mitarbeiters in die objektive Beurteilung des Qualitätsmerkmals übersetzt. Im Forschungsprojekt sollten passende Anwendungsszenarien zusammen mit dem projektbegleitenden Ausschuss (PA) ausgewählt und für die Entwicklung berücksichtigt werden. Ein beispielhaftes Anwendungsszenario für eine solche subjektive Qualitätsprüfung, die von dem vorgestellten Vorgehen profitiert, ist die manuelle Sichtprüfung von Schweißnähten. Durch Schweißvorgänge werden Anlauffarben im Stahl hervorgerufen, die gelb, braun, violett, dunkelblau, mittelblau, hellgrau oder grau sein können. Dabei können verschiedene Kombinationen der Anlauffarben zulässig sein, wohingegen andere Kombinationen außerhalb der Qualitätsanforderungen liegen. Ohne diese Kenntnis ist eine Beurteilung der Qualität nicht möglich [18]. In Abbildung 1 (links) ist dieser Sachverhalt vereinfacht für zwei unterschiedliche Bauteilfarben (grün und blau) dargestellt.

Die Entscheidungslogik gibt dem Mitarbeiter dabei eine Auswahl, ob ein vorliegendes Bauteil eher dem einen oder dem anderen Bild ähnelt. Dieser „paarweise Vergleich“ wird so lange wiederholt, bis die Bauteilfarbe erfolgreich klassifiziert wurde. Dabei werden die Unterschiede zwischen den auszuwählenden Ausprägungen des Qualitätsmerkmals mit jeder Entscheidung geringer. Entsprechendes gilt für weitere manuelle Sichtprüfungen verschiedener Qualitätsmerkmale. Im

Ergebnis wird also eine Bewertungsskala mit deutlich verbesserter Ergebnisbeurteilung nutzbar. Die Datenqualität für nachgelagerte Analysen erhöht sich signifikant, da anstelle einer binären i. O. / n. i. O. Entscheidung eine deutlich differenziertere Klassifizierung – trotz weiterhin manueller Prüfung – möglich wird.

Im Projekt sollte aufbauend auf den Ergebnissen dieser Objektivierung die Entscheidungslogik in einer Anwendung für Smart Devices umgesetzt werden, um sie dem Mitarbeiter ortsungebunden zugänglich zu machen. Über die Einbindung der Anwendung in den Arbeitsablauf der Mitarbeiter kann die Bewertung der Bauteilqualität objektiviert werden. Durch das systematische Vorgehen werden Fehlentscheidungen durch subjektive Einflüsse am Ort der Entstehung vermieden und die Qualität des Prüfprozesses erhöht. So kann eine verbesserte Reliabilität, als zentrale Anforderung an eine Messmethode, sichergestellt werden.

Während der manuellen Sichtprüfung sollten über eine Kamera, die im Smart Device integriert und auf das Bauteil ausgerichtet ist, Bilddaten aufgenommen werden. Sowohl die Bilddaten als auch die durch den Mitarbeiter in der Anwendung für Smart Devices vorgenommenen (objektivierten) Klassifizierungen dienen als Grundlage für das Trainieren eines ML-Modells mittels Supervised Learning. Insbesondere kommen dabei Deep Learning (DL)-Algorithmen zur automatisierten Klassifizierung der Bilddaten zum Einsatz (vgl. Abbildung 1 (rechts))

Es wird untersucht, unter welchen Randbedingungen ML-Algorithmen geeignet sind, um mit den objektivierten Daten trainiert zu werden. Dazu gehört die Analyse der Aufnahmebedingung (Bildqualität, Perspektive, etc.) und die strukturierte Ablage der Trainingsdaten. Nach ausreichendem Training und Testen ist das ML-Modell so performant, dass es die Qualitätsbeurteilung automatisiert übernehmen kann. Im Projekt sollten so die Grundlagen für eine technische Realisierung dieser automatisierten optischen Prüfung geschaffen werden. Es sollten darüber hinaus Ansätze entwickelt und evaluiert werden, wie sich diese automatisierte optische Prüfung hardwaretechnisch umsetzen lässt. D

abei sollten neben Smart Devices, ebenfalls Ansätze mit stationären Kameras betrachtet werden, um sowohl für die Datenaufnahme als auch zur Automatisierung die geeignetste Lösung für jeden Anwendungsfall auszuwählen. Im Rahmen des Projektes sollten gemeinsam mit dem PA Szenarien ausgewählt werden, in denen die Automatisierung der Sichtprüfung sinnvoll ist.

Zusammenfassend waren folgende Projektergebnisse zu erwarten:

Teillösung 1: Werkerassistenz (vgl. Abbildung 1 (links))

- Objektivierung der Qualitätskriterien in einer Entscheidungslogik für die Befähigung der Mitarbeiter
- Umsetzung der Entscheidungslogik und Datenaufnahme als **App für Smart Devices**

Teillösung 2: Automatisierung (vgl. Abbildung 1 (rechts))

- Performantes ML-Modell zur Automatisierung der manuellen Sichtprüfung

Die Kombination beider Teillösungen werden im Folgenden als »KOMBI-Gesamtlösung« bezeichnet (vgl. Abbildung 1). Die Projektergebnisse wurden als **Leitfaden in Form eines**

webbasierten Softwaretools (»KOMBI-Softwaretool«) bereitgestellt. Das webbasierte »KOMBI-Softwaretool« gibt, nach Eingabe der eigenen Randbedingungen, Empfehlungen zur spezifischen Implementierung des Konzeptes von »KOMBI« für das jeweilige interessierte Unternehmen. Dadurch können nach Abschluss des Projektes auch Unternehmen auf einfache Weise von den Projektergebnissen profitieren, die nicht im projektbegleitenden Ausschuss vertreten sind.

1.1 Wissenschaftlich-technische und wirtschaftliche Problemstellung

Wie im ersten Kapitel dargestellt, ist das Umfeld produzierender KMU von einer zunehmenden Flexibilisierung und Individualisierung über alle Branchen hinweg geprägt. Sowohl die steigende Individualisierung als auch die Forderung nach mehr Flexibilität ergeben eine erhöhte Anzahl manueller Sichtprüfungen, bei denen Mitarbeiter subjektive Entscheidungen treffen. Mitarbeiter müssen das Fachwissen mitbringen, um über die Produktqualität zu urteilen und die Arbeitsbelastung der Mitarbeiter steigt. Sollen Mitarbeiter entlastet werden, ergeben sich grundsätzlich zwei wissenschaftlich-technische Problemstellungen, die mit verallgemeinerten Vorgehensbeschreibungen gelöst werden können. Zum einen müssen die subjektiven Einschätzungen in jedem Fall objektiviert werden. Ein Vorgehen zur Objektivierung subjektiver Qualitätsprüfungen ist in den produzierenden Branchen nicht verbreitet [6]. Zum anderen stellt die alleinige Objektivierung keine Entlastung für die Mitarbeiter dar. Daraus ergibt sich die zweite wissenschaftlich-technische Problemstellung, die nur mit einer Entwicklung eines Vorgehens zur Einbindung von innovativen Technologien wie Smart Devices, die Mitarbeiter aktiv unterstützen, und ML, welches den Mitarbeitern Aufgaben abnehmen kann, gelöst werden kann. Mitarbeiter besitzen eine hohe Flexibilität bei verschiedenen Aufgaben selbstständig Lösungen zu finden. Für KMU ist die Bereitstellung vollautomatisierter Lösungen für optische Qualitätsbeurteilungen deshalb nicht zielführend, da diese Systeme in ihren Einsatzgebieten auf ein Anwendungsszenario beschränkt und sehr kostenintensiv sind [19]. Daraus ergibt sich die im ersten Kapitel dargelegte wirtschaftliche Problemstellung: insbesondere für KMU müssen unterstützende bzw. automatisierte Systeme zur optischen Qualitätsbeurteilung günstig und flexibel sein. Die einzige Alternative für KMU stellt daher eine kostengünstige Lösung zur Unterstützung und Entlastung der Mitarbeiter bei optischen Sichtprüfungen dar.

2. Stand der Forschung und Entwicklung

In aktuellen, anderen Forschungsvorhaben werden einzelne Aspekte des hier dargelegten Ansatzes aufgegriffen. Sowohl die Objektivierung subjektiver Qualitätskriterien als auch die Werkerassistenz und Automatisierungslösung von manuellen Sichtprüfungen sind Gegenstand verschiedener Forschungsvorhaben.

Objektivierung basierend auf Entscheidungslogik / Messskalen

Innerhalb der Produktion existieren bereits Anwendungen zur Objektivierung subjektiver Qualitätskriterien, bei der die Produktentwicklung und Qualitätswahrnehmung eines einzelnen Produktes im Fokus stehen [20]. Die Lösungen konzentrieren sich auf die Objektivierung einzelner Oberflächenwahrnehmungen oder allgemein auf haptische Empfindungen des Menschen [21]. Dabei erfolgt die Objektivierung auf Basis von definierten Messskalen. Eine Objektivierung manueller Sichtprüfungen findet bislang jedoch nicht statt. Darüber hinaus mangelt es insbesondere in der manuellen Sichtprüfung an einer ausreichenden Dokumentation der subjektiven Qualitätsbeurteilung [6, 22]. Im Rahmen des Forschungsvorhabens »KOMBI« wurde sowohl eine Objektivierung erarbeitet als auch eine ausreichende Dokumentation der Qualitätsbeurteilung sichergestellt.

Entscheidungsunterstützung in der Produktion über Smart Devices

Zur Entscheidungsunterstützung und Flexibilisierung manueller Produktionsprozesse werden bereits eine Vielzahl von Assistenzsystemen auf Basis von Smart Devices eingesetzt [23]. Beispielhafte Anwendungen reichen von der Wartung und Instandhaltung [24–29], über Montage und Logistik [30–32] bis hin zur Mitarbeiterqualifikation [33, 34]. Der Einsatz von Smart Devices beschränkt sich dabei auf spezifische Produktionsprozesse, um eine Entlastung der Werker zu erzielen [35, 47]. Eine Übertragbarkeit auf die Sichtprüfung in der optischen Qualitätssicherung ist nicht allgemein gegeben. Das Forschungsvorhaben KOMBI ermöglicht eine Übertragbarkeit der Werkerassistenz auf diese Anwendungsfälle mittels der Entscheidungslogik.

Einsatz von ML-Modellen in der Bilderkennung

In der Produktion werden bereits ML-Modelle zur Bilderkennung erfolgreich eingesetzt. Insbesondere dient die ML-basierte Bilderkennung zur Identifizierung von Qualitätsmerkmalen und deren Abweichungen [35]. ML-Modelle zur Bilderkennung greifen vor allem auf das Prinzip des Deep Learning (DL) zurück. DL-Modelle sind künstlich neuronale Netze, die eine Vielzahl versteckter Schichten aufweisen [36]. In Abhängigkeit von den Eigenschaften des Datensatzes, wie der Anzahl an Datenpunkten, und Anforderungen an das DL-Modell, wie zum Beispiel der Rechendauer, werden geeignete DL-Modelle für die Klassifizierung von Bilddaten ausgewählt [37]. Geeignete DL-Modelle sind unter anderen das Multilayer Perceptron (MLP) oder das Convolutional Neural Network (CNN). Zur Erzielung besserer Ergebnisse bei der Bilderkennung werden DL-Modelle stetig weiterentwickelt. Insbesondere CNN-Modelle wie ResNet, GoogleNet und AlexNet erzielen sehr gute Ergebnisse [38–40]. Diese Modelle werden in Programmierumgebung wie Python implementiert und können über Bibliotheken wie TensorFlow oder Cafe in einfacher Weise aufgerufen werden [41, 42].

Im Rahmen der Qualitätssicherung bei additiven gefertigten Bauteilen werden durch Bilderkennung mittels CNN Fehler mit einer Genauigkeit von 99,4 % detektiert. Die Datengrundlage des trainierten DL-Modells lag bei 840 Aufnahmen [43]. In der Automobilindustrie werden DL-Modelle, die mit Millionen von Bildern trainiert wurden, zur Identifikation von Rissen in Karosserieblechen erfolgreich eingesetzt [44]. Mithilfe eines MLP werden acht unterschiedliche Objekte mit einer Genauigkeit von 99,86 % erkannt und sortiert. Der MLP wurde auf Basis von 12 Bildern trainiert [45]. Mithilfe der Datenaugmentation durch Drehen, Rotieren und Spiegeln der Bilder ist es möglich, die Datengrundlage zu erhöhen [45, 46].

Der Stand der Forschung zeigt, dass DL-Modelle in der Lage sind, Fehler auf Bauteilen erfolgreich zu identifizieren. Voraussetzung einer erfolgreichen Anwendung von DL-Modellen sind die Datengrundlage und die Auswahl des geeigneten DL-Modells. Allerdings ersetzen diese Automatisierungslösungen die manuelle Durchführung der Qualitätsbeurteilung, anstatt auf diesen aufzubauen.

Die einzelnen Anforderungen an das Forschungsvorhaben werden in Tabelle 1 noch einmal zusammenfassend dargestellt. Zur eindeutigen Abgrenzung des Forschungsvorhabens, wurde eine ausführliche Konkurrenzanalyse durchgeführt.

Tabelle 1: Konkurrenzanalyse hinsichtlich alternativer Lösungen zu KOMBI

Forschungsprojekte												
Kommerzielle Software (Auszug)												
Anforderungen	Kombi	Pluto [47]	Molem [48]	Sake [49]	Appsist [50]	STEP [51]	Uni-Spital Zürich [52]	ETRI Korea [45]	Fraunhofer Neapel [43]	SurfMax (Zeiss) [21]	Proserv Electronic [53]	AUDI QS [44]
Objektivierung subjektiver Qualitätskriterien	●	○	○	○	○	○	◐	○	○	●	○	◐
Entscheidungslogik zur Werkerassistenz	●	●	○	●	●	◐	◐	○	○	○	●	○
Automatisierung manueller, optischer Entscheidungen	●	○	○	○	○	○	◐	●	●	●	◐	●
Einsatz in der Qualitätssicherung/ Produktion	●	●	○	●	●	●	○	●	●	●	●	●
Smart Device Support	●	◐	●	○	●	○	○	○	○	○	●	○
Einsatz von ML in der Bilderkennung	●	◐	○	○	○	○	●	●	●	k.A.	○	●
Übertragbarkeit auf verschiedene Anwendungsfälle	●	●	○	●	●	●	○	●	●	●	○	◐

Die Kombination der Themenfelder Werkerassistenz durch eine Entscheidungslogik, die Objektivierung subjektiver Qualitätskriterien und die Automatisierung von manuellen, optischen Entscheidungen mit visuellen ML-Techniken bilden dabei den zentralen Forschungsbedarf, der von KOMBI adressiert wurde. Die Lösung wurde dabei im Bereich der Qualitätssicherung in der Produktion eingesetzt und durch den Einsatz von Smart-Devices unterstützt.

Die Befähigung von Mitarbeitern in Form von Entscheidungsunterstützung (Werkerassistenz) zur Objektivierung ist bereits seit einigen Jahren Gegenstand von Forschung und Industrieberatung der Abteilung Produktionsqualität des Fraunhofer IPT [15, 16, 54–58]. Ebenfalls besteht große Expertise im Bereich des Datenmanagements und der Datenanalyse im Kontext der Produktion [59–62].

3. Forschungsziel und Lösungsweg

In den vorangegangenen Abschnitten konnte bereits gezeigt werden, dass sowohl Lösungen in den Disziplinen der Werkerassistenz als auch in der Automatisierung durch den Einsatz von ML erfolgreich in der Industrie eingesetzt werden können. Qualitätsbeurteilungen können ebenfalls mit technisch aufwendigen Systemen automatisiert werden, sodass sich bei hohen Stückzahlen und gleichbleibenden Qualitätsmerkmalen die Qualität automatisiert bestimmen lässt. Die eingesetzten Lösungen in diesem Anwendungsbereich sind jedoch so speziell und kostspielig, dass ein flächendeckender Einsatz insbesondere für KMUs nicht möglich ist. **Es fehlt daher aktuell an einer Lösung, die den Bedürfnissen produzierender KMUs gerecht wird.**

Die für »KOMBI« zugrundeliegende Arbeitshypothese lautete daher: **Eine flexible, kostengünstige und letztlich automatisierte Qualitätssicherung für KMU kann nur durch eine geeignete Objektivierung der subjektiven Qualitätskriterien als Kombination von Werkerassistenz und einer darauf aufbauenden ML-unterstützten Automatisierungslösung erfolgen.**

Aufgrund der hohen technischen und prozessualen Anforderungen ist die Lösungsfindung nicht trivial. Erst durch die Ableitung generischer Beschreibungsmöglichkeiten für einen spezifischen Anwendungskontext, kann dieser verallgemeinert dargestellt werden. Durch die Einbeziehung diverser Anwendungsszenarien lässt sich schließlich ein allgemeines Vorgehen ableiten.

Das Ergebnis des Forschungsvorhabens ist **die Ableitung entsprechender Gestaltungsregeln, Vorgehen und Lösungen für die Objektivierung, die Werkerassistenz, sowie die Automatisierung. Dies wurde im »KOMBI-Softwaretool« aufbereitet und zur Verfügung gestellt.**

3.1 Bearbeitungsschritte und Personaleinsatz

Das Forschungsvorhaben »KOMBI« gliederte sich in sieben Arbeitspakete (AP) (vgl. Abbildung 2). Das ursprünglich geplante jeweilige Vorgehen und die voraussichtlichen Ergebnisse der AP werden im Rahmen der Arbeitspaketbeschreibungen im Folgenden erläutert.

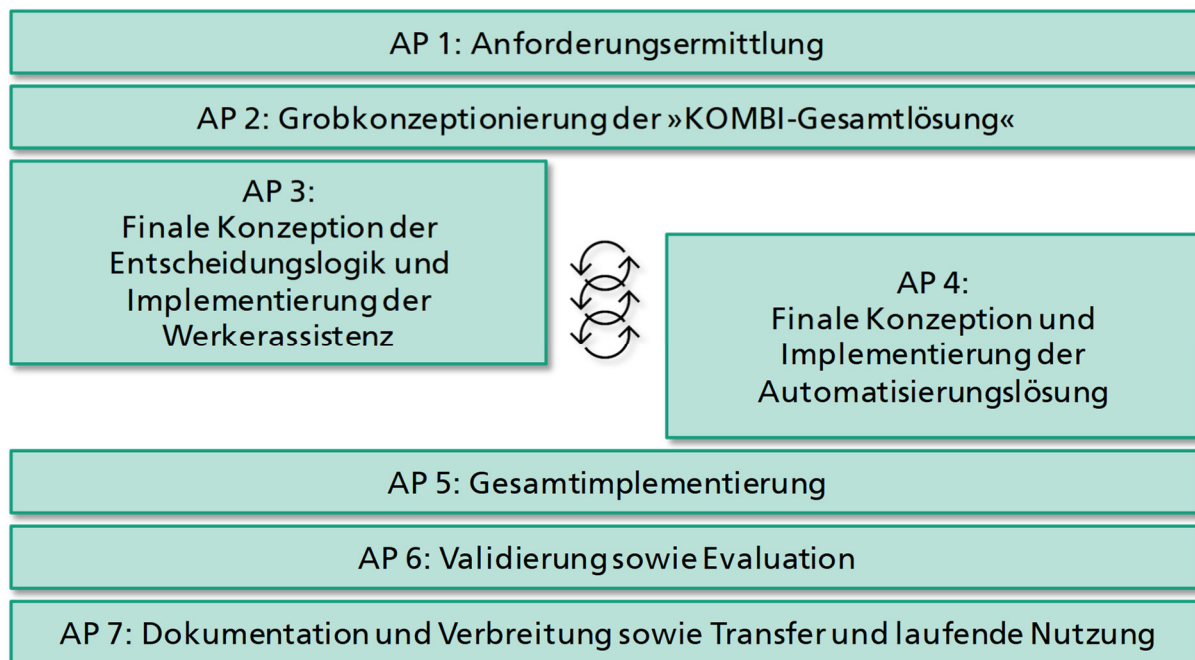


Abbildung 2: Gliederung des Forschungsvorhabens »KOMBI«

Arbeitspaket 1: Anforderungsermittlung

Vorgehen: Zu Beginn werden in Zusammenarbeit mit dem PA mindestens fünf Anwendungsszenarien (verschiedene Aufgaben, unterschiedliche Qualitätsmerkmale) für die Implementierung im Forschungsvorhaben »KOMBI« ausgewählt. Es werden die zu beurteilenden Qualitätsmerkmale definiert und, gemeinsam mit einem Experten aus den Unternehmen des PA, Anforderungen an die Objektivierung bestimmt. Zusätzlich werden die Anforderungen an die Entscheidungslogik, die die Qualitätsbewertung darstellt, abgeleitet. Für die Werkerassistenz werden sowohl die technischen sowie softwareergonomischen Anforderungen als auch die ergonomischen Anforderungen an den Arbeitsplatz definiert. Im Rahmen der Automatisierungslösung werden Anforderungen an die Aufbereitung der Inputdaten sowie an die Auswahl der zu implementierenden DL-Algorithmen bestimmt (z. B. benötigte Genauigkeit oder benötigte Anzahl an Bilddaten). Ferner werden Anforderungen an den Arbeitsplatz ermittelt, der die reproduzierbare Aufnahme von Bilddaten über eine Kamera ermöglicht.

Ergebnis: Ausgewählte Anwendungsszenarien, Anforderungsliste bezüglich der Objektivierung durch die Entscheidungslogik, der Werkerassistenz sowie der Automatisierungslösung

Arbeitspaket 2: Grobkonzeptionierung der »KOMBI-Gesamtlösung«

Vorgehen:

Objektivierung durch Entscheidungslogik für die Befähigung des Mitarbeiters

Basierend auf den mit dem PA identifizierten Anforderungen zur Objektivierung werden die Qualitätsbeurteilungen durch einen Experten für die jeweiligen Anwendungsszenarien vorgenommen. Es wird eine objektive Entscheidungslogik entwickelt, wofür eine geeignete Skala für die Ausprägung des jeweiligen Qualitätsmerkmals definiert wird. Darauf aufbauend wird die

entsprechende Entscheidungslogik erarbeitet. Das allgemeine Vorgehen zur Objektivierung wird dabei als erster Teil eines Leitfadens (vgl. Kap. 1: »KOMBI-Softwaretool«) dokumentiert.

Entscheidungslogik zur Werkerassistenz über Smart Device (Teillösung 1)

Auf Basis der entwickelten Entscheidungslogik und der in AP 1 definierten Anforderungen wird die Werkerassistenz konzeptioniert (z. B. Kriterien zur Device-Auswahl). Grundlegende Gestaltungsregeln für die Einbindung der Entscheidungslogik und die Interaktion mit dieser werden ausgearbeitet und im Leitfaden dokumentiert. Außerdem werden Randbedingungen (z. B. Ergonomie), die sich an den Arbeitsplatz für die assistierte Sichtprüfung ergeben, bestimmt.

Automatisierungslösung durch die Anwendung von DL-Algorithmen (Teillösung 2)

Unter Hinzunahme der im Rahmen der Werkerassistenz aufzunehmenden Daten sowie der Anforderungen aus AP 1 wird das Vorgehen zum Aufbereiten der Inputdaten sowie zum Auswählen geeigneter DL-Algorithmen spezifiziert. Ferner wird das Vorgehen zum Trainieren, Testen und Evaluieren der DL-Algorithmen beschrieben. Unter Berücksichtigung von technologischen Rahmenbedingungen, wie beispielsweise der Lage des Bauteils zur Kamera oder der Bildgröße, wird ein Vorgehen entwickelt, um für ein beliebiges Anwendungsszenario die Automatisierungslösung auszulegen. Dies beinhaltet auch die Ausgestaltung des Arbeitsplatzes zur Datenaufnahme.

Ergebnis: Gesamtkonzept bestehend aus der Objektivierung mittels Entscheidungslogik, der Werkerassistenz und Automatisierungslösung. Konzepte zu Teillösungen zur Objektivierung, Werkerassistenz und Automatisierungslösung erarbeitet und im Leitfaden dokumentiert

Arbeitspaket 3: Finale Konzeption der Entscheidungslogik und Implementierung der Werkerassistenz (Teillösung 1)

Vorgehen: In Abhängigkeit der vom PA ausgewählten Anwendungsszenarien wird die Entscheidungslogik final konzeptioniert. Dafür werden die zur objektiven Qualitätsbeurteilung definierten Messskalen weiter spezifiziert. Dabei wird gemäß den in AP 1 identifizierten Anforderungen und des in AP 2 erarbeiteten Vorgehens ein geeignetes Smart Device ausgewählt. Anhand der definierten Gestaltungsregeln wird die Benutzeroberfläche zur Anzeige der Entscheidungslogik programmiert. Darüber hinaus wird der Arbeitsplatz der Werkerassistenz für das Anwendungsszenario ausgelegt. Nach der programmiertechnischen Umsetzung werden die Prototypen zur Werkerassistenz in den jeweiligen Unternehmen des PA implementiert. Die Implementierung dient der kontinuierlichen Datenaufnahme für die Umsetzung der Automatisierungslösung.

Die Arbeiten in diesem Arbeitspaket finden in engem iterativem Austausch mit den Arbeiten in AP 4 statt, um aufeinander abgestimmte Teillösungen zu erhalten, die eine stimmige Gesamtlösung ergeben (vgl. Abbildung 2).

Ergebnis: Implementierte Teillösung 1 (Prototyp) der Werkerassistenz mit integrierter Entscheidungslogik

Arbeitspaket 4: Finale Konzeption und Implementierung der Automatisierungslösung (Teillösung 2)

Vorgehen: Zuerst werden DL-Algorithmen basierend auf den Eigenschaften des Datensatzes (vgl. AP 3) und Anforderungen an die DL-Algorithmen (vgl. AP 1) mit dem in AP 2 beschriebenen Vorgehen ausgewählt. Die innerhalb der Werkerassistenz aufgenommenen Daten dienen als Input für das in AP 2 beschriebene Vorgehen des Trainierens und Testens der ausgewählten DL-Algorithmen. Darüber hinaus kann auf bereits vorhandene Daten (Klassifizierungen von Qualitätsmerkmalen) aus den Unternehmen zurückgegriffen werden. Das Aufbereiten der Daten für das Training der ML-Modelle erfolgt unter anderem über Techniken der Datenaugmentation, wie z. B. der künstlichen Rotation der Bilder. Mithilfe weiterer Inputdaten werden die ML-Modelle validiert und evaluiert sowie das Ergebnis mit der Einschätzung erfahrener Mitarbeiter verglichen. Neben der Modellierung wird ein Arbeitsplatz mit der Automatisierungslösung für das jeweilige Anwendungsszenario ausgestaltet. Die Automatisierungslösung wird in zwei Phasen implementiert bei der die

1. Entscheidungen der Automatisierungslösung vom Mitarbeiter überwacht werden
2. Entscheidungen durch Automatisierung eigenständig vorgenommen werden

Ergebnis: Implementierte Teillösung 2 (Prototyp) Automatisierungslösung in verschiedenen Anwendungsszenarien

Arbeitspaket 5: Gesamtimplementierung

Vorgehen: Die in AP 3 und AP 4 implementierten Teillösungen werden zu einer Gesamtlösung zusammengeführt. Um eine spätere Einsatzfähigkeit der Teillösungen zu gewährleisten, werden die implementierten Teillösungen modularisiert. Dies ermöglicht einen einfachen Rollout bei der zukünftigen Anwendung der »KOMBI-Gesamtlösung« in Unternehmen, da sich die Softwarebestandteile flexibel einsetzen lassen.

Ergebnis: Implementierte »KOMBI-Gesamtlösung« bestehend aus modularisierten Teilsystemen

Arbeitspaket 6: Validierung sowie Evaluation

Vorgehen: Die »KOMBI-Gesamtlösung« wird dem PA validiert und ferner evaluiert. Dabei wird eruiert, ob eine Objektivierung der Qualitätsbeurteilung in den Anwendungsszenarien durch die Werkerassistenz erfolgreich ist. Iterativ werden in den dreimal jährlich stattfindenden Arbeitstreffen Zwischenvalidierungen der Teillösungen bestehend aus Werkerassistenz auf der einen und Automatisierungslösung auf der anderen Seite durchgeführt. Auf Basis des Feedbacks des PA werden die Lösungen kontinuierlich optimiert und angepasst.

Ergebnis: Optimierte Gesamt- sowie Teillösungen basierend auf Validierung und Evaluierung durch den PA

Arbeitspaket 7: Dokumentation und Verbreitung sowie Transfer und laufende Nutzung

Vorgehen: In AP 7 werden die Projektergebnisse als Leitfaden in Form eines interaktiven »KOMBI-Softwaretool« zusammengestellt und somit nachhaltig dokumentiert und nutzbar gemacht. Das »KOMBI-Softwaretool« wird in Form einer webbasierten Anwendung entwickelt. Es gibt nach der Eingabe der Randbedingungen, die ein potentieller Anwender (z.B. Qualitätskriterium, Bauteilgröße, Stückzahl, etc.) in seiner Produktion hat, Empfehlungen zur Umsetzung für das jeweilige Unternehmen. Dadurch wird sichergestellt, dass die Unternehmen

des PA sowie externe Unternehmen über den PA hinaus die Projektergebnisse auf weitere Anwendungen übertragen können.

Zur Verbreitung der Projektergebnisse werden diese durch wissenschaftliche Veröffentlichungen in Journals und auf Konferenzen kommuniziert. Durch die Fraunhofer Open Access Strategie 2020 wird der freie Zugang zu den Veröffentlichungen sichergestellt. Projektresultate werden ebenfalls über industrienaher Magazine jährlich verbreitet. Neben den Veröffentlichungen wird über eine projekteigene Webseite, die Webseiten der Partner des PA und sozialen Medien auf das Projekt aufmerksam gemacht. Die konkreten Arbeitsinhalte sind im Kapitel 5 „Umsetzbarkeit und Transfer der Ergebnisse“ erläutert.

Ergebnis: Erfolgreiche Verbreitung der Projektergebnisse und nachhaltige Verwertung der Ergebnisse über das »KOMBI-Softwaretool«

4. Verwendung der Zuwendung und Ergebnisse

Das Hauptziel des KOMBI-Projektes war die Objektivierung subjektiver Qualitätskriterien. Dieses Ziel wurde durch die Bereitstellung einer Werkerassistenz über Smart Devices zur objektiven Qualitätsbewertung der subjektiven Kriterien durch visualisierte Klassifikationshilfen ermöglicht. Zudem sollte die Nutzung der (während der Qualitätsbewertung) generierten Daten zur Automatisierung der Qualitätsbewertung mittels ML-Modellen zur Erreichung dieses Zieles beitragen. Die Kombination beider Teillösungen wird im Folgenden als »KOMBI-Gesamtlösung« bezeichnet.

Darüber hinaus wurde eine webbasierte Anwendung entwickelt, in welcher die Projektergebnisse als Leitfaden in Form eines interaktiven »KOMBI-Softwaretool« zusammengestellt und somit nachhaltig dokumentiert und nutzbar gemacht wurden.

4.1 Arbeitsdiagramm

Eine Übersicht über die zeitliche Verteilung der Arbeitspakete wird in Abbildung 3 dargestellt. Die Bearbeitung erfolgte durch wissenschaftliche Mitarbeiter (24,14 PM). Ursprünglich war auch der Einsatz weiterer Arbeiten von wissenschaftlichen Mitarbeitern (7 PM) vorgesehen. Aufgrund von Personalmangels konnten diese Personenmonate jedoch nicht verbucht werden. Die offenen Arbeitsinhalte wurden im Projekt durch den Einsatz von wissenschaftlichen Hilfskräften sowie Ergebnissen aus wissenschaftlichen Abschlussarbeiten aufgefangen. So konnten die angestrebten Ziele ohne den Einsatz weiterer wissenschaftlicher Mitarbeiter erreicht werden.

Die wissenschaftlichen Mitarbeiter konzentrierten sich auf die Gesamtleitung des Projektes, die Konzeptionierung und Implementierung der Werkerassistenz sowie der Automatisierungslösung einschließlich der Validierung auf Basis der definierten Anwendungsszenarien aus dem PA. Studentische Hilfskräfte unterstützten bei den aufwändigsten Arbeitspaketen (AP 2, AP 3, AP 4). Eine studentische Hilfskraft war über die gesamte Laufzeit im Projekt tätig (14,4 PM). Es wurden ebenfalls weitere studentische Hilfskräfte ohne direkte Finanzierung über das Projekt KOMBI eingesetzt, um die angestrebten Ziele zu erreichen.




Abbildung 3: Arbeitsdiagramm für die Projektdurchführung

4.2 Notwendigkeit und Angemessenheit der geleisteten Arbeiten

Die geleistete Arbeit der wissenschaftlichen Mitarbeiter (HPA A) von 24,14 Personenmonaten (PM) über die Gesamtlaufzeit des Vorhabens, wichen wie im vorigen Abschnitt beschrieben von den in der Vorhabensbeschreibung beantragten PM ab. Durch den Einsatz zusätzlicher wissenschaftlicher und studentischer Hilfskräfte, die nicht direkt über das Vorhaben finanziert wurden, konnten alle im Vorhaben beschriebenen Arbeiten geleistet werden. Alle eingesetzten Arbeiten waren notwendig und angemessen, um die Ziele zu erreichen und das Vorhaben erfolgreich abzuschließen. Dabei wurden keine Leistungen Dritter in Anspruch genommen.

Neben dem beschriebenen Personaleinsatz war auch die Einbindung des projektbegleitenden Ausschusses (PA) notwendig, um im angemessenen Umfang den Anforderungen der Industriepartner gerecht zu werden. Um ein möglichst übertragbares »KOMBI-Konzept« entwickeln zu können, wurde darauf geachtet, unterschiedliche, aus verschiedenen Branchen stammende, Anwendungsszenarien auszuwählen. Um den Transfer der »KOMBI-Gesamtlösung« auf weitere Anwendungsszenarien zu gewährleisten, war der PA aus Anwenderunternehmen unterschiedlicher Branchen zusammengesetzt. Darüber hinaus bestand der PA aus Befähigern, die die Marktrelevanz der betrachteten Technologien sowie die Validität der »KOMBI-Gesamtlösung« durch die vorliegende Expertise sicherstellen.

Der PA hatte damit die ideale Besetzung zur Sicherstellung der industriellen Relevanz von »KOMBI«. Neben der Berücksichtigung von Anforderungen produzierender (klein- und mittelständischer) Unternehmen wurde durch die Branchenvielfalt auch die unternehmensunabhängige Gültigkeit der abgeleiteten Vorgehensbeschreibung sichergestellt. Im Rahmen regelmäßiger Projektreview-Termine hat das Fraunhofer IPT den aktuellen Bearbeitungsstand vorgestellt und Zwischenergebnisse mit dem PA diskutiert. Hierfür waren drei Treffen pro Jahr vorgesehen, die sich an den Meilensteinen im Projekt orientierten. In diesen Projekttreffen wurden weiterhin die thematischen Schwerpunkte und das weitere Vorgehen bis zum nächsten Projekttreffen abgestimmt und verabschiedet. Entsprechend den Terminen für Reviews bzw. Workshops wurden die folgenden Meilensteine definiert:

- **MS1 (Monat 4):** Anwendungsszenarien wurden spezifiziert und ausgewählt, finale Anforderungen liegen vor
- **MS2 (Monat 7):** Grobkonzeptionierung abgeschlossen
- **MS3 (Monat 9):** Erster Prototyp für Werkerassistenz (Teillösung 1) liegt vor und Datenaufnahme hat begonnen
- **MS4 (Monat 11):** Datenbasis aus der Werkerassistenz für Implementierung der Automatisierungslösung liegt vor
- **MS5 (Monat 14):** Erster Prototyp bestehend aus Automatisierungslösung (Teillösung 2) sowie der Kombination aus Werkerassistenz und Automatisierungslösung (»KOMBI-Gesamtlösung«) und erste Ergebnisse aus dem Praxis-Einsatz liegen vor
- **MS6 (Monat 19):** »KOMBI-Gesamtlösung« final in den ausgewählten Anwendungsszenarien implementiert

- **MS7 (Monat 21):** Validierung und Evaluierung durch den PA abgeschlossen
- **MS8 (Monat 24):** Projektergebnisse abschließend dokumentiert und veröffentlicht (»KOMBI-Softwaretool«)

In Veranstaltungen und Treffen mit den PA Mitgliedern wurden die durchgeführten Arbeiten vorbereitet, vorgestellt und validiert sowie wichtige Inhalte gemeinsam erarbeitet, welche insbesondere für eine industrieorientierte Entwicklung der Gesamtlösung dienten.

Im Folgenden sind die durchgeführten Arbeiten und erzielten Ergebnisse nach Arbeitspaketen aufgeschlüsselt und dargestellt.

4.3 Arbeitspaket 1: Anforderungsermittlung

In Arbeitspaket 1 galt es die Anforderungen an die Gesamtlösung zu ermitteln. Zur Anforderungsermittlung wurden mithilfe des PA verschiedene Anwendungsszenarien und zugehörige Qualitätsmerkmale in bilateralen virtuellen Konferenzen und im Kick-off Meeting aufgenommen. Zusätzlich wurde eine Recherche zu relevanten Standards und Normen der Sichtprüfung mit Relevanz in den Branchen der PA Mitglieder vorgenommen. Die Anforderungen wurden für die Objektivierung (Merkmalsunterscheidungen, Skalenausprägungen etc.) und Entscheidungslogik (subjektive und objektive Qualitätsentscheidungen), der Werkerassistenz (technische und softwareergonomische Anforderungen) sowie der Automatisierungslösung (Anforderungen an Inputdaten, Algorithmen etc.) in einer Liste festgehalten. Die Liste von Anforderungen diente den Entwicklungen in den folgenden Arbeitspaketen.

Die wichtigsten Anforderungen die in Zusammenarbeit mit dem PA festgehalten und bewertet wurden, sind:

- Objektivität und Entscheidungslogik
 - Die Regeln der Entscheidungslogik müssen transparent und nachvollziehbar sein
 - Die Entscheidungslogik muss Unsicherheiten des Entscheiders einbeziehen
 - Dimensionen der Qualitätsurteile sind frei zu bewerten (Skala frei definierbar)
- Werkerassistenz
 - Die Werkerassistenz sollte auf vielen verschiedenen Smart Devices funktionieren
 - Bei den Anwendern sollte eine Akzeptanz entstehen
 - Ein hoher Tragekomfort der Smart Devices ist erforderlich, um mehrere Stunden am Stück arbeiten zu können
- Automatisierungslösung

- Eine Genauigkeit von 95 % sollte erreicht werden, damit das Niveau der Fehlerrate dem eines menschlichen Prüfers nahekommt
- Zuverlässigkeitsstatistik muss angefertigt werden für einen Einsatz in der QS
- Umlernen oder Erweitern auf neue Anforderungen sollte gegeben sein (Verschärfung der Beurteilungskriterien etwa) – Anpassbarkeit der Modelle

Insgesamt wurden 109 Anforderungen aufgenommen.

Zu den Anwendungsfällen wurden Proben von einigen der PA Mitgliedern versendet, sodass eine Datenaufnahme unabhängig von einem Vor-Ort Besuch stattfinden konnte. In virtuellen Konferenzen wurden die Anwendungsszenarien vollumfänglich beschreiben (Produkte, Qualitätsmerkmale, Merkmalsausprägungen, Sichtprüfungsvorgänge etc.). Bei diesen virtuellen Konferenzen war mindestens ein Vertreter des jeweiligen Unternehmens sowie des Fraunhofer IPT beteiligt. Die Durchführung der Konferenzen bedingte stets eine entsprechende Vor- und Nachbereitung. Im Anschluss an die Konferenzen wurden die Anwendungsfälle aufgearbeitet, um sie für die weitere Projektbearbeitung nutzbar zu machen.

In der Aufnahme von Anwendungsfällen wurde deutlich, dass die Mitglieder des PA unterschiedliche Dokumente für Mitarbeiter in der Sichtprüfung bereitstellen. Die Dokumente unterschieden sich in Form und Informationsgehalt. Teilweise wurden von Kunden, Anforderungen in Textform mit Beispielbildern und Definitionen von n. i. O. und i. O. Teilen bereitgestellt. Diese machen es unerfahrenen Mitarbeitern leichter die Anforderungen und Standards zu erlernen. Unterschiede zwischen Qualitätsmerkmalen und -ausprägungen, Produkten und Kunden, konnten innerhalb der Anweisungen der Unternehmen festgestellt werden. Um diese Informationen an die Sichtprüfer weiterzugeben und im Prüfprozess bereitzustellen, wurden diese teilweise in vereinfachter Form mit Bildern am Arbeitsplatz aufgestellt. Dort wo keine oder wenig Informationen bereitgestellt wurden, waren die Erfahrungswerte und das Erfahrungswissen der Sichtprüfer die wichtigste Ressource, um Anforderungen an die Sichtprüfungen zu definieren. Insbesondere für nicht kritische Qualitätsdefekte konnten unterschieden zwischen den Expertenmeinungen festgestellt werden.

Zur Aufnahme der Anwendungsfälle wurden Protokolle angefertigt, die die jeweiligen Ziele der Sichtprüfung, die Beschreibung der Produkte, der Qualitätskriterien und Ausprägungen, sowie die Durchführung der Sichtprüfung festhalten. Beispielhaft folgt in Tabelle 2 eine verkürzte und anonymisierte Darstellung eines Protokolls eines Anwendungsfalls:

Tabelle 2: Beispielhaftes Protokoll eines Anwendungsfalls in der Sichtprüfung

Anwendungsfall: Sichtprüfung an Montageplätzen für elektrische Komponenten (Leiterplatten)
Ziele
<ul style="list-style-type: none"> • Verkürzung der Lieferzeit und Verbesserung der Qualität ausgelieferter Produkte – Insbesondere bei Einzelfertigungen

<ul style="list-style-type: none"> • Weniger qualifizierte Mitarbeiter müssen qualifiziert werden • Nachverfolgbarkeit der Qualität in der Sichtprüfung (bspw. durch Lieferantenfehler) 	
Beschreibung der Produkte/des Produktes das geprüft wird	
<ul style="list-style-type: none"> • Leiterplatten die auf einer Frontplatte montiert sind • Zweiseitige Betrachtung des Produktes (Vorder- und Rückseite) 	
Merkmale der Leiterplatine	<ul style="list-style-type: none"> • Größe ca. 15*10 cm • Mehrere Bauteile (30+) in verschiedenen Größen auf der Leiterplatine angebracht
Merkmale der Frontplatte	<ul style="list-style-type: none"> • Größe ca. 20*13 cm • Helle (Weiße) Farbe mit schwarzen Markierungen • Zwei Displays am oberen Rand ca. 4*2 cm • Auf der Frontplatte befinden sich Bohrlöcher in der Größenordnung < 1 cm und > 0,3 cm • Es sind ca. >10 Bohrlöcher vorhanden • Die Beschriftung ist ca. < 1 cm breit • Verschiedene Sprachen liegen für die Beschriftung vor
Qualitätskriterien und deren Ausprägungen	
<ul style="list-style-type: none"> • Prüfung auf Vollständigkeit • Prüfung auf Lagerichtigkeit • Prüfung auf Maß-, Form-, Winkelhaltigkeit 	
Qualitätskriterien Leiterplatine	<ul style="list-style-type: none"> • Korrekte Montageposition der Leiterplatine • Korrekte Bauteile verbaut (Montageposition der Bauteile auf der Leiterplatine)
Qualitätskriterien Frontplatte	<ul style="list-style-type: none"> • Jegliche Sprachfehler der Beschriftungen • Löcher auf der Frontplatte (Anzahl und Ort) • Oberflächenqualität der Frontplatte (Kratzer, Verschmierungen, Farbschicht)
Durchführung der Sichtprüfungen	

Ort	<ul style="list-style-type: none"> • Montageplätze auf denen Arbeitsschritte (Montageschritte) durchgeführt werden • An diesen Plätzen wird auch die Sichtprüfung durchgeführt • Gute Sichtverhältnisse • Beleuchtung vorhanden • Smart Devices zum Teil bereits eingebunden
Durchführender	<ul style="list-style-type: none"> • Sichtprüfer/Monteur am Montagearbeitsplatz
Anweisungen	<ul style="list-style-type: none"> • Beurteilung der Qualitätsmerkmale in Fehlertypen • Hilfsmittel ausgedruckt neben dem Arbeitsplatz • Training der Sichtprüfer für Produkte
...	

Die versendeten Proben wurden für die Datenaufnahme genutzt, indem die Produktionsumgebung simuliert und verschiedene Bildaufnahmen gemacht wurden. Diese Bildaufnahmen dienen den Entwicklungen in AP3 und AP4. Ausführliche Tests zu den Bildaufnahmen für die Automatisierungslösung sind in Kapitel 4.6 Arbeitspaket 4 im Detail beschrieben.

Folgende Unternehmen haben Anwendungsszenarien und Proben bereitgestellt:

- Aurubis Stolberg GmbH & Co. KG – Sichtprüfung von Oberflächendefekten auf Metallbändern und -drähten
- CALSITHERM Silikatbaustoffe GmbH – Sichtprüfung von Silikatplatten und Thermoelementschutzrohren [Proben bereitgestellt]
- E.GO Mobile AG – Sichtprüfung von Schweißnähten an Aluminiumrahmen
- ELABO GmbH – Sichtprüfung an Montageplätzen [Proben bereitgestellt]
- Güntert Präzisionstechnik GmbH – Sichtprüfung von Drehteilen [Proben bereitgestellt]
- LBBZ-NRW GmbH – Sichtprüfung von Schweißverbindungen
- Rhein-Getriebe GmbH – Sichtprüfung von Abseilgeräten [Proben bereitgestellt]
- Schoeller Werk GmbH & Co. KG – Sichtprüfungen von Schweißnähten auf der Oberfläche (Längsschweißnähte von Rohren), Sichtprüfung von Oberflächendefekten in Längsrichtung (außen und innen) [Proben bereitgestellt]

4.4 Arbeitspaket 2: Grobkonzeptionierung der »KOMBI-Gesamtlösung«

Das Gesamtkonzept bestehend aus der Objektivierung mittels Entscheidungslogik, der Werkerassistenz und Automatisierungslösung, wurde erfolgreich in Arbeitspaket 2 grob ausdefiniert. Konzepte zu Teillösungen zur Objektivierung, Werkerassistenz und Automatisierungslösung wurden erarbeitet und dokumentiert.

Die Ausarbeitung des Grobkonzeptes zeigt die Zusammenwirkung der Hauptbestandteile des Projektes auf, sowie deren Teilkonzepte. In Abbildung 4 ist das entwickelte Grobkonzept dargestellt. Im Zentrum ist die Entscheidungslogik in Zusammenschluss mit einer Dokumentationsdatenbank abgebildet. Mit dieser zentralen Einheit sind die Einzelbestandteile aus Werkerassistenz, Objektivierung und Automatisierungslösung verknüpft.

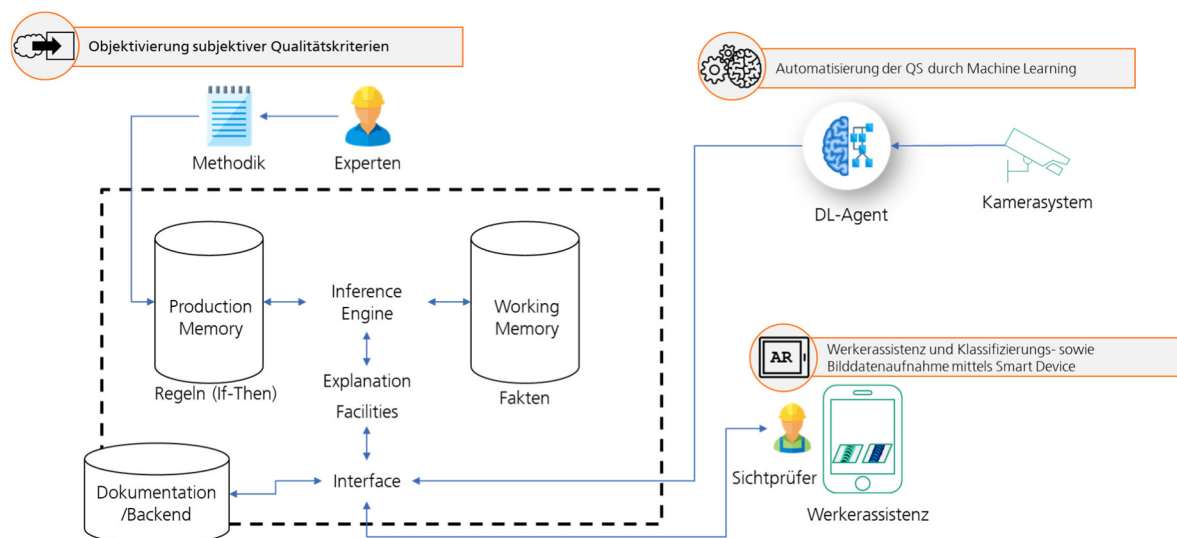


Abbildung 4: Grobkonzept der KOMBI Gesamtlösung

Entscheidungslogik als zentrales Element

Auf Basis der in AP1 gesammelten Anforderungen und Details zu den Anwendungsszenarien, konnte das Konzept der Entscheidungslogik entwickelt werden. Zunächst wurden hierfür bestehende Entscheidungsunterstützungssysteme analysiert, um geeignete Kandidaten auszumachen. Um Mitarbeiter in der Sichtprüfung in Ihrer Entscheidung zu unterstützen, können Expertensysteme (Expert Systems – ES) als Teilbereich der Entscheidungsunterstützung zum Einsatz kommen [63]. Ein ES, bietet dem Benutzer Schlussfolgerungen oder Entscheidungen, die wesentlich besser oder öfter richtig sind, als der Benutzer sein könnte [64–66]. Ein vielversprechendes Modellierungswerkzeug, welches mit den Anforderungen bzw. Gegebenheiten der Anwendungsfälle aus AP1 übereinstimmt, sind Belief Rule-Based Expert Systems (BRBES) [67]. Hierzu verwendet das BRBES die zentralen Elemente der Wissensrepräsentation (Wissensbasis, auch production memory oder Belief-Rule-Base) und einen Inferenzmechanismus (Schlussfolgerungen, auch inference engine) [68]. Wissensrepräsentationen werden als Wenn-Dann-Regeln (belief rule) abgebildet. Diese Regeln umfassen Überzeugungsgrade (belief degrees), eine Gewichtung der Regel (rule weight) und

eine Gewichtung des Input (antecedent attributes) [52, 54]. Mithilfe der Überzeugungsgrade und Gewichtungen können unsichere Informationen abgebildet werden und Erfahrungswissen in den Entscheidungsprozess eingebunden werden [69]. Darüber hinaus können BRBES Entscheidungsträgern direkten Zugang und Transparenz bieten [67, 70, 71]. Perspektivisch besteht die Möglichkeit die Parameter der Wissensrepräsentation mithilfe von ML-Algorithmen zu optimieren [72]. Ein weiterer Grund BRBES zu nutzen, liegt in den vielseitig und erfolgreich umgesetzten Anwendungen [67]. Folgendes vereinfachtes Beispiel stellt den Output des BRBES, so wie es im Grobkonzept vorgesehen ist, dar.

WENN Riss Groß UND Löcher 3 DANN Qualität (70%) Level C, (30%) Level B, (0%) Level A

Der Input bzw. die antezedenten Attribute stellen in diesem Fall die Risse und Löcher dar, welche auf dem Produkt in Ausprägung und Anzahl von einem Sichtprüfer wahrgenommen werden können. Sofern es sich um einen großen Riss und 3 Löcher handelt, wird über den Inferenzmechanismus diese Regel aktiviert. Die Konsequenz bzw. der Output daraus stellt eine Wahrscheinlichkeitsverteilung bezogen auf definierte Qualitätslevel dar. Mathematisch kann dies in folgender Form dargestellt werden [73]:

$$A_i, i \in 1, \dots, I \quad (1-1)$$

Mit den antezedenten Attributen A und einem konsequenten Attribut H kann das BRB Modell wie folgt repräsentiert werden:

$$BRB = \{A_1, \dots, A_i, \dots, A_I, H\} \quad (1-2)$$

Jedes antezedente Attribut hat eine Menge von referenziellen Werten, welche wie folgt dargestellt werden können:

$$A_i = \{A_{v,i}; v = 1, \dots, V_i\} \quad (1-3)$$

Die Variable v in der Gleichung entspricht der Laufvariable für die Anzahl der referenziellen Werte und die Variable i stellt die Laufvariable für die entsprechende Regel dar. Variable v kann unterschiedlich viele referenzielle Werte annehmen. Referenzielle Werte können kategorisch für qualitative Attribute und numerisch für quantitative Attribute sein. Wenn es insgesamt I antezedente Attribute gibt, dann existieren Q qualitative Attribute und J quantitative Attribute mit:

$$I = Q + J \quad (1-4)$$

Jedes im BRBES hinterlegte konsequente Attribut hat lediglich einen Referenziellen Wert hinterlegt. Die Konsequenz ist die Folge eines aktivierten antezedentem Attribut. Die Menge von referenziellen Werten für ein konsequentes Attribut kann wie folgt beschrieben werden als:

$$H = \{h_n; n = 1 \dots \dots, N\} \quad (1-5)$$

In der oben genannten Gleichung ist n als Laufvariable für die Anzahl der konsequenten Attribute anzunehmen. Falls K ($k \in 1, \dots, K$) Regeln in der Regelbasis vorhanden sind, kann der Belief Degree (BD) für jeden einzelnen Referenzwert des konsequenten Attributes wie folgt dargestellt werden:

$$BD = \{(h_1, \beta_{1,k}), \dots, (h_n, \beta_{n,k}), \dots, (h_N, \beta_{N,k})\}, n = 1 \dots N \quad (1-6)$$

Eine Regel ist die Kombination von verschiedenen referenziellen Werten von antezedenten Werten in einem BRBES Modell. Die Struktur kann von der k-ten Regel beschrieben werden als:

$$R_k \{ \text{Wenn: } (A_1 \text{ is } A_{A_i,j}^j) \wedge (A_2 \text{ is } A_{1,2}^2) \wedge \dots \wedge (A_l \text{ is } A_{k,Tk}^k) \}$$

$$\text{Dann: } (h_1, \beta_{1,k}), \dots, (h_n, \beta_{n,k}), \dots, (h_N, \beta_{N,k})$$

$$\text{Summe der Glaubensgrade: } \beta_{n,k} \sum_{n=1}^N \beta_{n,k} = 1 \text{ for all } k \{1..K\} \quad (1-7)$$

$$\text{Gewichtung der Regeln: } \theta_k \leq 1 \text{ for all } k \{1 \dots, K\}$$

$$\text{Gewichtung der Attribute: } \delta_i^k \text{ for all } k \{1, \dots, K\}, i \in \{1, \dots, l\}$$

Der konsequente Teil stellt eine Glaubensverteilungsdarstellung für die Sicherheitsstufe dar, welche besagt das die Regel bspw. zu einem 70%igen Anteil dem Sicherheitsniveau mittelmäßig entspricht und zu einem 30%igen Anteil dem Sicherheitsniveau schlecht entspricht. Bei dieser Glaubensregel beträgt der Gesamtglaubensgrad 1 ($0,3+0,7=1$), sodass die Bewertung vollständig ist. [74]

Für die KOMBI-Gesamtlösung bedeutet dies, dass es mithilfe des BRBRES möglich ist, subjektive Experteneinschätzungen zu Qualitätsausprägungen als auch definierte Regeln aus bspw. Normen für eine Bewertung der Qualität zu nutzen. Zudem können Daten der Automatisierungslösung als auch der Werkerassistenz als Input verarbeitet werden. Unsicherheiten werden durch den Inferenzmechanismus genutzt, um in subjektiven Entscheidungsprozessen möglichst objektiv zu handeln. Als Ausgabe wird dem Nutzer die Entscheidung aufbereitet, inklusive der dazu verwendeten Eingangsdaten und Regeln.

Werkerassistenz

Die Werkerassistenz wurde auf Basis der Anforderungen der ausgewählten Entscheidungslogik und der Anforderungen aus AP1 konzeptioniert. Der Nutzer kann Bilder mit den Smart Devices aufnehmen und diese für eine Verwendung in der Entscheidungslogik und Automatisierungslösung beurteilen und somit labeln. Visualisierte Klassifikationshilfen in Form eines paarweisen Vergleichs stehen nachfolgend dem Sichtprüfer bereit. Die Beurteilung des vorliegenden Produktes geschieht durch Aufzählung und Benennung der Merkmale und deren Ausprägung auf dem zu bewertenden Bild. Dies kann je nach Anwendungsfall individuell durchgeführt werden. Die Bewertung dient als Input zu dem BRBES. Das Labeln der Bilddaten durch die Werkerassistenz für die Automatisierungslösung ist mithilfe dieser Beurteilungsprozesse und der Dokumentationsdatenbank im Konzept abgedeckt.

Darüber hinaus dienen die Smart Devices dazu, den Sichtprüfern kontextabhängige Entscheidungsempfehlungen zu geben, die vom BRBES unter Einbeziehung von Unsicherheiten berechnet wurden. Dabei dient die Smart-Devices-Anwendung als Dialogkomponente des

BRBES und Frontend des Systems. Die Entscheidung, das Frontend der Anwendung auf Smart Devices zu implementieren, basiert auf den Anforderungen aus AP1. Einzelne Geräte können ortsunabhängig genutzt werden. Die Interaktion mit der Anwendung kann während oder direkt nach der Inspektion erfolgen, so dass der Prozess nicht gestört wird. Darüber hinaus können Webcams von der Anwendung gesteuert werden, um überall dort Aufnahmen zu machen, wo der Einsatz von Personal zu gefährlich oder unpraktisch ist.

Um Anforderungen an ergonomischen Aspekten und Hardwareunabhängigkeit gerecht zu werden, wurde entschieden eine Webapplikation für das Frontend zu entwickeln. Die Webapplikation kann Hardwareunabhängig aufgerufen und genutzt werden. Für das Frontend wurden erste Mock-ups der Benutzeroberflächen und Funktionalitäten entwickelt. Zudem wurde für die weitere Entwicklung realitätsnahe Szenarien aufgesetzt, um im Kontext dieser usability Tests durchführen zu können.

Objektivierung

Um die Wissensbasis mithilfe der Werkerassistenz initial aufzusetzen und subjektive Beurteilungen der Qualität aufzunehmen, kann die sogenannte ATZ Skala (erste Vorstellung in der automobiltechnischen Zeitschrift - ATZ) zum Einsatz kommen. Die ATZ Skala ist eine mehrstufige Skala mit unipolaren Skalen. Bei Unipolaren Skalen werden die Items von geringen bis hohe Ausprägungen, wie z.B. gar nicht zufrieden bis sehr zufrieden, beurteilt. Das Bewerten dieser Ausprägungen anhand der Skala basiert auf dem subjektiven Empfinden des Probanden. Diese subjektiven Ausprägungen von Merkmalen können dann in Zahlenwerte umgewandelt werden. [75] Folgende Vorgehensweise für die Objektivierung von subjektiven Qualitätsmerkmalen und -ausprägungen wurde unter Einbezug der ATZ Skala entwickelt:

1. Identifikation und Definition der Prüfmerkmale durch Experteninterviews, Analyse von domänenspezifischen Normen und Standards, oder bereits vorhandenen Prüfanweisungen und Kundenanforderungen
2. Entwicklung der Merkmalsausprägung der Prüfmerkmale:
 - a. Wahrnehmungsschwellen festlegen bei linearen Merkmalen durch Aufnahme von Testfeedback von Probanden oder festlegen eines Referenzwertes
 - b. Priorisierung der Merkmale anhand von Kategorien (Qualitätslevel)
 - c. Typen der Merkmale festlegen
3. Eintragen der Merkmalsausprägungen und des Merkmaltyps in eine ATZ Skala
4. Neue oder überarbeitete Prüfanweisung erstellen
5. Regeln für die Wissensbasis zur Qualitätsbewertung von Produkten aufstellen, aus der sich die initiale Wissensbasis des BRBES ergibt

Automatisierungslösung

Für die Konzeptionierung der Automatisierungslösung wurden selbsttagierende Agenten ausgewählt. Diese können in beliebiger Anzahl mit der Entscheidungslogik verknüpft werden,

sodass mehrere Produktionsstraßen parallel überwacht werden können. Geeignete DL- Algorithmen und vortrainierte DL-Modelle, die in den Agenten die Qualitätsmerkmale und deren Ausprägungen überwachen, wurden auf Basis einer Literaturrecherche ausgewählt. Eine Auflistung befindet sich in der Beschreibung der Arbeiten von AP4. Die Ausgestaltung des Arbeitsplatzes (Lage der Kamera zum Bauteil, Lichtverhältnisse etc.) wurde auch unter Zuhilfenahme der Anforderungen aus AP1 vordefiniert. Die detaillierte Ausgestaltung je Anwendungsfall benötigt jedoch die Untersuchungen aus AP4.

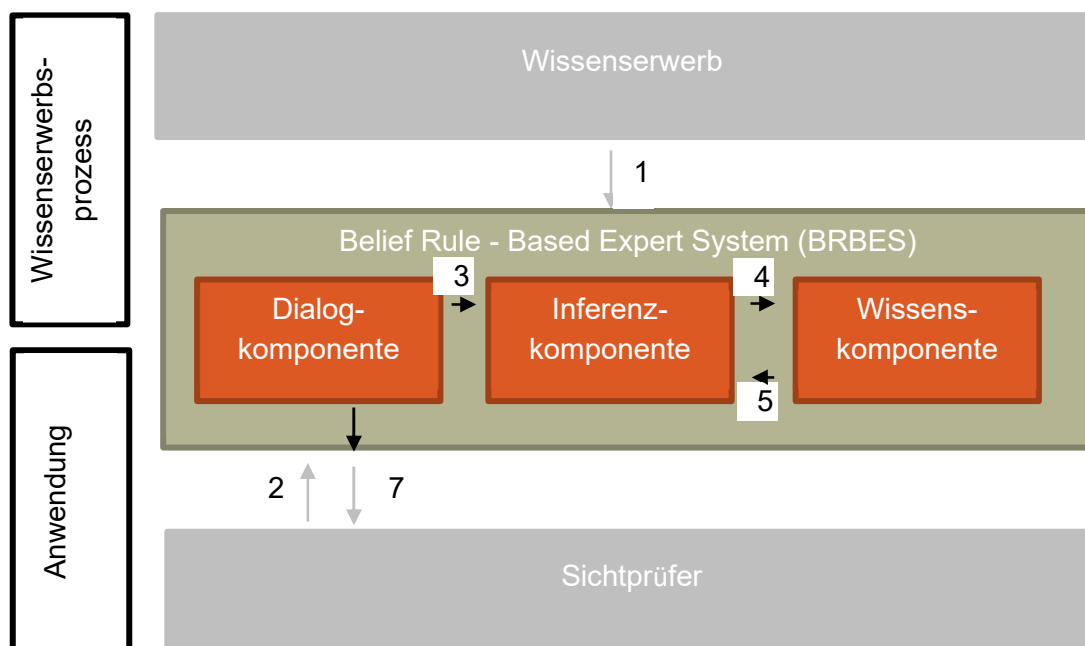
Alle Funktionalitäten des Gesamtkonzeptes wurden in den Leitfaden aufgenommen. Das webbasierte Tool, welches zu Dokumentationszwecken und als Leitfaden dienen soll, wurde prototypisch aufgesetzt, sodass dieses mit Inhalten aus den folgenden Arbeitspaketen angereichert werden kann.

4.5 Arbeitspaket 3: Finale Konzeption der Entscheidungslogik und Implementierung der Werkerassistenz (Teillösung 1)

Auf Basis der vom PA bereitgestellten Anwendungsszenarien und den dafür beschriebenen Qualitätsmerkmalen und deren Ausprägungen, wurde die Entscheidungslogik in Arbeitspaket 3 final konzeptioniert und die Werkerassistenz implementiert. Die Arbeiten in diesem Arbeitspaket fanden in engem iterativem Austausch mit den Arbeiten in AP4 statt, um aufeinander abgestimmte Teillösungen zu erhalten, die eine stimmige Gesamtlösung ergeben.

Finale Konzeption der Entscheidungslogik

Im Allgemeinen haben Expertensysteme keine vorgegebene Gestaltung der Systemarchitektur und der Komponenten. Je nach Komplexitätsgrad, Reifegrad und Anwendungsbereich variiert der Aufbau des BRBES.[76] [74] [77] Von Bedeutung ist die Gestaltung der 2 Hauptkomponenten der Wissensbasis und des Inferenzmechanismus. In Abbildung 5 werden alle Komponenten mitsamt ihren Verknüpfungen dargestellt.



Insgesamt gibt es 6 Verknüpfungen im gesamten BRBES mitsamt den Schnittstellen zum Sichtprüfer und dem Experten. Die erste Verknüpfung verbindet die Wissenserwerbskomponente mit der Wissensbank. Die Wissenserwerbskomponente kann sowohl qualitatives als auch quantitatives Wissen beinhalten. Beim Wissenserwerbsprozess wird das spezifische Wissen des Experten extrahiert und in der Wissensbasis abgespeichert. Hierbei wird das Wissen in Form der zuvor beschriebenen Regeln gespeichert. Die zweite Verknüpfung des Systems liegt zwischen dem Sichtprüfer und der Dialogkomponente. Die Dialogkomponente stellt die Werkerassistenz dar, welche als User Interface und Schnittstelle zwischen dem Benutzer und dem BRBES gilt. Der Input, der über die Schnittstelle an die Inferenzkomponente gegeben wird, hat die Form der identifizierten Merkmale, deren Ausprägung sowie einem bestimmten beliebigem Grad oder Glaubensgrad des Sichtprüfers. Demnach wird in Schritt 3 der Input an den Inferenzmechanismus weitergeleitet. Darauffolgend wird im Schritt 4 der Input mit dem hinterlegten Wissen in der Wissensbasis verglichen und die Regeln aktiviert, welche mit dem Input die größte Übereinstimmung aufweisen. Die aktivierten Regeln werden im Schritt 5 wieder an den Inferenzmechanismus geleitet und dieser ermittelt mithilfe eines hinterlegten Algorithmus an die Dialogkomponente weitergeleitet und dem Sichtprüfer dargestellt. Das Ergebnis des BRBES ist eine Empfehlung, die in sogenannten globalen Regeln hinterlegt ist. Dies könnte Bspw. die Anweisung sein, das Produkt auszusortieren. Im Folgenden werden die einzelnen Komponenten detaillierter erläutert und es wird auf die Vorgehensweise zu deren Entwicklung näher Bezug genommen.

4.5.1 Entwicklungsprozess der Wissenskomponente

Die Wissenskomponente eines BRBES ist maßgeblich für den Output und die Performance des BRBES verantwortlich. Je nach Menge und Varianz der in der Wissensbasis hinterlegten Regeln können unterschiedliche gute Ergebnisse generiert werden. Der in *Tabelle 2* gezeigte Anwendungsfall weist eine geringe hinterlegte Breite an Informationen von Experten auf, was zur Folge hat, dass nur eine begrenzte Anzahl an Regeln aufgestellt und aktiviert werden kann. Diesbezüglich hat die Inferenzkomponente nur einen begrenzten Rahmen zum Schlussfolgern, welche sich negativ auf das Ergebnis hinsichtlich der beliebigem Grades des Outputs auswirken kann. Dahingegen ist für Prüfungsvorgänge von Produkten mit einer großen Menge an Informationen ein qualitativ hochwertigeres Ergebnis möglich, insofern die Inferenzkomponente mit einer größeren Anzahl an Regeln interagieren kann.

Der Entwicklungsprozess der Wissenskomponente des BRBES wird in 4 Schritte unterteilt, die in *Abbildung 6* dargestellt sind.

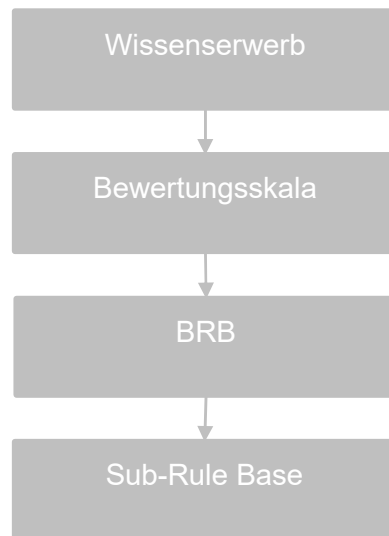


Abbildung 6: Entwicklungsprozess der Wissenskomponente

Wissenserwerbsprozess

Der Erste Schritt des Entwicklungsprozesses der Wissenskomponente beinhaltet den Wissenserwerb. Dieser impliziert das Extrahieren von hinterlegten Daten von Experten, welche dann verwendet werden, um eine Bewertungsskala zu erstellen. Anhand dieser Bewertungsskala können Regeln für die BRB gebildet werden. Das Extrahieren und Zusammenfassen der Daten variiert in ihrer Art und Weise je nach Anwendungsfall und Wissenstyp. Insgesamt wurden für 5 Anwendungsfälle des PA Daten extrahiert und jeweils eine BRB erstellt. Der erste Anwendungsfall beinhaltet die Qualitätsanforderungen einer Klimaplatte. Aufgrund der hohen Anforderungen an das Produkt, wird nach dem letzten Produktionsschritt eine Sichtprüfung durchgeführt. Bei der Sichtprüfung der Klimaplatte werden verschiedenste Anforderungen des Kunden berücksichtigt. Die Informationsquellen der Qualitätsanforderungen entstammen den durchgeführten Interviews mit Experten sowie dem bereitgestellten Bildmaterial. Beim Extrahieren des Wissens anhand von Bildern, müssen die zuvor definierten Merkmalsausprägungen beachtet werden. Beim zweiten Anwendungsfall handelt es sich um ein Zahnrad, bei welchem ebenfalls eine Sichtprüfung durchgeführt wird. In diesem Fall wurden lediglich Bilder als Informationsquellen hinterlegt. Anhand dessen wurde entschieden, bei welchen Merkmalen und Ausprägungen das Zahnrad als n. i. O oder i. O eingestuft wird. Bei den anderen 3 Anwendungsfällen wurde zum Extrahieren der Daten nach dem gleichen Prozess vorgegangen. Alle 5 Anwendungsfälle mitsamt der Regelanzahl in der BRB sind in *Tabelle 3* dargestellt. Die Fünfte Spalte der Tabelle zeigt eine subjektive Bewertung der Schwierigkeit des Wissenserwerbsprozesses durch die Experten.

Tabelle 3: Übersicht des Wissenserwerbs der Anwendungsfälle

	Anwendungsfall	Anzahl der Regeln	Wissensquellen	Schwierigkeitsgrad des Wissenserwerbsprozess
1	Klimaplatte	52	Experteninterview + Bilder	6
2	Zahnrad	15	Bilder	2
3	Laufrolle	35	Kundenanforderungen + Bilder	9
4	Ventilkolben	22	Prüfanweisungen + Bilder	8
5	Frontplatine	7	Experteninterview + Bilder	4

Bewertungsskala

Im Zweiten Schritt des Entwicklungsprozesses der Wissenskomponente wurde anhand der extrahierten Informationen aus den Quellen die ATZ Bewertungsskala generiert. Anhand dieser Skala ist es möglich die Qualität eines Produktes auszudrücken und so ein Qualitätslevel für die jeweiligen Merkmalsausprägungen festzulegen. Insgesamt wurden für 5 Anwendungsfälle, jeweils eine ATZ Skala entworfen. Der Aufbau der Skalen ist bei jeder Skala einheitlich gestaltet. In ABBILDUNG ist die ATZ Skala für den Anwendungsfall der Ventilkolben dargestellt. Dort ist zu erkennen, dass die Tabelle in 3 Spalten aufgeteilt ist. Die Erste Spalte von links beinhaltet die jeweiligen Qualitätsmerkmale, welche durch den Wissenserwerbsprozess entstanden sind. Die Qualitätsmerkmale können quantitativ oder qualitativ sein. Falls das Merkmal quantitativ ist, dann wird dem numerischen Wert ein linguistischer Begriff zugeordnet. Falls das Merkmal qualitativ ist, wird der Begriff so in die Tabelle übernommen. Jedes Qualitätsmerkmal hat individuelle Ausprägungen, welche unterschiedliche Qualitätslevel zur Folge haben. Beispielsweise weist das Qualitätsmerkmal „Druckstelle Bund“ die Ausprägung „groß“ auf, welche dem Qualitätslevel D zugeordnet wurde. Die darüber angeordneten Spalten gelten als Richtwerte für die Qualität eines Produktes. Anhand der Zusammenhänge zwischen den Qualitätsmerkmalen und den Konsequenzen in Form von einer Tabelle, kann für jedes Merkmal eine Regel erstellt werden. Im Folgenden wird dieser Prozess näher beschrieben.

Tabelle 4: ATZ-Skala Ventilkolben

Qualitätslevel	Nicht in Ordnung		In Ordnung	
	D	B	A	
Druckstelle Bund (Hülse)rand	sehr groß	groß	kein	
Bund Roststellen	Vorhanden (braun)	nicht vorhanden		
Beschädigungen				
Bund (Hülse)rand	sehr groß	groß	keine	
Beschädigungen				
Bund 2 (Hülse)rand	gebrochen	nicht gebrochen		
Außendurchmesser	vorhanden	nicht vorhanden		
Beschädigungen				
Zapfen				
Aufwurf zur Planfläche	Vorhanden	nicht vorhanden		
Zapfen				
Beschädigung				
Planfläche		Glanzstelle (ohne Aufwurf)	keine	
Kratzer/Pt				
tiefe	akzeptabel	klein	keine	
Planfläche Fehler				
Planfläche				
Rost	Vorhanden (braun)	nicht vorhanden		
Mantelfläche				
Rost	Vorhanden (braun)	nicht vorhanden		
Stirnfläche				
Rost	Vorhanden (braun)	nicht vorhanden		

BRB (Belief-Rule-Base)

Die Regeln in der BRB werden anhand der oben genannten ATZ Skala in Form von einer WENN-DANN Verknüpfung gebildet. Insgesamt wird für jeden Anwendungsfall mit ATZ-Skala eine BRB gebildet. Die Regeln in einer BRB bestehen aus einem konsequentem und einem antezedentem Teil, die miteinander verknüpft sind. Der antezedente Teil der Regel stellt den „WENN“ Teil dar und der konsequente Teil stellt den „DANN“ Teil dar. In den Anwendungsfällen werden die antezedenten Attribute aus den Qualitätsmerkmalen der Produkte gebildet. Der Anwendungsfall Ventilkolben hat z.B. insgesamt 13 Antezedenten Attribute, denen jeweils pro Attribut individuelle Referenzielle Werte zugewiesen sind. Mit:

$$A_i, i \in 1, \dots, 13.$$

Das Erste Antezedente Attribut hat als Referenzwerte sehr groß, groß und keine hinterlegt, die wie folgt dargestellt werden:

$$(Druckstelle Bund) A_1 = \{A_{1,1}; \text{sehr groß}, \quad A_{2,1}; \text{groß}, \quad A_{3,1}; \text{keine}\}$$

Der konsequente Teil der Regel hat jeweils nur eine bestimmte Anzahl an konsequenten Attributen, welche für jede Regel der BRB verwendet wird.

$$H = \{h_1; Q - \text{Level D}, h_2; Q - \text{Level B}, h_3; Q - \text{Level A}\}$$

Darüber hinaus beinhaltet der konsequente Teil eine Glaubensgrad Verteilung, welche sich auf die Attribute beziehen. Demnach sind die ersten 3 Regeln der BRB wie folgt dargestellt:

- 1) {Wenn: (A_1 ist $A_{1,1}$)
Dann: $\{(h_1, 0,2), (h_2, 0,8)\}$
- 2) {Wenn: (A_1 ist $A_{2,1}$)
Dann: $\{(h_1, 0,2), (h_2, 0,8)\}$
- 3) {Wenn: (A_1 ist $A_{3,1}$)
Dann: $(h_3, 1)$ }

Die Verteilung der Glaubensgrade in den 3 Regeln wurde aufgrund der Hohen Qualitätsanforderungen des Ventilkolbens so ausgewählt, dass wenn der Referenzielle Wert des antezedentem Attributes in der ATZ Skala die Folge Q-Level B entspricht, die Verteilung in 2 Qualitätslevel unterteilt ist. Q-Level B besitzt demzufolge eine Sicherheit von 80% bei der Aussage und Q-Level D besitzt einen 20%igen Anteil. Nach Bedarf können einzelne Regeln mit einem Regelgewicht θ_k und einem Attributgewicht $\overline{\delta_{k_i}}$ gewichtet werden. Aufgrund der hohen Anzahl der Regeln und der möglichen Regelkombinationen, werden die Regeln in so genannte Sub-Rules erweitert.

Sub-Rules

Im Allgemeinen werden Sub-Rules verwendet, um komplexere Entscheidungsmöglichkeiten zu vereinfachen. [74] Anhand des Unterteilens der Wissensbasis in Sub-Rules, können verschiedene Kategorien gruppiert werden und es entstehen spezifische Wissensbasen, die unabhängig voneinander ihre Regeln kombinieren. In dem Anwendungsfall Ventilkolben wurde die Wissensbasis in eine Sub-Rule Base transformiert. Um die 11 Attribute der Qualitätsmerkmale (A1-A11) in jeweils 6 Zwischenvariablen (X1-X6) abspeichern zu können, wurden insgesamt 11 Sub-Rule Bases entwickelt. Anschließend werden die Zwischenergebnisse der einzelnen Sub-Rules aggregiert und es entsteht ein Gesamtergebnis. Bei den anderen Anwendungsfällen wurden die Sub-Rules nach dem gleichen Prinzip entwickelt. Abbildung 4-5 zeigt die Sub-Rule Base für den Anwendungsfall Ventilkolben.

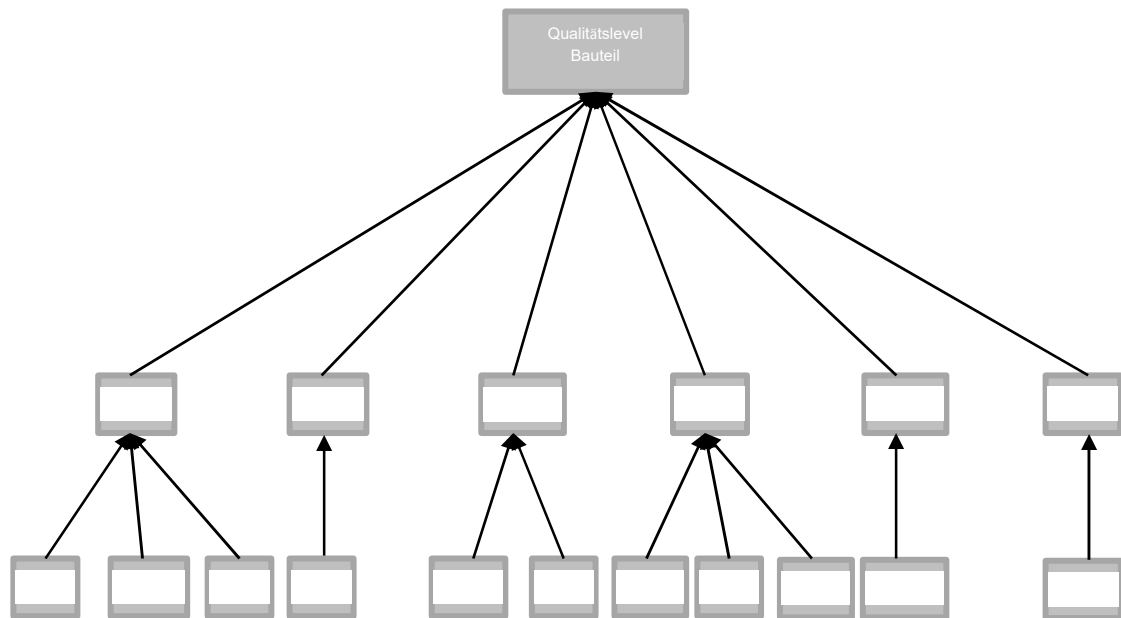


Abbildung 7: Sub-Rules Anwendungsfall Ventilkolben

Um die Regeln in den einzelnen Sub-Rules aktivieren und Schlussfolgerungen erzielen zu können, wird ein Input von dem Sichtprüfer benötigt. Dieser Input muss nach der Eingabe des Sichtprüfers transformiert werden, um weiterverarbeitet zu werden. Das folgende Kapitel zeigt die Inferenzkomponente und ihre Funktion im BRBES.

4.5.2 Inferenzkomponente

Die Inferenzkomponente, auch „Schlussfolgerungskomponente“ genannt, ist für das Schlussfolgern der Ergebnisse des BRBES verantwortlich. Dementsprechend hat die Inferenzkomponente einen großen Einfluss auf die Performance und das Ergebnis des BRBES. Der Entwicklungsprozess der Inferenzkomponente ist nach Yang et. al [74], Hossain et.al. [76] und Liu et.al. [78] in 6 Schritte gegliedert, die wie folgt dargestellt werden:

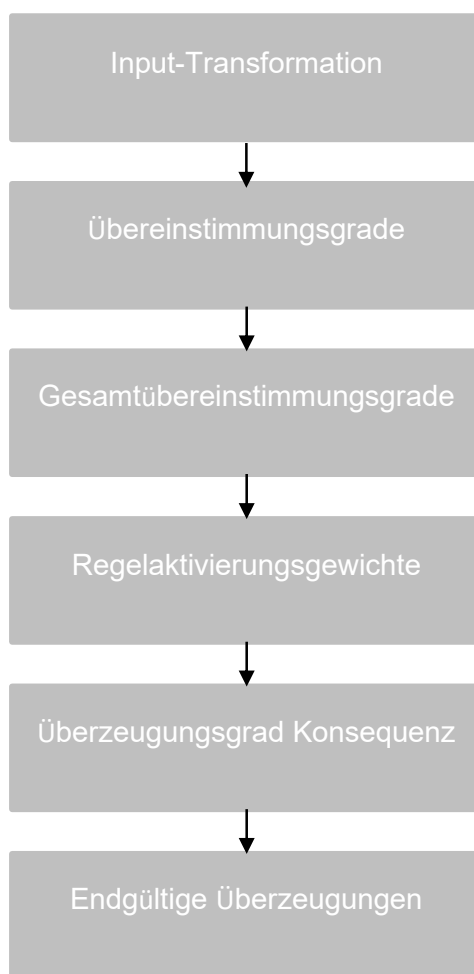


Abbildung 8: Entwicklungsprozess der Inferenzkomponente

Im ersten Schritt des Inferenzmechanismus wird der Input transformiert. Jedes antezedente Attribut kann als möglichen Input verwendet werden. Der Input X eines Sichtprüfers kann als eine Menge von Tulpen in der folgenden Form gemäß YANG et. al. [74] angenommen werden:

$$X = \{(X_1^*; \varepsilon_1) \wedge (X_2^*; \varepsilon_2) \dots \dots (X_T^*; \varepsilon_T)\}, \varepsilon_i \geq 0 \quad (2-1)$$

Die Variable X_1^* steht für den ersten Input des antezedenten Attributes U_i und ε_i steht für den Grad der Überzeugung (Belief Degree) des Inputs, welcher die Unsicherheit der Eingabedaten

des Nutzers widerspiegelt. Um Unsicherheiten und Unwissenheit bei der Wahl des belief degrees einzubinden, wird der belief degree des Inputs transformiert. Das Transformieren kann wie folgt dargestellt werden [76]:

$$\begin{aligned} \text{Wenn } h_{i3} \geq \varepsilon_i \geq h_{i2}, \text{ DANN } \beta_{i2} &= \frac{h_{i3} - \varepsilon_i}{h_{i3} - h_{i2}}, \\ \beta_{i3} &= (1 - \beta_{i2}) \\ \text{Wenn } h_{i2} \geq \varepsilon_i \geq h_{i1}, \text{ DANN } \beta_{i1} &= \frac{h_{i3} - \varepsilon_i}{h_{i3} - h_{i2}}, \\ \beta_{i2} &= (1 - \beta_{i1}), \end{aligned} \tag{2-2}$$

mit $h_{i3} = 100\%$, $h_{i2} = 50\%$ und $h_{i1} = 0\%$ und β_{i1} , β_{i2} , β_{i3} als resultierende belief degrees des Inputs. Die Variable h_{i1} steht in dem verwendeten BRBES für die höchste Sicherheit einer Aussage mit 100 %. h_{i2} steht für eine mittlere Aussagesicherheit mit 50% und h_{i1} für die niedrigste Aussagesicherheit mit 0%. Wenn Beispielsweise der Sichtprüfer eine 90%ige Aussagesicherheit hat, dass der Input dem referenziellen Wert des antezedenten Attributes entspricht, dann wird die Sicherheit der Aussage auf 80 % sehr sicher und 20 % weniger sicher verteilt.

Darüber hinaus kann der Grad der Überzeugung für eine Bewertung $S(X_1^*; \varepsilon_1)$ auf unterschiedliche referenzielle Werte $A_{i,j}$ des antezedenten Attributes U_i verteilt werden. Bei der Variablen $A_{i,j}$ bezieht sich die Laufvariable i zum i-ten antezedenten Attribut von U_i und j steht für den j-ten referenziellen Wert des Attributes i.

Die folgende Gleichung stellt den Zusammenhang zwischen der Bewertung des Inputs mit den hinterlegten Daten in der Wissensbasis dar [74]:

$$S(X_i^*; \varepsilon_i) = \{(A_{i,j}; \alpha_{i,j}); j = 1, \dots, J_i\}, \quad i = 1, 2, \dots, T \tag{2-3}$$

$\alpha_{i,j}$ stellt hierbei den Grad des Glaubens zu welchem der Input X_i^* dem referentiellen Wert $A_{i,j}$ zugeordnet ist. Des Weiteren hat $\alpha_{i,j}$ folgende notwendige Mathematische Bedingungen, mit denen der Input weiterverarbeitet werden kann [74]:

$$\alpha_{i,j} \geq 0 \wedge \sum_{j=1}^{J_i} \alpha_{i,j} \leq 1 \quad (i = 1, 2, \dots, T) \tag{2-4}$$

Beispielsweise hat das erste Antezedente Attribut U_1 (Druckstelle am Bund) in der Wissensbasis des Anwendungsfalles Ventilkolben folgende Referenzielle Werte hinterlegt: $A_{1,1}$ = sehr groß, $A_{1,2}$ = groß und $A_{1,3}$ = keine. Angenommen der Sichtprüfer ist sich zu 90% sicher, dass das Attribut A_1 der Ausprägung $A_{1,2}$ entspricht, dann kann der Input mit der Glaubensgradverteilung wie folgt dargestellt werden.

$$S(X_1^*; \varepsilon_1) = \{(sehr\ groß; 0), (groß, 0,8), (keine, 0,2)\} \tag{2-5}$$

Im Nächsten Schritt werden die einzelnen Übereinstimmungsgrade der Inputs berechnet. Diese quantifizieren die Inputs des Benutzers mit den Referenzwerten der erstellten [74, 76] Regeln in der Wissensbasis. Im Allgemeinen kann die Gleichung nach YANG et. al. [74] wie folgt dargestellt werden:

$$\alpha_{ij} = \frac{\tau(A_i^*, A_{ij})\varepsilon_i}{\sum_{j=1}^{J_i} [\tau(A_i^*, A_{ij})]} \quad (2-6)$$

$\tau(A_i^*, A_{ij})$ ist der Zuordnungsgrad zwischen dem Input A_i^* und A_{ij} . Dieser entspricht dem Wert 1, wenn der Input komplett dem j-ten linguistischen Wert entspricht. Für die entwickelten BRB entspricht der Input des Benutzers in jedem Fall der hinterlegten Referenz des Attributes.

Angenommen der belief degree ist $A_{1,2} = 0,8$ und $A_{1,3} = 0,2$ dann ist der individuelle Übereinstimmungsgrad für die beiden referenziellen Werte:

$$\alpha_{1,1} = 0,8 \text{ und } \alpha_{1,2} = 0,2.$$

Anhand dieser individuell berechneten Übereinstimmungsgrade werden die Gesamtübereinstimmungsgrade der Regeln berechnet. Der Gesamtübereinstimmungsgrad α_k einer Regel kann nach RIMER [74] wie folgt berechnet werden:

$$\alpha_k = \prod_{i=1}^{T_k} (\alpha_i^k)^{\overline{\delta_{ki}}} \quad (2-7)$$

Mit

$$\overline{\delta_{ki}} = \frac{\delta_{ki}}{\max_{i=1, \dots, T_k} \{\delta_{ki}\}}$$

Die Laufvariable k in der Gleichung iteriert jede Regel der Wissensbasis durch. α_i^k entspricht den vorher bestimmten Werten in der Gleichung (2-3) und $\overline{\delta_{ki}}$ entspricht den von den Experten generierten Attributgewichte der k-ten Regel. δ_{ki} entspricht die Attributgewichte der einzelnen Attribute der k-ten Regel. Die Laufvariable i entspricht den antezedenten Attributen einer Regel k. [74]

Im nächsten Schritt werden unter Verwendung der Gesamtübereinstimmungsgrade α_k und der Regelgewichte θ_k gemäß Gleichung (2-5) nach YANG et. al. [74] das Regelaktivierungsgewicht berechnet. Das Regelaktivierungsgewicht ω_k gibt die Wichtigkeit einer Regel in der Wissensbasis angesichts eines Inputs X_i^* an.

$$\omega_k = \frac{\theta_k \alpha_k}{\sum_{i=1}^L \theta_i \alpha_i} \quad (2-8)$$

Regeln können je nach Ausprägungen der antezedenten Attribute in einer Regel gewichtet werden. Angenommen eine Sub Rule Base besteht aus insgesamt 3 Regeln. Regel 1 hat eine Regelgewichtung von 1, Regel 2 hat eine Regelgewichtung von 0,6 und Regel 3 hat eine Gewichtung von 0,8. Das hat zur Folge, dass die erste Regel einen Größeren Einfluss bei der

Regelaggregation hat als die anderen beiden Regeln, da diese mit 60% und 80% respektive eine geringere Gewichtung haben.

In dem folgenden Schritt werden die Überzeugungsgrade der Konsequenzen bestimmt. Der Überzeugungsgrad $\overline{\beta_{ik}}$ in dem i-ten möglichen konsequenten Attribut ist bereits gegeben, wenn die BRB entwickelt ist mit $0 < \sum_{i=1}^N \overline{\beta_{ik}} \leq 1$. Die Regel ist komplett, wenn $\overline{\beta_{ik}} = 1$ entspricht und unvollständig, $\overline{\beta_{ik}} < 1$ ist. Da die entwickelten BRB auf Vollständigkeit des Inputs und der Wissensbasis basieren, kann dieser Schritt vernachlässigt werden.

Letztlich werden die Regeln einer Sub-Rule Base miteinander aggregiert und es entstehen endgültige Schlussfolgerungen. Diese Aggregation kann durch einen rekursiven oder analytischen ER-Ansatz durchgeführt werden. [76] Aufgrund der rechnerischen Komplexität des rekursiven Ansatzes, wird der Analytische ER- Ansatz nach Hossain.et.al [76] verwendet. Demnach kann die finale Schlussfolgerung $C(Y)$ mitsamt den referenziellen Werten der konsequenten Attribute O_j mittels der folgenden Gleichungen berechnet werden:

$$C(Y) = S(l_i) = \{ (O_j, \beta_j), j = 1, \dots, N \} \quad (2-9)$$

Mit β_j , als belief degree für ein referenziellen Wert eines konsequenten Attributes, welches wie folgt dargestellt werden kann. [74]

$$\beta_j = \frac{\mu \times [\prod_{k=1}^L (\omega k \beta_{jk} + 1 - \omega k \sum_{j=1}^N \beta_{jk}) - \prod_{k=1}^L (1 - \omega k \sum_{j=1}^N \beta_{jk})]}{1 - \mu [\prod_{k=1}^L (1 - \omega k)]} \quad (2-10)$$

mit

$$\mu = [\sum_{j=1}^N \prod_{k=1}^L ((\omega k \beta_{jk} + 1 - \omega k \sum_{j=1}^N \beta_{jk})) - \prod_{k=1}^L (1 - \omega k \sum_{j=1}^N \beta_{jk})]^{-1} \quad (2-11)$$

Das Endgültige Ergebnis stellt eine Glaubensgradverteilung jedes Referenziellen Attributes dar. Anhand dessen kann der Sichtprüfer entscheiden welche Qualitätsstufe dem Bauteil zugeordnet werden kann.

4.5.3 Feinabstimmung

Die Feinabstimmung des BRBES umfasste Änderungen an dem Inferenzmechanismus, die nach dem Entwickeln der Inferenzkomponente vorgenommen wurden. Im Allgemeinen wurden zwei wesentliche Änderungen vorgenommen. Zum einen die Einführung eines Knock-out Kriteriums und zum anderen die Anpassung der Glaubensgradverteilung der Schlussfolgerungen.

Ein „Knock-out“ Kriterium ist eine Funktion, die es ermöglicht, dass wenn ein Attribut ein Ausschlusskriterium als Referenz annimmt, mit sofortiger Wirkung mit n. i. O. gewertet wird. Angenommen der Sichtprüfer gibt mehrere Inputs in das System ein und ein Wert eines referenziellen Attributes entspricht als Konsequenz das Qualitätslevel D (das Level bei dem

Produkte n. i. O. sind), dann wird der gesamte Input als n. i. O. gewertet. Eine Knock-out Regel für den Anwendungsfall Ventilkolben kann demnach wie folgt aussehen.

$$\begin{aligned} & \text{Wenn}(\text{DruckstelleBund} == \text{sehrgro\ss}, \varepsilon_i = 1) \\ & \text{Dann} (Q - \text{Level D} == 1) \end{aligned} \tag{3-1}$$

In dieser Regel aktiviert der linguistische Wert „sehr groß“ und der belief degree von 1 das Knock-out Kriterium. Demzufolge ist der Sichtprüfer sich in diesem Fall zu 100% sicher, dass das Attribut „Druckstelle Bund“ die Referenz „sehr groß“ annimmt. Diese gilt als Ausschusskriterium in der ATZ-Skala, da es die Qualitätsstufe D annimmt.

Die zweite Änderung ist eine Anpassung der Glaubensgradverteilung der Schlussfolgerungen. Aufgrund der unterschiedlichen Regelkombinationen in den Sub-Rule Bases und der danach folgenden Regelaggregation aller aktivierten Sub-Rules, können unterschiedliche Qualitätsmerkmale in den jeweiligen Sub-Rules als Endergebnisse generiert werden.

Diese Schlussfolgerungen geben nicht immer eine direkte Entscheidungsunterstützung für den Sichtprüfer, aufgrund der minimalen prozentualen unterschiede der Ergebnisse. Angenommen eine Regelkombination, welche durch mehrere Inputs aktiviert wurde, geben als Endergebnis eine Glaubensgradverteilung von Q-Level A= 32%, Q-Level B= 33% und Q – Level D = 35% an. Hier ist es für den Sichtprüfer nicht eindeutig in welche Qualitätsstufe dieser das Produkt einordnen kann. Diesbezüglich wird die Glaubensgradverteilung der Outputs wie folgt durchgeführt. Im ersten Schritt wird der belief degree mit dem höchsten Wert, mit dem anderer belief degrees verglichen. Der Vergleich bezieht sich hierbei auf die Prozentualen Endergebnisse der anderen Qualitätsstufen. Demnach wird der zweitgrößte Wert aller anderen Werte in Betracht gezogen. Falls dieser in einem Abstand von 0-5% liegt, wird daraufhin die folgende Gleichung zur Glaubensgradverteilung angewendet:

Prozentual höchstes belief degree:

$$\begin{aligned} & \text{Wenn Endergebnis } \beta_j == \text{Max}(\beta_j), \\ & \text{Dann } (\text{Max}(\beta_j) + \sum_{i=1}^{Ji} \beta_j/2) * 0,6 \text{ Sonst } \beta_j / 2 \end{aligned} \tag{3-2}$$

Zweithöchstes Belief Degree:

$$\begin{aligned} & \text{Wenn Endergebnis } \beta_j == \text{Max}(\beta_j), \\ & \text{Dann } (\text{Max}(\beta_j) + \sum_{i=1}^{Ji} \beta_j/2) * 0,4 \text{ Sonst } \beta_j / 2 \end{aligned} \tag{3-3}$$

Gleichung (3-2) beschreibt eine Wenn-Dann Verknüpfung zwischen dem belief degree mit dem prozentual größten Wert und den restlichen belief degrees. Hierbei wird beim Aktivieren des

Wenn Teils, das belief degree mit dem höchsten Wert ein 60%iger Anteil der restlichen belief degrees dividiert durch 2 zugewiesen. Bei dem nicht-Aktivieren des Wenn Teils wird der Wert des belief degrees halbiert. Gleichung (3-3) beschreibt denselben Zusammenhang mit jedoch einer 40%igen Gewichtung der restlichen belief degrees, bei Aktivierung des Wenn-Teils.

Des Weiteren werden bei einem Abstand von 10-20% zwischen den höchsten und zweithöchsten Werten identische Gleichungen zur Glaubensgradverteilung verwendet, jedoch mit einer Änderung. Diese Änderung beinhaltet einen 70%ige Gewichtung für das Prozentual höchste belief degree und 30% für das zweithöchste belief degree.

Mithilfe der beschriebenen Vorgehensweisen zur Entscheidungsunterstützung werden zwei Werte mit einem marginalen prozentualen Abstand dem Sichtprüfer als Schlussfolgerung vorgeschlagen. Darüber hinaus bedeutet das Ergebnis, dass bei einem erhöhten Abstand zwischen den belief degrees, die Glaubensgradverteilung eindeutiger wird. Wird z.B. ein Abstand über 20% zwischen dem höchsten Wert und den restlichen Werten generiert, wird der höchste Wert mit 100% gewichtet. Angenommen die Ergebnisse der Inputs der Sub-Rule-Bases haben folgende Schlussfolgerungen in Tabelle 5 generiert:

Tabelle 5: Darstellung Beispielhafter Glaubensgradverteilungen

	Q-Level A	Q-Level B	Q-Level D
Ergebnis 1	60%	20%	20%
Ergebnis 2	3%	80%	17%
Ergebnis 3	30%	32%	38%
Ergebnis 4	35%		65%
Zwischensumme	128%	132%	140%
Ergebnis:	32%	33%	35%
Endergebnis	16%	39%	45%

Demzufolge sind die Ergebnisse 1-4 die einzelnen Ergebnisse bezogen auf die Inputs in den Sub-Rules. Die Qualitätslevel A-D stellen die konsequenten Attribute dar und die prozentualen Werte stehen für die belief degrees der Attribute. Die Zeile Zwischensumme zeigt die kumulierten Zwischenergebnisse der einzelnen Qualitätsstufen. Demnach beschreibt die Zeile Ergebnis die Zwischensumme der Q-Level in Relation zur Menge der Ergebnisse (Insgesamt 4). Diese Ergebnisse zählen als endgültige Schlussfolgerungen des Systems. Da die Ergebnisse sich prozentual marginal unterscheiden, ist der Sichtprüfer bei einer Entscheidung der Qualitätslevel des Produktes unsicher. Aufgrund dessen wurden anhand der Gleichung (2-10) Endergebnisse generiert, welche die Funktion haben, das Ergebnis mit dem größten prozentualen Anteil als Empfehlung für den Sichtprüfer zu setzen.

4.5.4 Implementierung der Werkerassistenz

Auf Basis der Anforderungen und Erkenntnisse aus AP1 und AP2 wurde die Benutzeroberfläche (Frontend) der Werkerassistenz gestaltet. Eine prototypische Testumgebung wurde am Fraunhofer IPT aufgesetzt, mit der es möglich ist, das Gesamtkonzept umzusetzen und bspw. die Werkerassistenz in einer möglichst realistischen Umgebung (Infrastruktur, Backend, Arbeitsplatz) testen zu können. Ein erster Prototyp wurde durch usability testing in realistischen Szenarios weiterentwickelt.

Die Systemarchitektur der Werkerassistenz ist in Abbildung 9 dargestellt. Das Frontend bzw. User Interface der Werkerassistenz ist als Client in der Architektur abgebildet. Über dieses können Sichtprüfer mit dem Gesamtsystem interagieren. Das Frontend ist als Webanwendung mit dem React-Framework realisiert und ermöglicht so eine einfache Skalierung auf andere Produktionsstandorte und Devices, mit denen eine Sichtprüfung durchgeführt werden soll. Das Backend mit Komponenten wie dem BRBES und den DL-Modellen ist mit Flask und Docker realisiert.

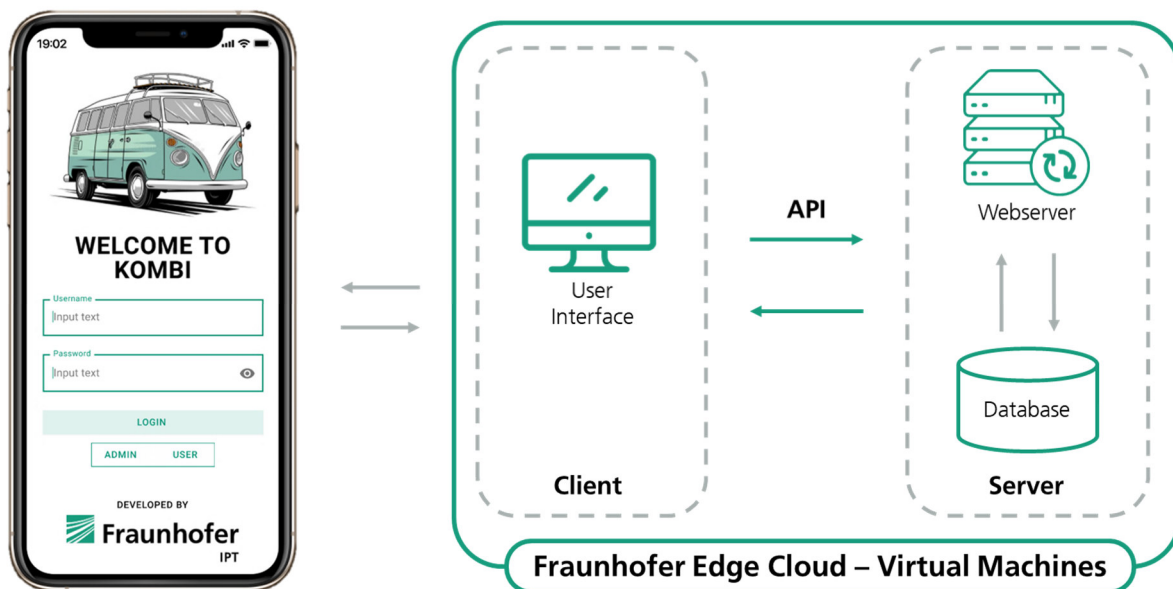


Abbildung 9: Systemarchitektur der Werkerassistenz

Das Frontend ist als Single Page Application Architektur programmiert worden. Im Detail wurden für die Erstellung das Next.js-Framework und das React.js verwendet. Die verwendeten Programmiersprachen umfassen Javascript, JSX, HTML und CSS. Der Code wird im Browser gespeichert und erledigt alle clientseitigen Aufgaben:

- Authentifizierung auf der Grundlage von Cookies
- Zwischenspeicherung von Sitzungen und Daten

- Anzeige von Informationen und Senden von Daten auf der Grundlage von Benutzerinteraktionen
- Die Interaktion mit der Datenbank des Servers erfolgt über APIs

Das Backend ist per API (Application Programming Interface) mit dem Frontend verknüpft. Die Realisierung des Backends umfasste die Entwicklung von Modellen, die die Tabellen in der Datenbank erstellen. Zudem wurden Schemes erstellt, welche die Tabellen und Abhängigkeiten zwischen ihnen definieren. Somit können Daten innerhalb des Backends effizient verarbeitet werden. Da im Frontend Jsons verwendet werden, war es nötig, Views zu programmieren, die die Aktionen/Endpunkte darstellen und als sogenanntes "crude" durchgeführt werden (create, update, delete etc.). Schemes übersetzen auch, welche Views aus den Modellen als Json dargestellt werden (ID, Benutzername etc.).

4.6 Arbeitspaket 4: Finale Konzeption und Implementierung der Automatisierungslösung (Teillösung 2)

Für die finale Konzeption und Implementierung der Automatisierungslösung, wurde der Fokus auf zwei Hauptaspekte im Projekt gelegt. Zum einen auf die Erstellung eines Bilddatensatzes aus den von den PA Mitgliedern bereitgestellten Proben. Zum anderen die Konzeption und Implementierung einer Deep Learning-Pipeline zur Verarbeitung der Bilddaten.

4.6.1 Erstellung eines geeigneten Bilddatensatzes

Zunächst wurden anhand des von den Unternehmen bereitgestellten Probensatzes, Bilddaten aufgenommen. Zu den Anwendungsfällen dieser Proben lagen ebenfalls aus AP1 die Anforderungen und Beschreibungen der Sichtprüfung (inklusive der Beschreibung der Produktionsumgebung) vor. Diese dienten dazu, Bilder unter realitätsnahen Bedingungen, wie sie in der Produktion vorzufinden sind, aufzunehmen und zu labeln. Im Folgenden wird die Versuchsplanung, die zur Aufnahme der Bilder genutzt wurde, die verwendeten Materialien und die resultierenden Bilddatensätze, präsentiert.

Methodik zur Erstellung geeigneter Bilddatensätze

Für die Aufnahme der Bilder wurden Untersuchungen zum Effekt der Umweltbedingungen durchgeführt. Wichtige Parameter, die einen Einfluss auf die Bildaufnahme haben, stellen die Beleuchtung und den Bildhintergrund dar. Diese spezifischen Umweltbedingungen wurden ausgewählt, da sie in bestehende Produktionsumgebungen kontrolliert werden können und diese auf Grundlagen von Studien einen großen Einfluss haben könnten. Auf Basis dieser beiden Größen wurde ein Versuchsplan mit sechs Versuchsaufbauten erstellt. Jede Versuchsanordnung stellt einen Datensatz dar. Die Beleuchtung wurde zwischen niedrig (nur der Deckenstrahler), neutral (ein LED-Strahler) und hoch (zwei LED-Strahler) variiert. Bei den beiden LED-Scheinwerfern handelt es sich um F&V K4000S LED-Panel. Jedes Panel erzeugt eine maximale Helligkeit von 6420 Lux in 1 m Entfernung. Das entsprechende Farbspektrum kann zwischen

3200 und 5600 K eingestellt werden. Der Deckenstrahler ist eine Standard-Leuchtstoffröhre und erzeugt eine diffuse Beleuchtung der Proben. Mögliche Hintergründe werden zwischen glatt und verrauscht unterschieden. Ein Glatter Bildhintergrund ist durch eine homogene, glatte Oberfläche in einheitlicher Farbe gekennzeichnet. Der verrauschte Hintergrund besteht aus einer heterogenen, mit unterschiedlichen Objekten versehenen, Komposition. Es wurden alle möglichen Konfigurationen aus Beleuchtung und Hintergrund getestet. Mit diesen Variationen von Beleuchtung und Hintergrund wird ein Spektrum zwischen einer üblichen verrauschten, lichtarmen Produktionsumgebung und einer gut beleuchteten, sauberen Umgebung simuliert. Die Konfigurationen sollte darüber aufschluss geben, wie die Umgebungsbedingungen während der Bildaufnahme die Leistung der DL-Modelle beeinflussen. Da die Automatisierungslösung zur Fehlererkennung auf Smart Devices läuft, wurde die integrierte Kamera eines Smartphones zur Bildaufnahme verwendet. Bei dem für die Aufnahmen verwendeten Smartphone handelt es sich um ein Nokia 5 aus dem Jahr 2017. Die resultierenden Anordnungen des Versuchsplans sind in Abbildung 10 schematisch dargestellt.




Abbildung 10: Schematische Darstellung der Versuchsaufbauten mit unterschiedlichen Lichtquellen und Bildhintergründen

Die aufgenommenen Bilder wurden anschließend vorverarbeitet, um Datensätze mit hoher Qualität für den Trainingsprozess der DL-Modelle zu erhalten. Dazu wurden die Defekte in jedem Bild mit einem Nachbearbeitungsverfahren manuell gelabelt. Fachexperten lieferten die notwendigen Informationen, um das korrekte Label der Defekte zu gewährleisten. Labelling, eine Open-Source-Software, wurde verwendet, um die Defekte zu labeln, indem sie in einem rechteckigen Rahmen eingezeichnet werden. Jedes Bild kann mehrere Defekte unterschiedlicher Art und Größe enthalten. Da die untersuchten Produkte im Vergleich zu den einzelnen Fehlern sehr groß sind, können die Bilder nicht direkt mit einem DL-Modell verarbeitet werden. Stattdessen wurde ein Sliding-Window-Ansatz verwendet, bei dem kleinere Bildausschnitte extrahiert wurden. Folgende drei Bildverarbeitungsschritte wurden dazu durchgeführt:

- **Downscaling:** Die ursprüngliche 4K-Bildauflösung wurde um den Faktor 4 herunterskaliert. Dadurch wurden sowohl die Breite als auch die Länge des Bildes durch einen Faktor von 2 verringert. Der Faktor für die Verkleinerung wurde so gewählt, dass die Sichtbarkeit kleiner Defekte erhalten bleibt aber auch die Berechnungszeiten der DL-Modelle beschleunigt werden.
- **Sliding window:** Ein rechteckiger Bildausschnitt (sliding window) wird über die Länge und die Höhe des Bildes geschoben, um kleinere Teile des Bildes zu extrahieren. Jedes Feld hat eine maximale Auflösung von 224 x 224 px, was den Standards der meisten DL-Modelle entspricht.
- **Labeling der Ausschnitte:** Jeder Bildausschnitt wird gelabelt, indem die Überlappung des Ausschnittes mit einer Umrandung der Defekte, die auf der jeweiligen Oberfläche auftritt, berechnet wird. Wenn die Überlappung zwischen Ausschnitt und Umrandung einen bestimmten Schwellenwert überschreitet, wird der Ausschnitt entsprechend dem Defekt gelabelt.

Als Ergebnis der Vorverarbeitung bestand jeder Datensatz aus 224 x 224 Bildausschnitten, die entweder zu einer der verschiedenen Defektklassen oder zur Klasse der Nicht-Defekte gehören. Jede Klasse wird anschließend in einem Verhältnis von 60 %, 20 % und 20 % in ein Trainings-, eine Validierungs- und eine Testsample aufgeteilt. Die begrenzte Anzahl von Produkten für beide Anwendungsfälle machte die Implementierung der 5-Fold Cross-Validation notwendig, um eine Verzerrung der Ergebnisse aufgrund einer bestimmten Aufteilung des Datensatzes zu vermeiden. Da sich die untersuchten Produkte hinsichtlich der Anzahl der Defekte pro Typ deutlich unterschieden, wiesen die Datensätze ein Ungleichgewicht der Klassen auf. Um diesem Ungleichgewicht während des Lernprozesses des DL-Modells entgegenzuwirken, wurde für jeden Trainingsatz eine Bilddatenaugmentierung verwendet. Eine zufällige Kombination der folgenden Augmentierungstechniken wurden angewendet, um die Klassen auszubalancieren:

- **Cropping:** Ein zufälliger kleinerer Bildausschnitt wird aus dem gesamten Bild extrahiert. Bei dieser Technik muss der extrahierte Ausschnitt auf Defekte überprüft werden, um zu gewährleisten, dass das Label erhalten bleibt.
- **Flipping:** Der Bildausschnitt wird nach dem Zufallsprinzip entweder um die horizontale oder vertikale Achse oder um beide Achsen gedreht.
- **Color Space Manipulation:** Konvertiert das Bild von seinem ursprünglichen RGB Farbraum in den HSV-Farbraum. Im HSV-Farbraum werden Sättigung und Helligkeit innerhalb eines kleinen Spektrums zufällig verändert. Der veränderte Pfad wird dann zurück in den RGB-Farbraum konvertiert.

Am Ende des Bildverarbeitungsschritts wurden sieben Bilddatensätze erzeugt, die aus den sechs verschiedenen Umgebungsbedingungen und dem Optimierungsdatensatz bestehen. Jeder Datensatz wird in fünf verschiedene Folds unterteilt, die wiederum aus einem Trainings-, einem Validierungs- und einem und einem Testdatensatz bestehen.

Die Methodik wurde auf zwei Anwendungsfälle, die vom PA bereitgestellt wurden, angewendet. Hierfür wurden 26 Kalziumsilikatplatten (Anwendungsfall 1) und 34 Stahlrohre (Anwendungsfall 2) zur Verfügung gestellt.

Ergebnisse für Anwendungsfall 1

Bei jeder Bildaufnahme der Kalziumsilikatplatten wurden die Vorder-, die Rück- und die vier Seitenflächen jeder Platte fotografiert. Für jeden Datensatz wurden insgesamt etwa 162 Bilder aufgenommen. Die Auswirkung der Beleuchtungsbedingungen auf die Bilder sind in Abbildung 11 zu sehen. Die Platten auf den Bildern weisen mehrere Einkerbungen auf der Oberfläche sowie Bruchstellen in der Nähe der Kanten auf. Bei schlechten Lichtverhältnissen (Teilbild (a)) sind die Vertiefungen kaum sichtbar, während sich der Bruch an der linken Seite der Platte noch vom Hintergrund abhebt. Bei Verwendung eines LED-Strahlers (Teilbild (b)) werden die Defekte durch eine Schattierung des näher an der Lichtquelle liegenden Teils des Defekts hervorgehoben. Mit zwei LED-Strahlern (Teilbild (c)) sind die Defekte deutlich sichtbar, aber stark ausgeleuchtet. Die Bildqualität während der Aufnahme wird sowohl durch die genauen Beleuchtungsbedingungen als auch durch die technischen Möglichkeiten der Smart Devices begrenzt. Während der Aufnahme der Bilder werden die Grenzen der Kameras deutlich. In einigen Fällen braucht die Kamera mehrere Sekunden, um die Oberfläche der Platten zu fokussieren. Dieser Effekt wird bei schlechten Lichtverhältnissen noch verstärkt. Insgesamt sind die aufgenommenen Bilder aufgrund der begrenzten technischen Möglichkeiten und der suboptimalen Beleuchtungsbedingungen für moderne Fotografie-Standards von geringer Qualität. Dennoch sind die Defekte in den meisten Fällen von den nicht-defekten Teilen der Produkte zu unterscheiden.




Abbildung 11: Auswirkungen der Beleuchtungsbedingungen auf die Bilder der Kalziumsilikatplatten von links nach rechts: (a) Deckenstrahler (b) 1 LED-Strahler (c) 2 LED-Strahler

Die anschließende Vorverarbeitung umfasst das Labeln der Defekte, die Unterteilung der Bilder in Ausschnitte und die Verarbeitung der Ausschnitte zu Datensätzen. Das Label Block definiert die gesamte Oberfläche der jeweiligen Seite der Platte ohne mögliche Defekte. Alle anderen Label entsprechen ihrer jeweiligen Defektkategorie. Diese lauten Block, Riss, Bruch, Rille, Ausspülung, Eindrückung und Verunreinigung. Samples der Kategorie Block weisen die größten Umrandungen in Höhe und Breite auf. Die meisten Defekte sind in der unteren linken Ecke zu finden. Risse und Rillen weichen sowohl in der Breite als auch in der Höhe von den anderen Fehlern ab. Unreinheiten machen die meisten der kleinsten Defekte mit einer Höhe und Breite

unter 100 px aus. Auf der Grundlage dieser Werte für die Abmessungen der Defekte können die durchschnittlichen Klassengrößen berechnet werden. Tabelle 6 zeigt die Anzahl der Objekte, die durchschnittliche Höhe, die durchschnittliche Breite und den prozentualen Anteil der abgedeckten Fläche für jede Klasse. Die Block Kategorie der nicht Defekten Bereiche macht mit etwa 97 % der Gesamtfläche die große Mehrheit aus. In den verbleibenden 3 % der Fläche machen Risse fast die Hälfte der defekten Fläche aus. Brüche und Rillen sind die zweit- und drittgrößte Fehlerklasse mit jeweils mehr als 0,5 % der Fläche. Am unteren Ende des Spektrums befinden sich Verunreinigungen, die 0,034 % der Fläche einnehmen und damit die geringste Anzahl von Pixeln unter allen Klassen darstellen. Außerdem weisen Risse im Durchschnitt eine viel größere Breite als Höhe auf, während alle anderen Defekte ein gleichmäßigeres Seitenverhältnis aufweisen. Nachdem die Bilder in gelabelte Ausschnitte unterteilt wurden, werden die Ausschnitte in Teilmengen von Trainings-, Validierungs- und Testsätzen aufgeteilt. Jeder Trainingsdatensatz wird anschließend augmentiert, um das Ungleichgewicht der Klassen auszugleichen. Nach der gezielten Augmentierung der Minderheitsklassen erhalten wir sieben Datensätze mit jeweils 600 Instanzen.

Tabelle 6: Übersicht der Eigenschaften der Klassen des Datensatzes von Anwendungsfall 1

Label	Anzahl	Durchschnittl. Höhe in px	Durchschnittl. Breite in px	Flächen in %
Block	162	1086	3232	97,02
Riss	39	236	1121	1,382
Bruch	51	220	337	0,659
Rille	28	496	446	0,550
Ausspülung	20	301	259	0,288
Eindrückung	13	209	132	0,070
Verunreinigung	21	88	89	0,034

Ergebnisse für Anwendungsfall 2

Wie im ersten Anwendungsfall wurden die Ergebnisse der Erstellung des Datensatzes von Stahlrohren mit der beschriebenen Methodik durchgeführt. Die Lage der Defekte auf den Rohren macht es erforderlich, Bilder von der Außenfläche, der Innenfläche und den beiden Enden des Rohrs zu machen. Die äußere Oberfläche der Rohre reflektiert einfallendes Licht stark. Diese Reflexionen überdecken oft die Oberflächenfehler. Abbildung 12 zeigt zwei Beispielbilder, bei denen dieser Effekt an der Außenfläche des Rohres auftritt.




Abbildung 12: Reflexionen auf der Metalloberfläche während der Bildaufnahme

Beide Rohre auf den Bildern weisen Kratzer an der Außenfläche auf. Der Verlauf der Kratzer kann nicht vollständig nachvollzogen werden, da die Reflexionen lokal besser sichtbar sind als die Oberflächenstruktur. Daher kann der Umriss des Defekts nicht eingegrenzt werden und der entsprechende Defekt bleibt ungelabelt. Beim Fotografieren der Innenflächen muss die Kamera sehr nahe an eines der Rohrenden herangeführt werden, um genügend Fläche zu erfassen. Entweder sind nur kleine Teile des Innenrohrs im Fokus oder die Kamera kann keinerlei Fläche fokussieren. Die Rohrenden sind der verbleibende Bereich mit möglichen Defekten. Die Rohrenden müssen in der Nachbearbeitung der Produktion entgratet werden. Der Grat tritt willkürlich am inneren oder äußeren Rand in der Nähe der Öffnung auf. Der vom Grat betroffene Bereich ist klein, selbst wenn die Kamera nahe an das Rohr herangeführt wird. Entgratete Rohre weisen eine Fase an der Innen- und Außenseite des Randes auf, wo der Grat entfernt wurde. Beim Fotografieren der Rohrenden fokussiert der Autofokus des Smartphones in einigen Fällen nicht auf den entsprechenden Bereich. Auch diese unscharfen Bilder werden in die Datensätze integriert.

Aufgrund der Beschriebenen Probleme durch Reflexionen und Limitationen der Smartphone Kameras, konnten nur eingeschränkt Bilder aufgezeichnet werden. Bilder der Außenfläche können nicht ausreichend gelabelt werden, so dass von diesem Teil der Rohre kein Bilddatensatz erzeugt werden konnte. Ähnlich wie die Außenfläche sind Bilder ausreichender Qualität der Innenfläche nicht zu erfassen. Die Enden sind die einzigen verbleibenden Teile des Rohrs, die analysiert werden konnten. Auf dieser Grundlage wurde ein einziger Binärdatensatz erfasst, um zwischen defekten und nicht defekten Rohrenden zu unterscheiden. Diese Bilder wurden auf eine Auflösung von 224 x 224 Pixel herunterskaliert, um sie für die Verarbeitung in den DL-Modellen vorzubereiten. Die herunterskalierten Bilder wurden entweder der Kategorie defekt (n. i. O.) oder der Kategorie nicht defekt (i. O.) zugeordnet. Danach wurden die Stichproben in einen Trainings-

, einen Validierungs- und einen Testdatensatz aufgeteilt. Wie zuvor beschrieben, wurden die Stichproben innerhalb des Trainingssets durch Augmentierung vergrößert, um den Datensatz künstlich zu vergrößern. Der Datensatz, der aus den Bildern von Rohrenden erstellt wurde, ist dennoch von begrenzter Qualität. Insbesondere ist die Anzahl der Muster im Datensatz mit insgesamt 49 Originalmustern sehr gering. Im Vergleich dazu besteht der durchschnittliche Datensatz aus den Dämmplatten aus fast 1000 Originalproben. Die i. O.-Klasse besteht aus 17 und die n. i. O.-Klasse aus 32 Originalmustern. Der Trainingsdatensatz enthält ursprünglich 31 Stichproben und wird auf 400 Stichproben augmentiert. Der Validierungs- und der Testdatensatz bestehen beide aus insgesamt 9 Stichproben.

4.6.2 Implementierung einer Deep Learning Pipeline

Die Implementierung einer DL-Pipeline diene der programmiertechnischen Umsetzung für die Automatisierungslösung, als auch der Realisierung einer Methodik, die von KMU umgesetzt werden kann. Entsprechend liegt der Fokus hier auf die verwendeten Methoden und erzielten Ergebnisse. Die Methodik, die an den 2 Anwendungsfällen erprobt wurde, umfasste die in Abbildung 13 dargestellten Schritte. Zunächst wurden die Auswahl und Implementierung geeigneter Modellierungsansätze und Algorithmen angegangen. Um die Modelle mit der besten Performance und dem geringsten Implementierungsaufwand auszuwählen wurden vortrainierte DL-Modelle durch Recherchen ausgewählt. Zusätzlich zählte dabei ein möglichst effizientes vortrainiertes Modell auszuwählen, da Speicherplatz und Rechenkapazität auf Smart Devices begrenzt sind. Bei dieser Recherche hat sich ergeben, dass insbesondere vortrainierte DL-Modelle gute Ergebnisse liefern. Dies liegt daran, dass insbesondere zur Erreichung der aus AP1 gestellten Leistungsanforderungen an die DL-Modelle (mind. 95 % Genauigkeit) ein Bilddatensatz vorliegen müsste, der einige Tausend Bilder je Anwendungsfall beinhaltet. Als weiterer Schritt galt die Generierung eines Testdesigns, in dem für alle Anwendungsfälle spezifiziert wurde, wie die vorhandenen Datensätze in Trainings-, Validierungs- und Testdatensatz aufgeteilt werden. Dies ist in Kapitel 4.6.1 beschrieben. Evaluationsmetriken und auch das Vorgehen für die weiteren Schritte der Methodik wurden hier festgelegt. Darauf folgend wurde die Vorverarbeitung der Bilddatensätze umgesetzt, wie ebenfalls in Kapitel 4.6.1 beschrieben. Im Feature Engineering, welches stark mit der Modellbildung im Zusammenhang steht, ging es darum, spezifischen Merkmale, d.h. Informationen, die den Modellen helfen werden, die Muster zu identifizieren, zu erzeugen. Spezifische Feature der Bilddaten dienten auch dazu, die Augmentierung und künstliche Erzeugung von Bilddaten voranzutreiben. Die Modellerstellung im folgenden Schritt umfasste die programmiertechnische Umsetzung der ausgewählten Modelle, um diese auf die Datensätze der Anwendungsfälle trainieren und anpassen zu können. Anschließend galt es, die Modelle zu bewerten mit den zuvor definierten Metriken, um das Benchmarking bewerten zu können und das beste Modell auszuwählen. Für den Benchmark wird die Performance von fünf DL-Modellen auf einem Optimierungsdatensatz analysiert. Die fünf Modelle bestehen aus einem Basismodell und vier DL-Modellkandidaten. Das Basismodell wird mit Standardeinstellungen trainiert, um einen Leistungsmaßstab für die Kandidatenmodelle zu erhalten. Die DL-Modellkandidaten werden in einem Transfer-Learning-Ansatz auf die beste Performance im Rahmen einer Hyperparameter-Optimierung abgestimmt. Im Schritt der Hyperparameter-Optimierung werden der beste Modellkandidat und seine entsprechenden

Hyperparameterwerte ermittelt. Anschließend wird der beste Modellkandidat auf den sechs Evaluierungsdatensätzen trainiert und bewertet. Schließlich erhalten wir ein DL-Modell, das für die Fehlererkennung im jeweiligen Anwendungsfall eingesetzt werden kann.

Mithilfe dieser Herangehensweise wurden im Benchmarking verschiedene vortrainierte DL-Modelle evaluiert. Die Ergebnisse sind im Folgenden beschrieben.

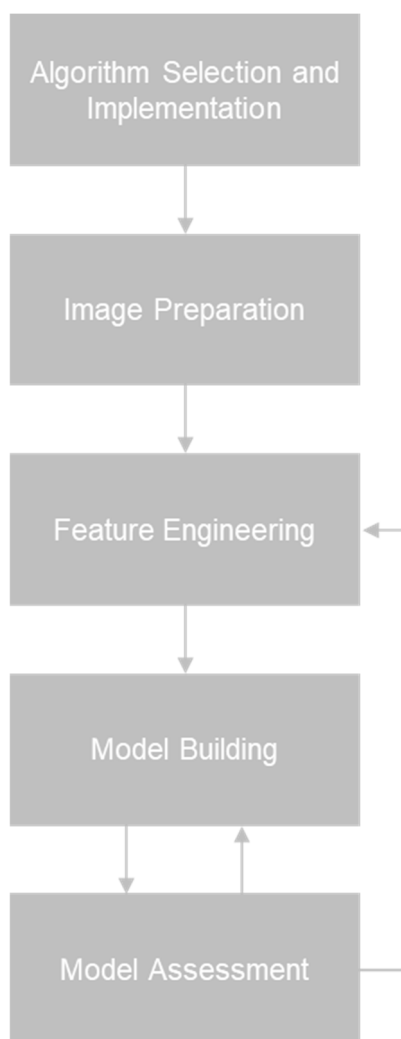


Abbildung 13: Methodik zur Umsetzung der Automatisierungslösung durch Implementierung einer Deep Learning-Pipeline

Benchmarking-Ergebnisse für Anwendungsfall 1

Für den ersten Anwendungsfall wird die Performance des Basismodells, ein MobileNetV2, das mit Standardeinstellungen auf dem Optimierungsdatensatz trainiert wurde, vorgestellt und anschließend analysiert. Zu den Kennzahlen gehören die Konfusionsmatrix und der Klassifikationsbericht über alle fünf Folds des Datensatzes. Zusätzlich werden die durchschnittlichen F1-Scores visualisiert, da sie die wichtigste Metrik für diese Aufgabe darstellen. Diese Ergebnisse werden dann als Benchmark für die anstehende Bewertung der DL-

Modellkandidaten verwendet. Nach dem Training wird die Leistung des Basismodells auf den unabhängigen Testsätzen von fünf Kreuzvalidierungsfalten bewertet. Die durchschnittlichen Ergebnisse über alle fünf Folds sind in Abbildung 14 zu sehen. Blöcke, Ausspülungen und Verunreinigungen erhalten die höchsten Werte aller Klassen entlang der Diagonale mit 86% und 87% im Recall. Die häufigste Fehlklassifizierung ist die Kennzeichnung von Vertiefungen als Blöcke. Auch Rillen und Ausbrüche werden in mehr als 20 % der Fälle als nicht fehlerhaft eingestuft. In der Teilgrafik (b) sind die jeweiligen Werte für F1-Score, Präzision und Recall für jede Klasse und als gemittelte Werte dargestellt. Außerdem gibt die letzte Spalte Support, die Anzahl der Proben für jede Klasse an. Blöcke, Risse und Verunreinigungen erhalten die höchsten Werte, während Vertiefungen mit großem Abstand die niedrigsten Werte unter allen Klassen liefern. Insgesamt liegt die durchschnittliche Genauigkeit bei 80 %, der durchschnittliche Makro-F1-Score bei 70 % und der durchschnittliche gewichtete F1-Score bei 80 %. Zusätzlich wurden die durchschnittlichen numerischen Werte für Loss und Accuracy auf dem Testset erhoben. Der durchschnittliche Loss beläuft sich auf 1,184 und die durchschnittliche Accuracy wird mit 0,7991 berechnet.



Abbildung 14: Performance des Basismodells. Links (a) die Konfusionsmatrix, rechts (b) Kennwerte.

Das Basismodell zeigt für die meisten Klassen gute Ergebnisse, obwohl beim Training nur die Standardeinstellungen verwendet wurden. Im Allgemeinen haben Klassen mit höherem Support eine bessere Accuracy, wobei Brüche eine Ausnahme bilden. Dieser Effekt ist logisch, da die Variation für die Mehrheitsklassen innerhalb des Trainingsatzes höher ist. Daher kann das neuronale Netz besser auf diese Klassen verallgemeinern. Ein kritisches Merkmal des Basismodells ist die Fehlklassifizierung von Defekten als Blöcke, da defekte Produkte vom Algorithmus nicht erkannt werden. Wenn diese Fehlklassifizierung in realen Anwendungen auftritt, werden diese fehlerhaften Produkte möglicherweise an Kunden ausgeliefert. Ein möglicher Grund für diese Fehlklassifizierung könnte sein, dass die Blockklasse die höchste Variation aller Klassen im Trainingsatz aufweist, da für diese Klasse keine Augmentierung verwendet wurde. Daher könnte der entsprechende Merkmalsraum der Blockklasse größer sein als der der Defektklassen, was wiederum die Einstufung als Block wahrscheinlicher macht. Insgesamt scheint die Anwendung des Transferlernens bzw. die Nutzung vortrainierter Modelle

ein vielversprechender Ansatz zu sein, da die Baseline ohne Hyperparameter-Tuning gute Ergebnisse erzielte. Durch Hyperparameter-Optimierung (HPO) der Kandidatenmodelle wurden noch bessere Ergebnisse erzielt.

Nachdem nun ein Basiswert für den Loss und die Accuracy festgelegt wurde, können die vier DL-Kandidatenmodelle anhand ihrer Leistung auf dem Optimierungsdatensatz bewertet werden. Die Kandidatenmodelle sind MobileNetV3Large, MobileNetV3Small, NASNetMobile und EfficientNetB0. Ihre jeweiligen Hyperparameter werden durch einen TPE-Algorithmus mit 300 Evaluierungen auf einem einzigen Fold des Evaluierungsdatensatzes optimiert. Anschließend werden die am besten geeigneten Konfigurationen von Modellen und Hyperparametern in einer Cross-Validation auf dem gesamten Datensatz getestet. Am Ende des Prozesses steht ein geeignetes Modell zur weiteren Bewertung der Umgebungsbedingungen der Lichtverhältnisse und Bildhintergrund in den Evaluierungsdatensätzen. Die Werte für Loss und Accuracy für jedes Modell bleiben relativ konstant und weisen nur geringe Schwankungen im Optimierungsprozess auf. Alle Modelle liegen mit ihrer Genauigkeit im gleichen Bereich von 75 bis 85 %. Insgesamt liefern sie bei den meisten Auswertungen höhere Accuracy Werte. Die durchschnittliche Genauigkeit der einzelnen Modelle variiert leicht, wobei EfficientNetB0 die höchsten und MobileNetV3Small die niedrigsten Werte aufweist. Im Vergleich zu vortrainierten Modellen ohne Einschränkungen hinsichtlich Rechenleistung und Festplattenspeicherplatz schneiden die Modelle etwas schlechter ab. Mit Resnet34 und Squeezenet1_0 wurde eine Genauigkeit von 92% erreicht. Die besten Ergebnisse wurden für Vgg16_bn mit einer Genauigkeit von 98 % erzielt. Alle beschriebenen DL-Modelle wurden weiter optimiert, haben aber die Qualität der Ergebnisse nicht wesentlich verbessert.

Das Modell mit der insgesamt besten Performance hinsichtlich der F1-Scores ist ein MobileNetV3Large mit einer versteckten Schicht von 442 Neuronen, das mit einer Lernrate von 0,000192 und einer Dropout-Rate von 0,064% trainiert wurde. Details können der Abbildung 15 entnommen werden. Der ursprüngliche Speicherplatz des MobileNetV3Large-Modells beträgt 21,5 MB. Durch die Konvertierung in ein TensorflowLite Modell mit der Tensorflow API wird der Speicherplatz auf 17.3 MB reduziert. Die anschließende Dynamic-Range-Quantisierung erzeugt ein Modell mit 4,4 MB Speicherplatz.



Abbildung 15: Ergebnisse der 5-Fold-Cross-Validation des besten Modells mit HPO

Die Tests vom HPO auf den sechs Evaluierungsdatensätzen zeigen unterschiedliche Ergebnisse. Jeder der Datensätze repräsentiert einen individuellen Satz von Umgebungsbedingungen innerhalb der Produktionsumgebung in denen die Bilder aufgezeichnet wurden. Die Ergebnisse umfassen die normalisierten Konfusionsmatrizen über alle 5 Folds der jeweiligen Datensätze sowie die entsprechenden f1-Werte. Nach dem Vergleich der Ergebnisse wurden die am besten geeigneten Umgebungsbedingungen aus den verschiedenen Setups ausgewählt. Das Modell von Datensatz 3 schneidet besser ab als alle anderen Modelle. Das auf dem Evaluationsdatensatz trainierte Modell rangiert mit einem entsprechenden gewichteten f1-Score von 0,84 leicht darunter. Der höchste Makro-F1-Score ist 0,771, den das Modell für Datensatz 3 erzielt. Das Modell von Datensatz 1 erhält die niedrigsten Werte sowohl für den gewichteten f1-Score als auch für den Makro-f1-Score. Das Modell von Datensatz 6 weist den zweitniedrigsten F1-Score auf. Die Mehrheit der Werte für den Makro-f1-Score liegt bei 0,7, wobei 0,628 der niedrigste und 0,771 der höchste Wert ist. Die gewichteten f1-Werte liegen zwischen 0,747 und 0,84.

Insgesamt übersteigen alle Werte für den gewichteten f1-Score den entsprechenden Makro-f1-Wert. Die Ergebnisse für die verschiedenen Datensätze entsprechen nicht den Erwartungen bei der Erstellung des Versuchsplans zur Bildaufnahme. Obwohl Datensatz 6 die saubersten Umgebungsbedingungen aufweisen sollte, rangiert das Modell bei den Scores auf dem vorletzten Platz. Nur Datensatz 1 entspricht den Erwartungen, indem das Modell die schlechteste Leistung bei gleichzeitig schlechtesten Umgebungsbedingungen aufweist. Es überrascht nicht, dass das Ergebnis für den Evaluierungsdatensatz sehr hoch ist, da das Modell auf der Grundlage der Performance in diesem speziellen Datensatz ausgewählt wurde.

Da die Bedingungen in der Einrichtung nicht mit der Qualität der Ergebnisse in den meisten Fällen korrelieren, könnte die Vorverarbeitung des Datensatzes wichtiger sein als die Umgebungsbedingungen während der Bildaufnahme. Andererseits ist die einzige Möglichkeit, die Qualität eines Datensatzes zu beurteilen, die Bildung eines Modells zur Klassifikation mit dem

Datensatz selbst. Die Ergebnisse zeigen, dass der erforderliche Datensatz mit zwei LED-Scheinwerfern und einem verrauschten Hintergrund die besten Trainingsdaten für das Modell liefert. Insgesamt ist es empfehlenswert, gute Lichtverhältnisse zu wählen, wenn die Produktqualität anhand von Bildern beurteilt werden soll.

Benchmarking-Ergebnisse für Anwendungsfall 2

Die Ergebnisse für den zweiten Anwendungsfall beschränken sich auf die Leistung des Basismodells für den Binärdatensatz, der an den Rohrenden gesammelt wurde. Wie im vorherigen Anwendungsfall wird MobileNetV2, das mit Standardeinstellungen trainiert wurde, als Basismodell verwendet. Im Gegensatz zu den Kalziumsilikatplatten werden die Rohrenden als vollständiges, herunterskaliertes Bild verarbeitet und nach den Klassen i. O. und n. i. O. unterschieden. Das Basismodell wird mit den fünf Folds des Datensatzes trainiert. Nach dem Training auf jedem Fold wird die Leistung auf dem entsprechenden Testsample bewertet. In (a) von Abbildung 16 ist die normalisierte Konfusionsmatrix für beide Klassen dargestellt. Darin erhält die nicht-defekte Klasse einen Recall von 81 %, während der Recall der defekten Klasse 65 % beträgt. Außerdem werden 35 % aller i. O.-Rohrenden als defekt klassifiziert. In (b) ist der durchschnittliche Klassifikationsbericht dargestellt. Der f1-Score der Klasse n. i. O. ist 16 % höher als der der Klasse i. O.. Außerdem wird der gewichtete f1-Score mit 73 % und der Makro-f1-Score mit 71 % berechnet. Die Gesamtzahl der Stichproben im Testdatensatz beläuft sich auf neun. Das Basismodell schneidet bei dem binären Datensatz der Rohrenden mit einer Genauigkeit von 75 % insgesamt sehr schlecht ab.

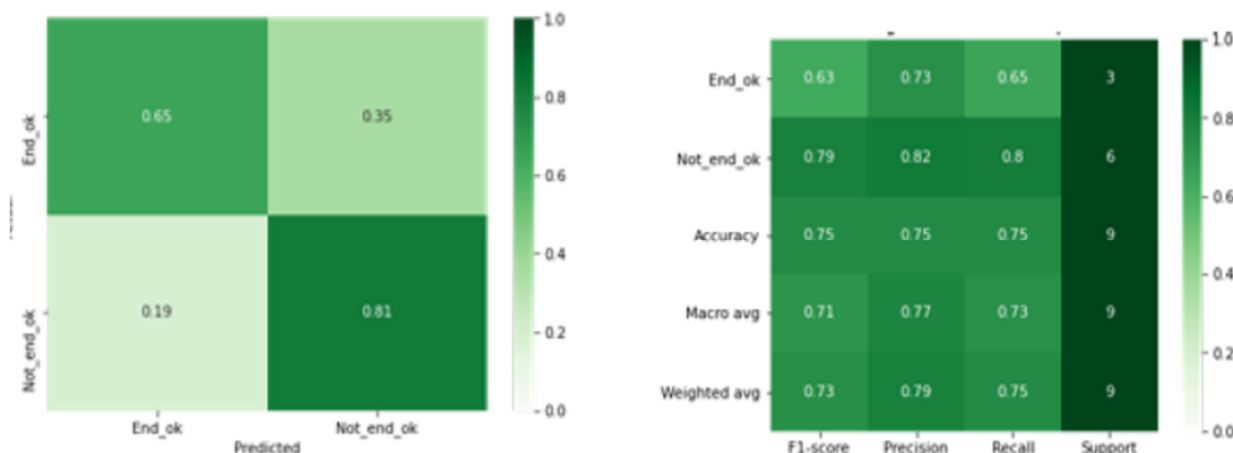


Abbildung 16: Ergebnisse des Basismodells für Anwendungsfall 2 mit (a) normalisierter Konfusionsmatrix und (b) Klassifikationsbericht

Obwohl einige Faltungen im Datensatz perfekte Ergebnisse erzielen, gibt es große Unterschiede in den Ergebnissen, um eine Aussage über die Qualität zu treffen. Die große Streuung der Ergebnisse könnte auf Unzulänglichkeiten in den Datensätzen zurückzuführen sein. Wie im Abschnitt über die Erstellung von Datensätzen beschrieben, sind einige Bilder im Datensatz nicht fokussiert. Dem neuronalen Netz könnte die Fähigkeit fehlen, aus diesen unscharfen Bildern in den Faltungsschichten aussagekräftige Merkmale zu erzeugen. Außerdem sind der gesamte

Datensatz und insbesondere der Testdatensatz klein. Daher gibt es möglicherweise nicht genügend Daten, um einen sinnvollen Lernprozess des Algorithmus zu etablieren. Es wird daher empfohlen, mehr Daten von zusätzlichen Rohren in der Produktion zu sammeln. Im Allgemeinen reichen die Fotofähigkeiten der intelligenten Geräte möglicherweise nicht aus, um angemessene Bilder der Metalloberfläche aufzunehmen. Als allgemeine Schlussfolgerung zu den Ergebnissen des Algorithmus wird empfohlen, die Daten von weiteren Rohren in der Produktion zu erfassen.

Als allgemeine Schlussfolgerung zu der vorgeschlagenen Lösung für die Fehlererkennung bei Stahlrohren lässt sich sagen, dass intelligente Geräte möglicherweise nicht in der Lage sind, Bilder mit ausreichender Qualität zu liefern, um kleine Fehler auf Metalloberflächen zu erkennen.

4.7 Arbeitspaket 5: Gesamtimplementierung

Die Gesamtimplementierung in Arbeitspaket 5 sah die Integration aller Einzelkomponenten in die KOMBI Gesamtlösung vor. Für die Entscheidungslogik wurde das Belief Rule Based Expert System (BRBES) entwickelt und in das Backend der Gesamtlösung implementiert. Das Backend wurde dabei auf der Cloud Infrastruktur des Fraunhofer IPT aufgesetzt, ist in seiner Form aber auch auf anderen Infrastrukturen übertragbar. Die prototypische Umsetzung der Werkerassistenz wurde in eine webbasierte Anwendung übertragen, welche als Frontend der Gesamtimplementierung dient. Frontend sowie Backend wurden über Schnittstellen miteinander verknüpft, sodass eine Kommunikation und Übertragung von Informationen stattfinden kann. Als Teil der Automatisierungslösung wurde ein DL Modell in das Backend integriert, um Daten, die mittels der Werkerassistenz aufgenommen werden, zu analysieren. Eine Verknüpfung zwischen DL Modell und BRBES wurde im Backend ebenfalls umgesetzt. In Abbildung 17 ist die Gesamtimplementierung aller Teilkonzepte abgebildet.

Im Fokus der Abbildung stehen die funktionalen Zusammenhänge zwischen den Teillösungen der Werkerassistenz, der Automatisierungslösung und der Entscheidungslogik.

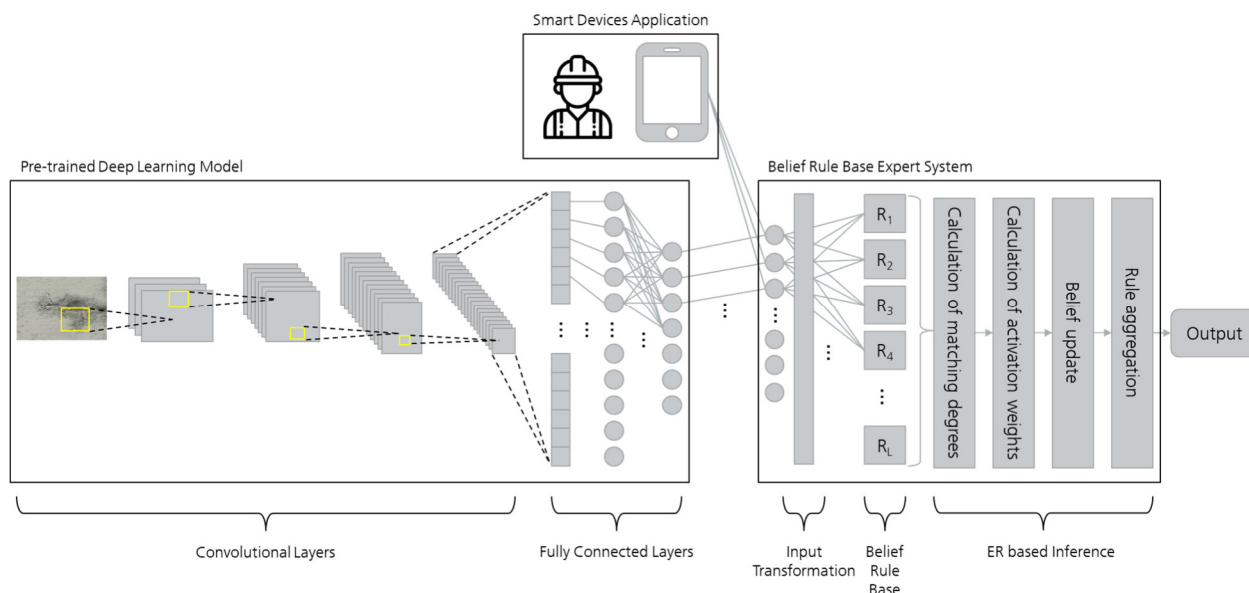


Abbildung 17: Gesamtimplementierung der KOMBI Lösung

Werkerassistenz – Smart Devices Applikation

Die im oberen Teil der Abbildung dargestellte Smart Devices Applikation dient der Informationsgewinnung durch Aufnahme und Auswertung von Bildmaterial der zu prüfenden Bauteile. Sichtprüfer nehmen mit den Smart Devices Bilddaten der zu prüfenden Produkte auf. Im paarweisen Vergleich bewerten die Sichtprüfer die Qualitätsmerkmale und Eigenschaften des Produkts. Die Bewertung dient als antezedentes Attribut zu dem BRBES. Die aufgezeichneten Bilder werden entsprechend der auf dem Produkt vorhandenen Fehler und Eigenschaften gelabelt. Die gekennzeichneten Daten werden verwendet, um DL-Modelle zu trainieren, die Fehler auf neuem Bildmaterial klassifizieren, um einen Teil des Inspektionsprozesses zu automatisieren.

Darüber hinaus dienen die Smart Devices dazu, den Sichtprüfern kontextabhängige Entscheidungsempfehlungen zu geben, die von einem BRBES unter Einbeziehung von Unsicherheiten berechnet wurden. Die Smart-Devices-Anwendung dient dabei als Dialogkomponente des BRBES und Frontend des Systems. Einzelne Geräte können ortsunabhängig genutzt werden, wenn eine Netzwerkverbindung hergestellt werden kann. Die Interaktion mit der Anwendung kann während oder direkt nach der Inspektion erfolgen, so dass der Prozess nicht gestört wird. Darüber hinaus können Webcams von der Anwendung gesteuert werden, um überall dort Aufnahmen zu machen, wo der Einsatz von Personal zu gefährlich oder unpraktisch ist.

Automatisierungslösung - Vortrainierte Deep Learning-Modelle

Die von der Smart-Device-Applikation und zusätzlichen Kameras aufgenommenen Bilder müssen verarbeitet werden, bevor sie für das Training der DL-Modelle verwendet werden können. Bei der Bildaufnahme werden die Produkte unter verschiedenen Bedingungen fotografiert, die in der Produktion auftreten (z. B. wechselnde Lichtverhältnisse). Bei der Bildverarbeitung werden die

aufgenommenen Bilder in Bereiche unterteilt, beschriftet und anschließend zu verschiedenen Datensätzen für das Training, die Validierung und den Test verarbeitet.

Um den Inspektoren die Möglichkeit zu geben, ihre visuellen Inspektionsverfahren zu verbessern und zu objektivieren, müssen bestimmte Überlegungen zu den DL-Modellen angestellt werden. Ein ausgewähltes Modell sollte in Bezug auf die Genauigkeit der erkannten Fehlerklassen vielversprechend sein. Außerdem sollte das Modell unter den Hardware-Bedingungen von Smart Devices lauffähig sein und der Aufwand für die Implementierung geringgehalten werden. Unter diesen Gesichtspunkten wird ein einstufiger Ansatz eines CNN-Klassifikators mit einer Sliding-Window-Implementierung gewählt. Als Klassifikator wird ein leichtgewichtiges, vortrainiertes CNN in Betracht gezogen, das auf den jeweiligen Defektdatensatz abgestimmt werden soll. Mögliche Kandidaten sind EfficientNetB0, MobileNetV3Large, MobileNetV3Small und NASNetMobile aufgrund ihrer Leistungsfähigkeit und Recheneffizienz.

Jedes Modell wird als vortrainierte Version ohne den ursprünglichen Klassifikationskopf verwendet, so dass nur die Convolutional Base des Modells genutzt wird. Über der Convolutional Base wird eine globale Average-Pooling-Schicht hinzugefügt, um die Anzahl der Merkmale zu reduzieren. Nach dem Pooling werden die Werte von einem neuen Klassifizierungskopf klassifiziert, der die Wahrscheinlichkeit der Zugehörigkeit zu einer bestimmten Klasse innerhalb des jeweiligen Fehlerdatensatzes vorhersagt. Beim Basismodell besteht der Klassifizierungskopf nur aus einer vollständig verbundenen Schicht von der globalen Pooling-Schicht bis zum Ausgang. Im Klassifikationskopf der Modellkandidaten ist eine zusätzliche versteckte Schicht integriert.

Die Anwendung der DL-Modelle besteht aus drei Schritten. Zunächst wird das Basismodell auf dem Optimierungsdatensatz trainiert, um Benchmarkwerte zu erhalten. Im zweiten Schritt werden die vier Kandidatenmodelle im Rahmen einer Hyperparameter-Optimierung auf einem Fold des Optimierungsdatensatzes trainiert. Die vielversprechendsten Konfigurationen von Modellen und Hyperparametern werden dann in einer Kreuzvalidierung trainiert, um einen Überblick über die Modelleleistung zu erhalten. Das beste Modell und die entsprechenden Hyperparameter werden aus den Kandidatenmodellen ausgewählt. Im dritten Schritt wird das beste Modell auf den Evaluierungsdatensätzen trainiert und bewertet. Die Ausgabe des DL-Modells besteht aus einer Klassifizierung der Bildsegmente nach den Defekten, die an dem Bauteil vorhanden sind.

Entscheidungslogik - Belief rule base expert system

Das BRBES verwendet zwei verschiedene antezedente Attribute für die Berechnung der Qualitätsstufen des Produkts und der Konsequenzen in Form von zu treffenden Entscheidungen (z. B. Ausschuss oder Nacharbeit). Zum einen der Output des DL-Modells und zum anderen eine Qualitätsbeurteilung über die Smart-Device-Anwendung. Beide werden vom BRBES getrennt verarbeitet. Das bedeutet, dass der Sichtprüfer selbst Auswertungen vornehmen und Entscheidungsempfehlungen erhalten kann. Alternativ können auch Entscheidungsempfehlungen aus den Ergebnissen der DL-Modelle empfangen werden.

Um die Wissensbasis des BRBES zu entwickeln, werden zunächst Prüfmerkmale aus Expertenwissen, Kundenanforderungen und bestehenden Prüfanweisungen und -protokollen identifiziert. Anschließend bestimmen die Experten die Eigenschaften der Merkmale anhand der ATZ-Skala. Außerdem werden die Merkmale priorisiert, was die antezedenten Attributgewichte darstellt. Schließlich werden die Regeln aufgestellt, die aus dem Antezedens-Attribut und einer Konsequenz bestehen. Die Regeln werden ebenfalls mit Gewichten versehen, um Unterschiede in der Wichtigkeit der Regeln auszudrücken. Für jedes einzelne Produkt können individuelle Regelbasen erstellt werden, so dass die Skalierbarkeit auf andere Produkte oder Kundenanforderungen gewährleistet ist.

Sobald das BRBES eingerichtet ist, werden die folgenden Schritte durchgeführt:

- Inputtransformation der antezedenten Attribute, des Wertes und der Überzeugungsgrade der Smart-Devices-Anwendung und des DL-Modells
- Berechnung des Übereinstimmungsgrads des Input mit den Regeln
- Berechnung der Aktivierungsgewichte, die die Wichtigkeit einer Regel in der Wissensbasis gegeben eines Input wiedergibt
- Generierung eines Ergebnisses durch Regelaggregation mit Evidential Reasoning (RIMER)

Jeder Input und der daraus berechnete Output werden zur Dokumentation der Prüfvorgänge gespeichert. Wodurch Mittel zur Integration in bestehende Unternehmensinformationssysteme bereitgestellt werden

Funktionsdemonstration der Gesamtlösung

Die Gesamtlösung wurde wie in Kapitel 4.8 beschrieben, im Rahmen der Validierung demonstriert. Im Folgenden werden Screenshots dieser Demonstration gezeigt und erläutert. Diese zeigen die Funktionsweise des Frontends der Werkerassistenz auf, sowie die Ergebnisse welche im Backend der Gesamtlösung bestehend aus Entscheidungslogik und Automatisierungslösung berechnet wurden.

Abbildung 18 stellt die Programmabfolge im Frontend der Werkerassistenz dar. Nach Applikationsstart gibt es die Möglichkeit sich als Admin oder als User anzumelden. Beiden Nutzertypen stehen unterschiedliche Funktionalitäten bereit.

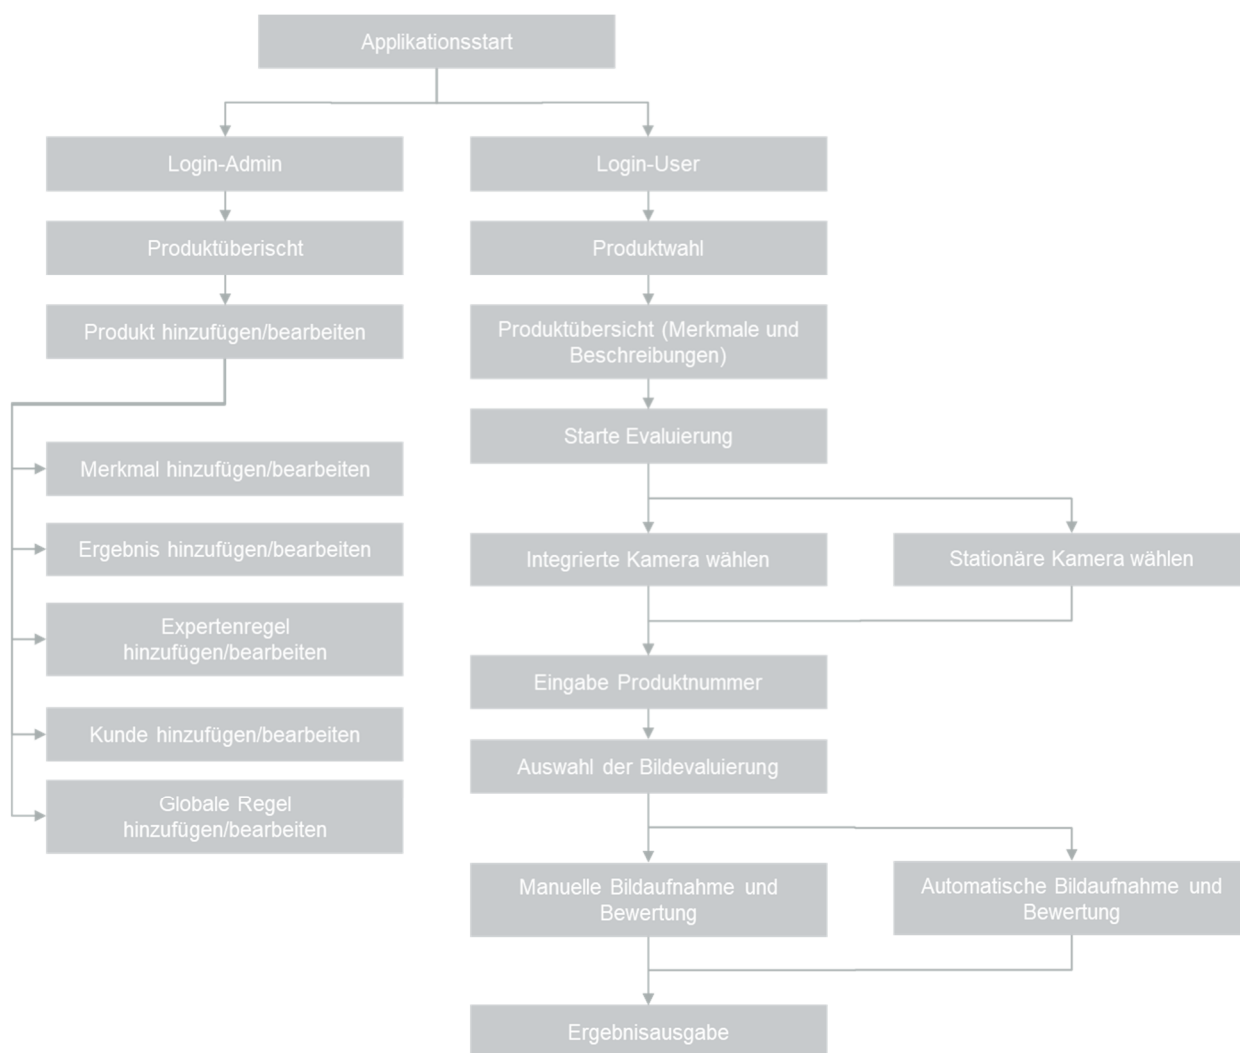


Abbildung 18: Programmabfolge im Frontend der Werkerassistenz

Der Admin wurde für Experten und Verantwortliche für das Management und Organisation der Sichtprüfung umgesetzt. Hier stehen den Nutzern eine Produktübersicht als Startseite bereit, in der alle bereits angelegten Produkte aufgelistet sind. Weitere können angelegt werden. Dazu stehen Funktionalitäten bereit, um die Wissensbasis des BRBES bzw. der Sichtprüfvorgänge nach Produkt zu erstellen und zu bearbeiten. Zu jedem Produkt können eine detaillierte Beschreibung als auch Referenzbilder hinzugefügt werden. In Abbildung 19 sind drei Screenshots des Admin-Nutzers abgebildet. Von links nach rechts sind der Login, die Produktübersicht und das Hinzufügen eines neuen Produktes zu sehen.

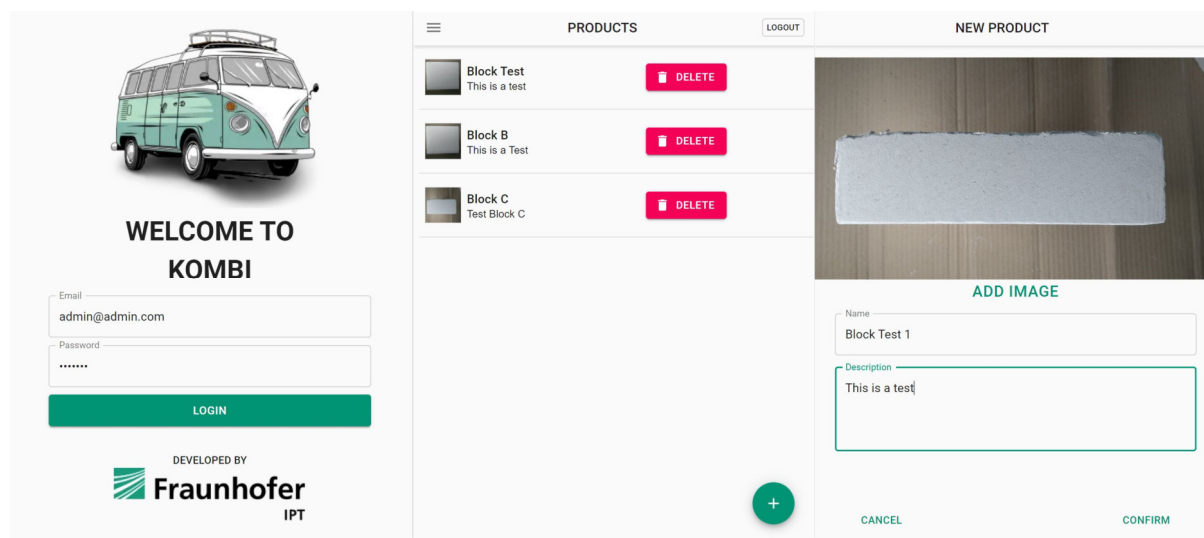


Abbildung 19: Admin-Nutzer Screenshots aus Login, Produktübersicht und dem Hinzufügen eines neuen Produktes (v. links nach rechts)

Sofern ein Produkt angelegt ist, können diesem Merkmale, Ergebnisse, Expertenregeln, Kunden und Globale Regeln hinzugefügt werden. Die Merkmale stellen die antezedenten Attribute des BRBES dar, welches durch den Sichtprüfer im User-Bereich der Werkerassistenz für eine Bewertung zur Verfügung gestellt wird, oder durch die DL-Modelle der Automatisierungslösung im Backend erkannt werden. Ergebnisse stellen dem Output des BRBES dar, welcher an dieser Stelle definiert werden kann. Es können bspw. Qualitätslevel oder Kategorien angelegt werden, nach denen Produkte in der Sichtprüfung je nach Merkmal und Ausprägung definiert werden können. Das Anlegen von Expertenregeln nutzt die zuvor gemachten Angaben zu Merkmalen und Ergebnissen. In intuitiv gestalteter, visueller Darstellung werden die Regeln konstruiert, mithilfe vordefinierter Strukturen. Um aus den Ergebnissen der Inferenz zwischen antezedenten Attributen über die Werkerassistenz und dem BRBES im Backend eine übergeordnete Arbeitsanweisung bzw. -empfehlung anzuzeigen, können globale Regeln angelegt werden. Dazu werden zunächst Kunden hinzugefügt. Darauffolgend können globale Regeln erstellt werden, die aus den Expertenregeln und einer Verknüpfung des Kundenstammes entstehen. Hier können Nutzer dem Sichtprüfer eine Empfehlung erstellen, was mit dem vorliegenden Produkt je nach Bewertung zu tun ist. Im Freitextfeld kann z.B. das Aussortieren angeordnet werden, wenn eine Verknüpfung zwischen einem bestimmten Ergebnis der Expertenregeln und optional einem Kunden angelegt wird. Der Nutzer hat also die Möglichkeit, direkte und umsetzbare Anweisungen auf Basis der Ergebnisse des BRBES zu erhalten. In allen Seiten der Admin-Nutzer sind Parametrierungen für das BRBES möglich. Es können Gewichte für Regeln und Attribute festgelegt werden aber auch z.B. Belief Thresholds (Schwellwerte) für den Glaubensgrad des Sichtprüfers. In Abbildung 20 ist die Eingabemaske für Merkmale (Hier Quality Characteristic) eines Produktes, die Konstruktion von Regeln und die Eingabemaske für globale Regeln abgebildet.

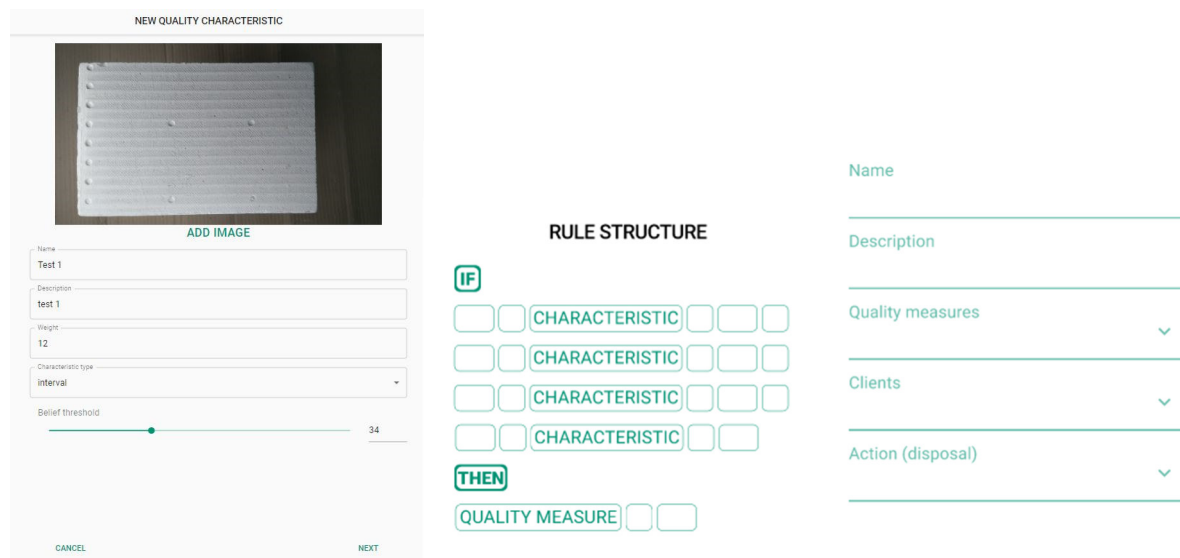


Abbildung 20: Admin-Nutzer Screenshots für das Hinzufügen von Merkmalen, der intuitiven Regelstruktur zur Bildung von Expertenregeln für die Wissensbasis der BRBES, und dem Hinzufügen einer globalen Regel (v. links nach rechts)

Der User wurde für Nutzer der Sichtprüfung entwickelt, die den Bewertungsprozess von Produkten vornehmen und letztendlich vor Entscheidungen stehen, ob sie bspw. ein Produkt aussortieren oder weitere Aktionen notwendig sind. Nach Login der Nutzer können aus der Liste von Produkten, die der Admin angelegt hat, das zu beurteilende Produkt ausgewählt werden. Hier können Produktmerkmale und Beschreibungen angesehen werden, um eine Übersicht auf die wichtigsten Aspekte des Produktes und der durchzuführenden Sichtprüfung zu erhalten. Per Klick auf den Start der Evaluation steht der User vor der Möglichkeit, die integrierte Kamera des Smart Devices oder eine Festinstallierte Kamera zu nutzen, welche über das Backend angesteuert wird. Ist eine Kamera ausgewählt kann die individuelle Produkt ID oder Seriennummer des Produktes eingegeben werden. Dies dient der Dokumentation der Sichtprüfvorgänge und Bewertungen im Backend. Anschließend kann der Nutzer die Evaluierungsart auswählen. Hier steht die manuelle Evaluierung durch den Sichtprüfer auf dem Smart Device oder die automatische Evaluierung durch die im Backend deploytem DL-Modelle zur Auswahl. Wird die manuelle Evaluierung gewählt, wird der Nutzer durch die Bewertung der im Admin definierten Merkmale und deren Ausprägungen geführt. Sofern die automatische Evaluierung gewählt wird, wird das Ergebnis auf der folgenden Seite direkt dargestellt. Hier sind die Ergebnisse des BRBES abgebildet, als auch die zum Ergebnis passende globale Regel, die eine direkte Arbeitsanweisung an den Sichtprüfer enthalten kann. Abschließend kann der Nutzer in der User Ansicht das nächste Produkt beurteilen und gelangt an den Anfang des Vorgangs. Abbildung 21 zeigt die Eingabemaske der Produkt ID mit dem vom Nutzer aufgenommenen Bild des Produktes im Hintergrund. Rechts in der Abbildung ist das Ergebnis einer Evaluation zu sehen mit den im Admin definierten Qualitätsleveln D_1 bis D_3, sowie dem Ergebnis der auf Basis des Ergebnisses zugeordneten globalen Regel.

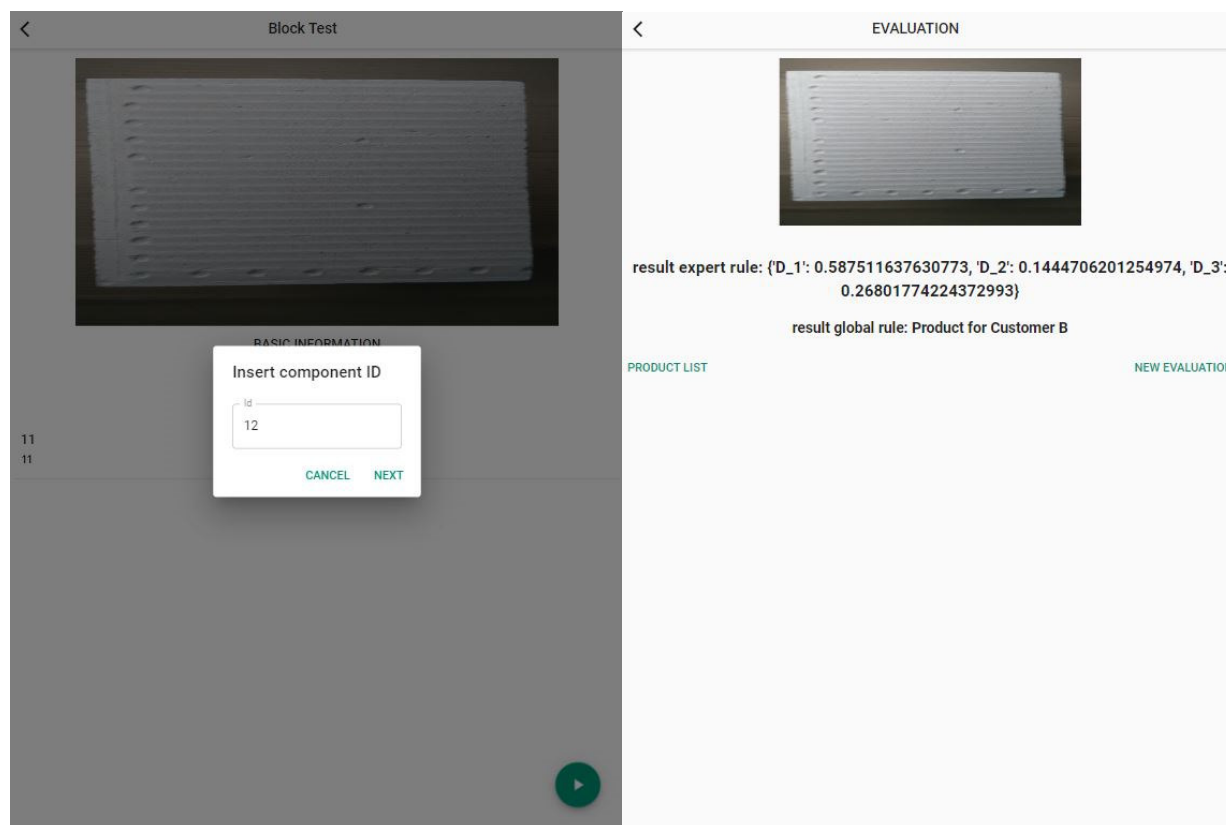


Abbildung 21: User-Nutzer Screenshots für das Zuordnen einer Produkt-ID und der Darstellung eines Evaluationsergebnisses (v. links nach rechts)

4.8 Arbeitspaket 6: Validierung sowie Evaluation

Die Validierung sowie Evaluation der Projektergebnisse wurde während der Projektlaufzeit in sogenannte Unit Tests und die Testung der Gesamtlösung aufgetrennt. Dabei dienten die vom PA bereitgestellten Anwendungsfälle als auch konstruierte Szenarien, die durch künstliche Daten angereichert wurden, als Testszenarien für die Validierung. Unit Tests beziehen sich auf die Validierung und Evaluation der Einzelkomponenten der Gesamtlösung, bestehend aus Werkerassistenz, Automatisierungslösung und Entscheidungslogik. Die Gesamtlösung wurde in einem konstruierten Szenario am IPT durch Mitarbeiter validiert, die die Bedingungen in der Sichtprüfung simuliert haben. Eine Validierung und Evaluation durch PA geschah anhand eines von den PA Mitgliedern bereitgestellten Anwendungsfalls, welcher vollständig in der Gesamtlösung zur Verfügung stand.

Validierung durch Unit Tests

Für die Entscheidungslogik wurde das Belief Rule Base Expert System (BRBES) entwickelt und in das Backend der Gesamtlösung implementiert. Das Backend wurde dabei auf der Cloud Infrastruktur des Fraunhofer IPT aufgesetzt, ist in seiner Form aber auch auf anderen Infrastrukturen übertragbar. Aus den von den PA Mitgliedern bereitgestellten Use Cases und

Daten wurde ein konstruiertes Beispiel entwickelt, anhand dessen das BRBES evaluiert wurde. Dazu wurden 20 Regeln in der Regelbasis des BRBES von Experten erstellt und abgelegt. Mithilfe von konstruierten Samples wurde der Inferenzmechanismus getestet und die Ergebnisse mit der Einschätzung eines Experten evaluiert. Die Erprobung der Lösung wurde durch Datenerfassung und Nutzung der Funktionalitäten der Applikation im simulierten Betriebsalltag durchgeführt. Die Ergebnisse des BRBES und des Experten stimmten überein. Auf Basis dieser Validierungstests wurden Anpassungen und Optimierungen an der Applikation vorgenommen. Zusätzlich wurde durch regelmäßiges Spiegeln der IST-Situation mit den definierten Anforderungen sichergestellt, dass diese erfüllt wurden.

Die Automatisierungslösung bzw. die darin entwickelten DL-Modelle wurden anhand der vom PA bereitgestellten Datensätze validiert und evaluiert. Aus der Recherche zu den DL-Algorithmen und vortrainierten DL-Modellen wurden die best-geeignetsten DL-Modelle ausgewählt und in einem Benchmark miteinander verglichen. Dazu wurden Bilder der bereitgestellten Proben genutzt. Für den Probensatz wurden vortrainierte DL-Modelle implementiert, die in der Lage sind, die Qualitätsbeurteilung in der Sichtprüfung durchzuführen. Eine Genauigkeit von 95% wurde dabei erreicht, wie in den Anforderungen aus AP 1 hervorging. Folgende Ergebnisse sind aus dem Benchmark in der Validierung hervorgegangen:

- Resnet34 92,50 % Genauigkeit
- Densenet121 91,25 % Genauigkeit
- Alexnet 91,88 % Genauigkeit
- Squeezenet1_0 93,13 % Genauigkeit
- Vgg16_bn 98,13 % Genauigkeit

Validierung der Gesamtlösung

Dazu wurde die Gesamtlösung final in einem ausgewählten Anwendungsszenario implementiert. Die Erprobung der Lösung wurde durch laufende Datenerfassung und Nutzung der Funktionalitäten der Applikation im simulierten Betriebsalltag durchgeführt. Auf Basis dessen wurden Anpassungen und Optimierungen an der Applikation vorgenommen. Zusätzlich wurde durch regelmäßiges Spiegeln der IST-Situation mit den definierten Anforderungen sichergestellt, dass diese erfüllt wurden. Die Dokumentation und der Transfer der Ergebnisse wurden abgeschlossen. Die Gesamtlösung wurde durch die Partner validiert und evaluiert und somit abgeschlossen. Die Validierung der Funktionsweise erfolgte durch eine Live-Demosession, die eine ausführliche Demonstration des Funktionsumfangs der Gesamtlösung und seiner unterschiedlichen Module umfasste. In der Live-Demosession wurde gezeigt, wie die Nutzer Admin und User die Gesamtlösung im Arbeitsalltag einsetzen. Es wurde dargestellt, wie Produkte, Kunden und Inspektionen aufgebaut sind, und wie diese durch den Admin neu angelegt bzw. gepflegt werden können. Die Funktionalitäten des Users werden anhand des konkreten Anwendungsszenarios dargestellt, um ein Produkt automatisiert oder manuell zu bewerten und eine Entscheidungsunterstützung zu generieren. Nach der Live-Demosession wurden die

Anforderungen aus Arbeitspaket 1 (Soll) mit den erreichten Ergebnissen (Ist) abgeglichen. Eine Diskussion der Erprobung und Funktionalität wurde geführt. Als Ergebnis des Soll-/Ist-Abgleichs steht die Erfüllung der Anforderungen aus dem Antrag.

4.9 Arbeitspaket 7: Dokumentation und Verbreitung sowie Transfer und laufende Nutzung

Die Projektergebnisse wurden als Leitfaden im »KOMBI-Softwaretool« zusammengestellt und somit nutzbar gemacht für interessierte Unternehmen. In Form einer webbasierten Anwendung kann mittels einer Eingabemaske, die Randbedingungen, die ein potentieller Anwender (z.B. Qualitätskriterium, Bauteilgröße, Stückzahl, etc.) in seiner Produktion im Bezug zur Sichtprüfung hat, Empfehlungen zur Umsetzung erhalten. Die Randbedingungen wurden in vier Kategorien aufgeteilt: Daten, Sichtprüfung, Implementierung und Anwendung. In der Kategorie Daten wird nach der Verfügbarkeit von Bildmaterial von Produkten, die geprüft werden sollen, gefragt, sowie der Verteilung des Datensatzes bezogen auf Defekt- und Gut-Teile. Diese Informationen dienen der Einschätzung, ob die Automatisierungslösung direkt von Beginn umsetzbar ist, indem mit vorhandenem Bildmaterial vortrainierte DL-Modelle auf den spezifischen Anendungsfall trainiert werden können. Fragen zur Kategorie Sichtprüfung zielen auf Grundlagen für den Einsatz des BRBES und zusätzlicher Hardware durch Kameras ab. Für die Wissensbasis ist es von Vorteil, wenn Kundenanforderungen, Prüfanweisungen oder Normen die den Ablauf der Prüfvorgänge oder Rahmenbedingungen sowie Regeln vorgeben. Damit die Gesamtlösung auch im Unternehmen Anwendung findet ist eine Implementierung notwendig, die nur auf einer existierenden Infrastruktur aufbauen kann. Diese Information wird daher ebenfalls abgefragt. Zuletzt wird der interessierte, potentielle Nutzer bezogen auf die Anwendung befragt. Hier werden Anforderungen bezogen auf die Auflösung des Gesamtsystems zur Beurteilung einer generellen Machbarkeit erfragt. In Abbildung 22 sind Ausschnitte der Anwendung abgebildet.

✓
Is your use case fit for Kombi?

1. Data

1.1. Is image data of products available?

Required

1.2. Does the amount of data differ between the defect classes apparent on the products?

No

Yes

2.2. Are documents like customer requirements, inspection rules, or norms available, that describe the visual inspection rules?

Required

2.3. Is the place where the inspection will take place accessible for employees?

Required

2. Visual Inspection

2.1. Are visual inspection experts available for providing rules of the visual inspection?

Required

3. Implementation

3.1. Is access to the company's infrastructure and information systems available?

Required

Abbildung 22: Ausschnitte aus dem Leitfaden »KOMBI-Softwaretool«

Die Projektergebnisse wurden sowohl durch wissenschaftliche Veröffentlichungen, Konferenzen und Postersessions als auch durch industrielle Veröffentlichungen und Vorträge verbreitet. Durch die Fraunhofer Open Access Strategie 2020 wurde der freie Zugang zu den Veröffentlichungen sichergestellt. Außerdem wurde über eine projekteigene Webseite und sozialen Medien auf das Projekt aufmerksam gemacht. Einen Überblick über die Gesamt geleisteten Arbeiten für den Ergebnistransfer sind in Kapitel 6 gelistet.

5. Wirtschaftliche Bedeutung der Forschungsergebnisse für KMU

Neben den dargestellten wissenschaftlich-technischen und wirtschaftlichen Problemstellungen zeigt eine aktuelle Studie den Aufholbedarf Deutschlands hinsichtlich der Digitalisierung und der Anwendung von ML. Nur 15 % der produzierenden Unternehmen in Deutschland haben bereits mehr als einen Anwendungsfall im Bereich ML implementiert [35]. Durch das Forschungsvorhaben »KOMBI« wurden KMU, die manuelle Sichtprüfungen einsetzen, befähigt, die Qualitätsbeurteilung objektiviert durchzuführen. Das zentrale Innovationspotential liegt in der Kombination der Werkerassistenz und der sich darauf aufbauenden Automatisierungslösung. Daraus ergeben sich Einsparpotentiale und Effizienzsteigerungen, die explizit für KMU die Wettbewerbsfähigkeit in den folgenden Bereichen steigern:

Qualität:

- Eine Objektivierung subjektiver Qualitätskriterien erhöht die Qualität der Sichtprüfung und reduziert damit den Ausschuss sowie teure Nacharbeit. Dadurch ergeben sich monetäre Einsparungen [79].
- Durch den Einsatz von Smart Devices in der Produktion lassen sich Fehlerraten manueller Prozesse um mehr als 20 % verringern [80]. Weitere Studien verifizieren dieses Potential, die neben Qualitätsverbesserungen insbesondere Zeiteinsparungen hervorheben [55, 81–83].
- Untersuchungen zeigen das Potential der automatisierten Bilderkennung zur Qualitätsbeurteilung von Bauteilen mittels ML-Modellen. Studien geben an, dass Prozesszeiten um bis zu 33 % reduziert werden, während die Erkennungsrate von Qualitätskriterien auf über 97 % ansteigt [84]. Weiterhin geht durch den Einsatz von ML der Programmieraufwand bei der Bilderkennung um bis zu 80 % zurück [84].

Investition:

- Die Investition in die Werkerassistenz bleibt durch den Einsatz von Smart Devices gering. Smart Devices wie beispielsweise Tablets oder Smartphones sind „commercial-off-the-shelf“-Produkte, deren Beschaffung sowohl einfach als auch kostengünstig ist.
- Die Automatisierungslösung stellt für Anwenderunternehmen eine geringe Investition dar. Für den Einsatz ist lediglich eine Kamera zur Generierung von Bildern nötig. Die Implementierung der ML-Modelle zur Klassifizierung der Bilder erfolgt über eine Open-Source Software, wie z.B. Python, und ist, abgesehen von Personalkosten, kostenlos.

Mitarbeiter

- Sowohl die Werkerassistenz als auch die Automatisierungslösung ermöglichen einen effizienteren Einsatz von Mitarbeitern. Kennzahlen, wie das Mitarbeiter-Maschine-Verhältnis können dadurch deutlich verringert werden. Die KOMBI-Gesamtlösung gibt den Anwendern die Flexibilität, Mitarbeiter an anderen Orten einzusetzen [85].
- KMU benötigen in Zukunft eine verringerte Anzahl hochqualifizierter Mitarbeiter für optische Sichtprüfungen. Neue Mitarbeiter im Unternehmen können trotz fehlenden Know-Hows oder fehlender Qualifikation das vorhandene Expertenwissen über die bereitgestellte Entscheidungslogik anwenden. Mitarbeiter können bei einer automatisierten Bilderkennung anderweitig eingesetzt werden.

Modularität

- Die Gesamtlösung bestehend aus zwei modularen Teillösungen stellen in sich funktionierende und geschlossene Systeme dar. Jedem Anwenderunternehmen obliegt die Entscheidung, welche Lösung eingesetzt wird und wie diese ausgestaltet

wird. Dabei sind die Teillösungen für die Unternehmen flexibel und abgestimmt auf deren verfügbare Ressourcen einsetzbar.

Neben den Anwendern sind profitierende Parteien sowohl die Befähiger-Unternehmen der Werkerassistenz als auch der Automatisierungslösung. Für die Befähiger-KMU ist ein hoher Nutzen zu erwarten, da 99 % der Unternehmen im Informations- und Kommunikationsbereich KMU sind [86]. Befähiger-KMU können basierend auf den Erkenntnissen aus dem Forschungsvorhaben »KOMBI« marktreife Softwaresysteme entwickeln.

Die Stärkung dieses Sektors ist für den Standort Deutschland wichtig, da diese Unternehmen eine hohe Innovationskraft im Bereich Software/IT besitzen und insbesondere im Hinblick auf die Hightech-Strategie und das ausgerufene Wissenschaftsjahr „Künstliche Intelligenz“ der Bundesregierung große Zukunftsrelevanz besitzen [87, 88].

Abschließend lässt sich festhalten, dass sich das »KOMBI-Konzept« bedarfsgerecht je nach wirtschaftlicher Situation und Marktanforderungen erweitern lässt. Generell werden mit diesem Forschungsvorhaben die Einstiegshürden in die Digitalisierung für KMU gesenkt.

6. Ergebnistransfer

Nach Projektende werden die bestehenden Prototypen der ausgewählten Anwendungsszenarien bestehend aus der Gesamtlösung und den Teillösungen für die erfolgreiche Nutzung durch das Fraunhofer IPT weiterentwickelt. Dazu werden weiterhin Daten aufgenommen, um innerhalb der ersten sechs Monate nach Projektende sowohl die Werkerassistenz als auch die DL-Algorithmen weiter zu optimieren.

Bei Abschluss des Projekts wird das »KOMBI-Softwaretool« auf der Projektwebseite zur Verfügung gestellt. Damit soll die Anwendung auch nach Projektende weiter erprobt und den Unternehmen der Transfer auf weitere Produktionsprozesse ermöglicht werden. Durch die heterogene Zusammensetzung des PA wird sichergestellt, dass der »KOMBI-Softwaretool« für unterschiedliche Anwendungsszenarien nutzbar ist. Darüber hinaus sorgen Branchenverbände für eine weitere Veröffentlichung der Ergebnisse außerhalb des PA. Dadurch wird das »KOMBI-Softwaretool« auch anderen Unternehmen zugänglich gemacht, die nicht direkt am Projekt beteiligt waren. Innerhalb der ersten zwölf Monate nach Projektende ist geplant fünf weitere Anwendungsszenarien in bilateralen Projekten auszuwählen und das »KOMBI-Konzept« umzusetzen.

Die Investition in eine Gesamtlösung und die Teillösungen bleibt gering. Anhand des »KOMBI-Softwaretools« können Unternehmen geeignete Hardware (z.B. Kamerahardware, Smart Device) sowohl für die Werkerassistenz als auch für die Automatisierungslösung auswählen, die im Vergleich zu herkömmlichen Industrielösungen sehr günstig ist. Dadurch, dass beide Teilkonzepte aufeinander aufbauen, können Kosten der jeweiligen Teilkonzepte besser abgeschätzt werden. Unternehmen können unabhängig die Entscheidung treffen, welche Lösung für das Anwendungsszenario am geeignetsten ist. Dieser Ansatz erhöht die Wettbewerbsfähigkeit und die Flexibilität der KMU.

Neben der Flexibilität ist der unmittelbare Nutzen für Anwender-KMU der effizientere Einsatz von Mitarbeitern, die Sichtprüfungen in einer höheren Qualität durchführen. Der mittelbare Nutzen für Anwender-KMU besteht in der Steigerung der Mitarbeiterakzeptanz bei der Digitalisierung der Produktion.

Die Befähiger-KMU erschließen neue Anwendungsfelder für Ihre entwickelten Lösungen und können so ihren potenziellen Kundenkreis erweitern. Auch ist die Entwicklung neuer Geschäftsmodelle möglich (Services, z.B. die Nutzung der Daten aus den Unternehmen zur allgemeinen Weiterentwicklung der »KOMBI-Lösung« durch die Befähiger-KMU). Dies führt zu einer nachhaltig gesteigerten Wettbewerbsfähigkeit der KMU auf dem wichtigen Informations- und Kommunikationstechnik-Markt [89], in dem auch der Markt für Services ein hohes Wachstum verzeichnet [90].

6.1 Plan zum Ergebnistransfer in die Wirtschaft

Um das »KOMBI-Konzept« einer breiten Öffentlichkeit zur Verfügung zu stellen, werden spezifische Transfermaßnahmen sowohl während als auch nach der Projektlaufzeit durchgeführt.

Das Ziel ist, Unternehmen branchenunabhängig zu befähigen, dass »KOMBI-Softwaretool« auf weitere Anwendungsszenarien zu übertragen.

6.1.1 Geplante spezifische Transfermaßnahmen während der Projektlaufzeit

Maßnahme	Ziel	Ort/Rahmen	Datum/Zeitraum
Arbeitssitzungen des PA	Formulierung von Inhalten, Zielsetzungen und Vorgehensweise, Diskussion der Ergebnisse. Sicherstellung der Praxisrelevanz der Projektergebnisse	Treffen bei der Forschungseinrichtung oder gastgebenden Unternehmen.	13.05.2020, 25.11.2020, 18.06.2021, 09.12.2021, 30.03.2022
Wissenschaftliche Veröffentlichungen auf Konferenzen und Tagungen	Diskussion der Ergebnisse in der Wissenschaft mit dem Fokus der Entscheidungslogik, Werkerassistenz und Automatisierungslösung	Jahrestagung der FQS; IMEKO, CIRP CMS	CIRP Design 28.03.2022
Industrielle Veröffentlichungen	Bekanntmachung der Zwischenergebnisse über der Entscheidungslogik, Werkerassistenz und Automatisierungslösung	IT&Production, QZ, MQ, QM Aktuell, VDI-Z, wt-online, zwf, etc.	QZ 01.06.2021
Vorträge und Verbände	Diskussion der Ergebnisse in Wirtschaft und Wissenschaft.	IHK, VDI, Unternehmensverbände, Messevorträge, ICNAP, etc.	DGQ 18.03.2021, EPIC 11.03.2022
Social-Media-Kanäle	Aktuelle Berichterstattung zu konkreten Ergebnissen und weiterem Vorgehen.	Facebook, Xing, LinkedIn, Twitter	Monatlich über die Projektlaufzeit

Projekteigene Homepage	Beiträge und Berichterstattung zu Ergebnissen	https://www.ipt.fraunhofer.de/de/projekte/kombi.html	Monatlich über die Projektlaufzeit
------------------------	---	---	------------------------------------

6.1.2 Geplante spezifische Transfermaßnahme nach Abschluss des Vorhabens

Maßnahme	Ziel	Ort/Rahmen	Datum/Zeitraum
Abschlussbericht	Wissenschaftliche Zusammenstellung und Erläuterung der Forschungsergebnisse	Online-Bereitstellung sowie Verbreitung des Berichts	Einmalig nach Ende des Projekts
Wissenschaftliche Veröffentlichungen	Wissenschaftliche Verbreitung des »KOMBI-Konzepts« in die Wissenschaft auf Konferenzen und Tagungen	Jahrestagung der FQS; IMEKO, CIRP CMS, »KOMBI-Homepage«	Fortlaufend nach Projektende (einmal jährlich)
Industrielle Veröffentlichungen	Verbreitung der Gesamtlösung, den Teillösungen und des »KOMBI-Konzepts« in die Wirtschaft	IT&Production, QZ, MQ, QM Aktuell, VDI-Z, wt-online, zwf, etc.; »KOMBI-Homepage«	Fortlaufend nach Projektende (zweimal jährlich)
Übernahme der Ergebnisse in die Lehre an der RWTH Aachen	Vermitteln von inhaltlichen und methodischen Kenntnissen im Bereich der Mitarbeiterbefähigung sowie der Anwendung von ML-Algorithmen	Lehrveranstaltungen der RWTH Aachen	Fortlaufend nach Projektende, Einarbeitung der Ergebnisse unmittelbar nach Projektende
Übernahme der Ergebnisse in Seminarprogramm des Fraunhofer IPT	Vermitteln von inhaltlichen und methodischen Kenntnissen im Bereich der Mitarbeiterbefähigung sowie der Anwendung von ML-Algorithmen	Bilaterale Seminare und Workshops mit Industrieunternehmen	Fortlaufend nach Projektende, Einarbeitung der Ergebnisse unmittelbar nach Projektende
Dissertation (1-2)	Wissenschaftliche Ausarbeitung des »KOMBI-Konzepts«	1-2 basierend auf den Projektinhalten	Start während der Projektlaufzeit

6.1.3 Einschätzung zur Realisierbarkeit des vorgeschlagenen und aktualisierten Transferkonzepts

Das Transferkonzept bestehend aus den zwei Maßnahmenpaketen während der Projektlaufzeit und nach Abschluss des Vorhabens, bildet die Grundlage, um die Ergebnisse und Erkenntnisse aus dem Vorhaben in die Industrie zu transferieren. Während der Projektlaufzeit zeigten sich insbesondere Veröffentlichungen und Vorträge in industrierelevanten Medien, sowie Social Media Beiträge auf der Website des Fraunhofer IPT als vielversprechend, um das Interesse von Unternehmen zu wecken. Über diese Kanäle konnten Kontakte geknüpft und weitere interessierte Unternehmen mit in den PA aufgenommen werden.

Zur Fortführung des Transfers in die Industrie sieht das Konzept nach Abschluss des Vorhabens gleichwertige Veröffentlichungen vor. Durch die Verbreitung der Gesamtlösung, den Teillösungen und des »KOMBI-Konzepts« in die Wirtschaft, wird eine Weiterentwicklung bzw. Umsetzung der Lösung möglich gemacht. Der Erfolg des Transferkonzeptes wird durch diese kontinuierliche Weiterführung durch Veröffentlichungen sichergestellt.

7. Beteiligte Forschungsstellen

IPT

Fraunhofer-Institut für Produktionstechnologie IPT

Steinbachstraße 17, 52074 Aachen

Forschungsstellenleiter: Prof. Dr.-Ing. Christian Brecher

Projektleiter: Hendrik Mende M.Sc.

Telefon: +49 241 8904 -386

hendrik.mende@ipt.fraunhofer.de

www.ipt.fraunhofer.de

I Abkürzungsverzeichnis

AP Arbeitspaket

API Application Programming Interface

ATZ Skala Skala mit erster Vorstellung in der automobiltechnischen Zeitschrift ATZ

BD Belief degree

BRB Belief-Rule-Base oder Wissensbasis

BRBES Belief Rule Base Expert System

DL Deep Learning

ES Expertensystem

FQS Forschungsgemeinschaft Qualität e.V.

HPO Hyperparameter-Optimierung

HSV Hue, saturation, value

i. O. in Ordnung

IPT Fraunhofer-Institut für Produktionstechnologie

KMU Kleine und mittlere Unternehmen

ML Machine Learning

n. i. O. nicht in Ordnung

PA Projektbegleitender Ausschuss

QS Qualitätssicherung

II Abbildungsverzeichnis

<i>Abbildung 1: Gesamtkonzept des Forschungsvorhabens »KOMBI«; links: Werkerassistenz beispielhaft für die Bewertung von Schweißnähten; rechts: Automatisierung der Qualitätssicherung durch Machine Learning</i>	6
<i>Abbildung 2: Gliederung des Forschungsvorhabens »KOMBI«</i>	13
<i>Abbildung 3: Arbeitsdiagramm für die Projektdurchführung</i>	17
<i>Abbildung 4: Grobkonzept der KOMBI Gesamtlösung</i>	23
<i>Abbildung 5: Systemarchitektur des BRBES</i>	28
<i>Abbildung 6: Entwicklungsprozess der Wissenskomponente</i>	29
<i>Abbildung 7: Sub-Rules Anwendungsfall Ventilkolben</i>	33
<i>Abbildung 8: Entwicklungsprozess der Inferenzkomponente</i>	34
<i>Abbildung 9: Systemarchitektur der Werkerassistenz</i>	40
<i>Abbildung 10: Schematische Darstellung der Versuchsaufbauten mit unterschiedlichen Lichtquellen und Bildhintergründen</i>	42
<i>Abbildung 11: Auswirkungen der Beleuchtungsbedingungen auf die Bilder der Kalziumsilikatplatten von links nach rechts: (a) Deckenstrahler (b) 1 LED-Strahler (c) 2 LED-Strahler</i>	44
<i>Abbildung 12: Reflexionen auf der Metalloberfläche während der Bildaufnahme</i>	46
<i>Abbildung 13: Methodik zur Umsetzung der Automatisierungslösung durch Implementierung einer Deep Learning-Pipeline</i>	48
<i>Abbildung 14: Performance des Basismodells. Links (a) die Konfusionsmatrix, rechts (b) Kennwerte</i>	49
<i>Abbildung 15: Ergebnisse der 5-Fold-Cross-Validation des besten Modells mit HPO</i>	51
<i>Abbildung 16: Ergebnisse des Basismodells für Anwendungsfall 2 mit (a) normalisierter Konfusionsmatrix und (b) Klassifikationsbericht</i>	52
<i>Abbildung 17: Gesamtimplementierung der KOMBI Lösung</i>	54
<i>Abbildung 18: Programmabfolge im Frontend der Werkerassistenz</i>	57
<i>Abbildung 19: Admin-Nutzer Screenshots aus Login, Produktüberischt und dem Hinzufügen eines neuen Produktes (v. links nach rechts)</i>	58
<i>Abbildung 20: Admin-Nutzer Screenshots für das Hinzufügen von Merkmalen, der intuitiven Regelstruktur zur Bildung von Expertenregeln für die Wissensbasis der BRBES, und dem Hinzufügen einer globalen Regel (v. links nach rechts)</i>	59
<i>Abbildung 21: User-Nutzer Screenshots für das Zuordnen einer Produkt-ID und der Darstellung eines Evaluationsergebnisses (v. links nach rechts)</i>	60
<i>Abbildung 22: Ausschnitte aus dem Leitfaden »KOMBI-Softwaretool«</i>	63

III Tabellenverzeichnis

<i>Tabelle 1: Konkurrenzanalyse hinsichtlich alternativer Lösungen zu KOMBI</i>	<i>11</i>
<i>Tabelle 2: Beispielhaftes Protokoll eines Anwendungsfalls in der Sichtprüfung</i>	<i>20</i>
<i>Tabelle 3: Übersicht des Wissenserwerbs der Anwendungsfälle</i>	<i>30</i>
<i>Tabelle 4: ATZ-Skala Ventilkolben</i>	<i>31</i>
<i>Tabelle 5: Darstellung Beispielhafter Glaubensgradverteilungen.....</i>	<i>39</i>
<i>Tabelle 6: Übersicht der Eigenschaften der Klassen des Datensatzes von Anwendungsfall 1..</i>	<i>45</i>

IV Literaturverzeichnis

- [1] W. Goschy und T. Rohrbach, „Deutscher Industrie 4.0 Index 2017“.
- [2] F. T. Piller, *Mass Customization*. Wiesbaden: Springer Fachmedien, 2007. [Online]. Verfügbar unter: <https://www.springer.com/de/book/9783835003552>
- [3] A. Weiler, *Der Kunde ist König – Individualisierte Produktion mit Losgröße 1*. [Online]. Verfügbar unter: <https://www.inform-software.de/blog/post/der-kunde-ist-koenig-individualisierte-produktion-mit-losgroesse-1> (Zugriff am: 12. September 2018).
- [4] M. Berger, *Test- und Prüfverfahren in der Elektronikfertigung: Vom Arbeitsprinzip bis Design-for-Test-Regeln*. Berlin: VDE-Verl., 2012.
- [5] ZfP Lehrstuhl für Zerstörungsfreie Prüfung, *Grundlagen der Sichtprüfung*. [Online]. Verfügbar unter: http://zfp.cbm.bgu.tum.de/mediawiki/index.php/Grundlagen_der_Sichtpr%C3%BCfung (Zugriff am: 12. September 2018).
- [6] U. Elpelt, „Sichtprüfung in der Produktion von Luftfahrzeug-Triebwerken“. München, 20. März 2013.
- [7] Sabine Goldbach und Theodor Meier, „Reduzierung des Human - Faktors bei der visuellen Prüfung an Luftfahrtstrukturen – ein Qualitätssicherungskonzept“. Fürth, 14. Mai 2007. [Online]. Verfügbar unter: <https://www.ndt.net/article/dgzfp07/Inhalt/v20.pdf>
- [8] M. Bossler, A. Kubis und A. Moczall, „Neueinstellungen im Jahr 2016: Große Betriebe haben im Wettbewerb um Fachkräfte oft die Nase vorn“, Institut für Arbeitsmarkt- und Berufsforschung, Nürnberg, IAB-Kurzbericht 18/2017, Aug. 2017.
- [9] S. Hardege und S. Hartig, „Fachkräftesicherung gewinnt weiter an Bedeutung: DIHK-Arbeitsmarktreport 2017“, Berlin.
- [10] H. Loferer, „Automatische Inspektion statt manueller Sichtkontrolle“, *J Oberfl Techn*, Jg. 56, Nr. 3, S. 66–67, 2016, doi: 10.1007/s35144-016-0035-5.
- [11] Thomas Knecht und Hans Wagner, *(Manuelle Optische Inspektion von kleinen Losgrößen: Hilfsmittel zur Qualitätssteigerung*. [Online]. Verfügbar unter: <https://epp.industrie.de/allgemein/hilfsmittel-zur-qualitaetssteigerung/> (Zugriff am: 12. September 2018).
- [12] Titus T. Suck, „Wie teuer ist es, kein AOI-System einzusetzen?“, *Produtronic*, Nr. 11, S. 8–10, 2002. [Online]. Verfügbar unter: <https://www.all-electronics.de/wp-content/uploads/migrated/article-pdf/91413/2020c460b87.pdf>

- [13] Sebastian Schröder und Carsten Köhler, „Mobiles Prüfsystem für die mechanisierte Handprüfung von Rohren und Stangen, auch in geführter Tauchtechnik“. Erfurt, 10. Mai 2010. [Online]. Verfügbar unter: <https://www.ndt.net/article/dgzfp2010/Inhalt/p49.pdf>
- [14] Dirk Berndt, *Montagefehler schnell erkannt*. Magdeburg, 2012. [Online]. Verfügbar unter: <https://www.fraunhofer.de/de/presse/presseinformationen/2012/april/montagefehler-schnell-erkannt.html>
- [15] F. Lindner, K. Kostyszyn, D. Grunert, K. Lossie und R. Schmitt, „Smart Devices. Vermittler zwischen Mensch, Maschine und Software“, *Fabriksoftware*, Nr. 23, S. 21–24, 2018, Art. no. 2.
- [16] F. Lindner, K. Kostyszyn, D. Grunert und R. Schmitt, „Smart Devices on the Shopfloor“, *ZWF Zeitschrift für wirtschaftlichen Fabrikbetrieb*, Jg. 112, Nr. 10, S. 662–665, 2017.
- [17] J. Krauß, E. Permin, R. H. Schmitt, M. Große Böckmann und M. Plutz, „Smartglasses im Einsatz auf dem Shopfloor : Erfahrungen, Potentiale und Limitationen“, *wt Werkstattstechnik online*, Nr. 106, 2016.
- [18] J. W. H. Wiech, „Zum Stand der Sichtprüfung im Rahmen der Herstellung und der wiederkehrenden Prüfung von Komponenten“.
- [19] J. Beyerer, F. P. León, C. Frese und J. Meyer, *Automatische Sichtprüfung: Grundlagen, Methoden und Praxis der Bildgewinnung und Bildauswertung*. Springer Berlin Heidelberg, 2016. [Online]. Verfügbar unter: <https://books.google.de/books?id=YTssDQAAQBAJ>
- [20] R. Schmitt und A. Neumann, „Qualitätswahrnehmung von Drehschaltern“, *ATZ*, Jg. 2015, Nr. 117, S. 68–75.
- [21] QZ Online, *Inline-Prüfgerät Surf Max: Bewertete Oberfläche*. [Online]. Verfügbar unter: <https://www.qz-online.de/produkte/uebersicht/beitrag/inline-pruefgeraet-surfmax-bewertete-oberflaeche-356090.html> (Zugriff am: 29. April 2019).
- [22] J. Beyerer, *Automatische Sichtprüfung und Bildverarbeitung*. [Online]. Verfügbar unter: https://ies.anthropomatik.kit.edu/lehre_asb.php (Zugriff am: 29. April 2019).
- [23] J. Krüger *et al.*, „Innovative control of assembly systems and lines“, *CIRP Annals*, Jg. 66, Nr. 2, S. 707–730, 2017, doi: 10.1016/j.cirp.2017.05.010.
- [24] Oculavis GmbH, *Oculavis Share Plattform I*. [Online]. Verfügbar unter: <https://www.share-plattform.de/> (Zugriff am: 13. September 2018).
- [25] Oculavis GmbH, *Oculavis Share Plattform II*. [Online]. Verfügbar unter: <https://www.youtube.com/watch?v=MQYxqfJfwuM&feature=youtu.be> (Zugriff am: 13. September 2018).
- [26] ESSERT GmbH, *Essert Augmented Automation I*. [Online]. Verfügbar unter: <https://www.youtube.com/watch?v=FGLndpaqsXU> (Zugriff am: 13. September 2018).

- [27] ESSERT GmbH, *Essert Augmented Automation II*. [Online]. Verfügbar unter: <https://www.essert.com/essert-augmented-automation> (Zugriff am: 13. September 2018).
- [28] Ubimax GmbH, *Ubimax xAssist*. [Online]. Verfügbar unter: <https://www.ubimax.com/de/loesungen/xassist.html> (Zugriff am: 13. September 2018).
- [29] thyssenkrupp AG, *thyssenkrupp – bringing new vision to elevator maintenance with Microsoft HoloLens*. [Online]. Verfügbar unter: <https://www.youtube.com/watch?v=8OWWhGiyR4Ns> (Zugriff am: 13.09.2018).
- [30] Sebastian Hoffmann, *Smart Glasses revolutionieren Kommissionierung*. [Online]. Verfügbar unter: <https://www.mm-logistik.vogel.de/index.cfm?pid=8432&pk=631186&print=true&printtype=article>.
- [31] Ubimax GmbH, *Ubimax xPick*. [Online]. Verfügbar unter: <https://www.ubimax.com/de/loesungen/xpick.html> (Zugriff am: 13. September 2018).
- [32] Ubimax GmbH, *Ubimax xMake*. [Online]. Verfügbar unter: <https://www.ubimax.com/de/loesungen/xmake.html> (Zugriff am: 13. September 2018).
- [33] iTiZZiMO AG, *Case Study: Bühler AG*. [Online]. Verfügbar unter: <https://www.itizzimo.com/case-study-buehler/> (Zugriff am: 13. September 2018).
- [34] José Pinto, *Daimler-Werk auf neuen Pfaden: Mercedes-Benz-Beschäftigte lernen mit smarten Brillen*. [Online]. Verfügbar unter: <https://www.hna.de/kassel/mercedes-benz-beschaefigte-lernen-mit-smarten-brillen-7379965.html> (Zugriff am: 13. September 2018).
- [35] Daniel Küpper *et al.*, *AI in the Factory of the Future: The Ghost in the Machine*.
- [36] I. Goodfellow, Y. Bengio und A. Courville, *Deep Learning*. MIT Press, 2016. [Online]. Verfügbar unter: <https://books.google.de/books?id=omivDQAAQBAJ>
- [37] Krauß, Jonathan and Frye, Maik and Beck, Gustavo Teodoro Döhler and Schmitt, Robert H., „Selection and Application of Machine Learning- Algorithms in Production Quality“ in *Machine Learning for Cyber Physical Systems*, 2019, S. 46–57.
- [38] A. Krizhevsky, I. Sutskever und G. Hinton, „Imagenet classification with deep convolutional neural networks“ in *NIPS*, S. 1097–1105.
- [39] K. He, X. Zhang, S. Ren und J. Sun, „Deep Residual Learning for Image Recognition“, 10. Dez. 2015. [Online]. Verfügbar unter: <http://arxiv.org/pdf/1512.03385v1>.
- [40] C. Szegedy *et al.*, „Going Deeper with Convolutions“, 17. Sep. 2014. [Online]. Verfügbar unter: <http://arxiv.org/pdf/1409.4842v1>.
- [41] Berkley AI Research, *Caffe: a fast open framework for deep learning*. [Online]. Verfügbar unter: <https://caffe.berkeleyvision.org/>.

- [42] Google Brain Team, *TensorFlow - An end-to-end open source machine learning platform*. [Online]. Verfügbar unter: <https://www.tensorflow.org/>.
- [43] A. Caggiano, J. Zhang, V. Alfieri, F. Caiazzo, R. Gao und R. Teti, „Machine learning-based image processing for on-line defect recognition in additive manufacturing“, *CIRP Annals*, 2019, doi: 10.1016/j.cirp.2019.03.021.
- [44] Volkswagen AG, *Audi optimizes quality inspections in the press shop with artificial intelligence*.
- [45] K. Kim, J. Kim, S. Kang, J. Kim und J. Lee, „Object recognition for cell manufacturing system“ in *2012 9th International Conference on Ubiquitous Robots and Ambient Intelligence (URAI)*, Daejeon, Korea (South), 26.11.2012 - 28.11.2012, S. 512–514, doi: 10.1109/URAI.2012.6463056.
- [46] O. Ronneberger, P. Fischer und T. Brox, „U-Net: Convolutional Networks for Biomedical Image Segmentation“ in *Lecture Notes in Computer Science, Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015*, N. Navab, J. Hornegger, W. M. Wells und A. F. Frangi, Hg., Cham: Springer International Publishing, 2015, S. 234–241, doi: 10.1007/978-3-319-24574-4_28.
- [47] Condat AG, *PLUTO*. [Online]. Verfügbar unter: <http://www.plutoprojekt.de/index.php/de/>.
- [48] I. A. G. TU Darmstadt, *Molem*. [Online]. Verfügbar unter: <https://www.qualifizierungdigital.de/de/molem-1087.php>.
- [49] Universität Leipzig, IAIS, AviComp Controls GmbH, Heidelberger Druckmaschinen AG, Ontos GmbH, USU Software AG, *Sake - Semantische Analyse Komplexer Ereignisse*. [Online]. Verfügbar unter: <https://www.sake-projekt.de/start/>.
- [50] Fraunhofer IAO, *Appsist*. [Online]. Verfügbar unter: <https://edtec.dfki.de/projekt/appsist/>.
- [51] USU Software AG (Konsortialführer), FLS GmbH, Heidelberger Druckmaschinen Aktiengesellschaft, Karlsruher Institut für Technologie (KIT), TRUMPF Werkzeugmaschinen GmbH + Co. KG, *Step*. [Online]. Verfügbar unter: <https://www.projekt-step.de/de/>.
- [52] M. Brendler, *Datenflut in der Medizin: Da hilft nur noch Kollege Computer*. [Online]. Verfügbar unter: <https://www.faz.net/aktuell/wissen/medizin-ernaehrung/bildgebende-diagnostik-ersetzt-die-kuenstliche-intelligenz-bald-den-arzt-15531347.html> (Zugriff am: 29. April 2019).
- [53] A. Lebert, *Effektive Inspektion für Kleinserien ab Losgröße 1*. [Online]. Verfügbar unter: <https://www.all-electronics.de/effektive-inspektion-fuer-kleinserien-ab-losgroesse-1/> (Zugriff am: 29. April 2019).

- [54] F. Lindner, E. Permin, R. Schmitt und F. Gesthuysen, „Flexibilisierung von Maschinenbedienern mit mobilen Endgeräten - Smartes Informationssystem als Erweiterung der klassischen Maschinensteuerung“, *ProductivITy*, Vol.22 No.4, S. 47–49, 2017.
- [55] R. Schmitt, E. Permin, J. Kerkhoff, M. Plutz und M. G. Böckmann, „Enhancing Resiliency in Production Facilities Through Cyber Physical Systems“ in *Springer Series in Wireless Technology, Industrial Internet of Things*, S. Jeschke, C. Brecher, H. Song und D. B. Rawat, Hg., Cham: Springer International Publishing, 2017, S. 287–313, doi: 10.1007/978-3-319-42559-7_11.
- [56] F. Lindner, E. Permin, R. Schmitt und F. Gesthuysen, „Echtzeit-Maschinendaten auf mobile Endgeräte bringen: Smart visualisiert“, *Elektronik*, Nr. 66, S. 38–41, 2018. [Online]. Verfügbar unter: <http://publica.fraunhofer.de/documents/N-484412.html>
- [57] K. Lossie und R. Schmitt, „Smart Glasses for State Supervision in Self-optimizing Production Systems“ in *Advances in Production Research: Proceedings of the 8th Congress of the German Academic Association for Production Technology (WGP), Aachen, November 19-20, 2018*, R. Schmitt und G. Schuh, Hg., Cham: Springer International Publishing, 2019, S. 166–177, doi: 10.1007/978-3-030-03451-1_17.
- [58] E. Permin *et al.*, „Smart Devices in Production System Maintenance“ in *Predictive Maintenance in Dynamic Systems: Advanced Methods, Decision Support Tools and Real-World Applications*, E. Lughofer und M. Sayed-Mouchaweh, Hg., Cham: Springer International Publishing, 2019, S. 25–51, doi: 10.1007/978-3-030-05645-2_2.
- [59] J. Krauß, M. Frye, G. T. D. Beck und R. H. Schmitt, „Selection and Application of Machine Learning- Algorithms in Production Quality“ in *Technologien für die intelligente Automation : technologies for intelligent automation*, Band 9, *MACHINE LEARNING FOR CYBER PHYSICAL SYSTEMS: Selected papers from the*, J. Beyerer, Hg., [S.I.], Berlin, Germany: MORGAN KAUFMANN; Springer Vieweg, 2019, S. 46–57, doi: 10.1007/978-3-662-58485-9_6.
- [60] R. Schmitt, L. Niendorf, K. Kostyszyn und M. Große Böckmann, „Herausforderung Informationsqualität - Daten effizient generieren, richtig interpretieren und adressatengerecht bereitstellen“ in *Informationsqualität, Datensicherheit & Wissensschutz - die Risikoprävention im Mittelpunkt der ISO-Revision: 19. Business Forum Qualität, 17. und 18. September 2015, Aachen*, R. Schmitt, Hg., 1 Aufl., Aachen: Apprimus Verlag, 2015.
- [61] C. Brecher, F. Klocke, R. Schmitt und G. Schuh, *AWK Aachener Werkzeugmaschinen-Kolloquium 2017 Internet of Production für agile Unternehmen*, 1. Aufl. Aachen: Apprimus Verlag, 2017.
- [62] Fraunhofer IPT, *Forschungsprojekt "charMant"*. [Online]. Verfügbar unter: <https://www.charmant-projekt.de/de/projekt.html> (Zugriff am: 7. Mai 2019).

- [63] N. A. D. Connell und P. L. Powell, „A Comparison of Potential Applications of Expert Systems and Decision Support Systems“, *The Journal of the Operational Research Society*, Jg. 41, Nr. 5, S. 431, 1990, doi: 10.2307/2583375.
- [64] F. Nelson Ford, „Decision support systems and expert systems: A comparison“, *Information & Management*, Jg. 8, Nr. 1, S. 21–26, 1985, doi: 10.1016/0378-7206(85)90066-7.
- [65] R. Pfeifer und H.-J. Lüthi, „Decision Support Systems And Expert Systems: A Complementary Relationship?“ in *Expert Systems and Artificial Intelligence in Decision Support Systems: Proceedings of the Second Mini Euroconference, Lunteren, The Netherlands, 17–20 November 1985*, H. G. Sol, C. A. T. Takkenberg und De Vries Robbé, Pieter F, Hg., Dordrecht: Springer Netherlands, 1987, S. 41–51, doi: 10.1007/978-94-009-3805-2_4.
- [66] H. G. Sol, C. A. T. Takkenberg und De Vries Robbé, Pieter F, Hg., *Expert Systems and Artificial Intelligence in Decision Support Systems: Proceedings of the Second Mini Euroconference, Lunteren, The Netherlands, 17–20 November 1985*. Dordrecht: Springer Netherlands, 1987.
- [67] Z.-J. Zhou, G.-Y. Hu, C.-H. Hu, C.-L. Wen und L.-L. Chang, „A Survey of Belief Rule-Base Expert System“, *IEEE Trans. Syst. Man Cybern, Syst.*, S. 1–15, 2019, doi: 10.1109/TSMC.2019.2944893.
- [68] G. Gottlob, T. Frühwirth und W. Horn, *Expertensysteme*. Vienna: Springer, 1990.
- [69] Jian-Bo Yang, Jun Liu, Jin Wang, How-Sing Sii und Hong-Wei Wang, „Belief rule-base inference methodology using the evidential reasoning Approach-RIMER“, *IEEE Transactions on Systems, Man, and Cybernetics - Part A: Systems and Humans*, Jg. 36, Nr. 2, S. 266–285, 2006, doi: 10.1109/TSMCA.2005.851270.
- [70] S. Sachan, J.-B. Yang, D.-L. Xu, D. E. Benavides und Y. Li, „An explainable AI decision-support-system to automate loan underwriting“, *Expert Systems with Applications*, Jg. 144, S. 113100, 2020, doi: 10.1016/j.eswa.2019.113100.
- [71] L. Chang, Y. Zhou, J. Jiang, M. Li und X. Zhang, „Structure learning for belief rule base expert system: A comparative study“, *Knowledge-Based Systems*, Jg. 39, S. 159–172, 2013, doi: 10.1016/j.knosys.2012.10.016.
- [72] M. S. Hossain, S. Rahaman, R. Mustafa und K. Andersson, „A belief rule-based expert system to assess suspicion of acute coronary syndrome (ACS) under uncertainty“, *Soft Comput*, Jg. 22, Nr. 22, S. 7571–7586, 2018, doi: 10.1007/s00500-017-2732-2.
- [73] Swati Chan, Jian-Bo Yang, Dong-Ling Xu, David Eraso Benavides, Yang Li, „Expert Systems with Applications: An explainable AI decision-support-system to automate loan underwriting“, Jg. 2019, S. 1–24. [Online]. Verfügbar unter: <https://www.journals.elsevier.com/expert-systems-with-applications>

- [74] Lian-Bo Yang, Jun Liu, Jin Wang, Member, IEEE, How-Sing Sii, and Hong-Wei Wang, „Belief Rule-Base Inference Methodology Using the Evidential Reasoning Approach—RIMER“, *IEEE TRANSACTIONS ON SYSTEMS, MAN, AND CYBERNETICS—PART A: SYSTEMS AND HUMANS*, VOL. 36, NO. 2, MARCH 2006, Jg. 2006, Nr. 36, S. 266–285, 2006.
- [75] J.-M. Birkhold, „Komfortobjektivierung und funktionale Bewertung als Methoden zur Unterstützung der Entwicklung des Wiederstartsystems in parallelen Hybridantrieben = Objectification of comfort and functional evaluation as methods to support the development of restarting systems in parallel hybrid drivetrains“, 2013.
- [76] Hossain, Mohammad Shahadat, Saifur, Rahaman, Rashed, Mustafa ·, *A belief rule-based expert system to assess suspicion of acute coronary syndrome (ACS) under uncertainty*. [Online]. Verfügbar unter: <https://doi.org/10.1007/s00500-017-2732-2>.
- [77] Zhi-Jie Zhou Guan-Yu Hu, Chang-Hua Hu Cheng-Lin Wen and Lei-Lei Chang, „A Survey of Belief Rule-Base Expert System“, *EEE Transactions on Systems, Man, and Cybernetics: Systems*, S. 1–12.
- [78] Jun Liu, Jian-Bo Yang†, Jin Wang‡, How-Sing Sii¶ und Ying-Ming Wang, „Fuzzy Rule-Based Evidential Reasoning Approach for Safety Analysis“, *International Journal of General Systems*, Jg. 33, 2-3, S. 183–204, 2004, doi: 10.1080/03081070310001633536.
- [79] V. K. Omachonu, S. Suthummanon und N. G. Einspruch, „The relationship between quality and quality cost for a manufacturing company“, *Int J Qual & Reliability Mgmt*, Jg. 21, Nr. 3, S. 277–290, 2004, doi: 10.1108/02656710410522720.
- [80] M. Plutz, R. Schmitt und A. Gomer, *Einfluss der Nutzung von Smart Glasses auf die Durchlaufzeit und Fehlerrate in manuellen Montageprozessen*, 2015. [Online]. Verfügbar unter: <http://publica.fraunhofer.de/documents/N-358489.html>
- [81] S. Kasselmann und S. Willeke, *4.0 Ready: Technologie-Kompendium - Interaktive Assistenzsysteme*. [Online]. Verfügbar unter: https://www.iph-hannover.de/_media/files/downloads/Projekt_40-Ready_Technologie-Kompendium.pdf.
- [82] B. Görtz, *Assistenzsysteme in der Produktion - Praxisleitfaden*. [Online]. Verfügbar unter: <https://www.ihk-rheinland-wirtschaft40.de/blog/2018/06/07/assistenzsysteme-in-der-produktion-praxisleitfaden/>.
- [83] D. E. Qeshmy, J. Makdisi, da Silva, Elias Hans Dener Ribeiro und J. Angelis, „Managing Human Errors: Augmented Reality systems as a tool in the quality journey“ in Bd. 28, *Procedia Manufacturing*, D. E. Qeshmy, J. Makdisi, da Silva, Elias Hans Dener Ribeiro und J. Angelis, Hg., 2019, S. 24–30. [Online]. Verfügbar unter: <https://www.sciencedirect.com/science/article/pii/S2351978918313477>
- [84] Fujitsu Journal, *AI-Enabled Image Recognition System to Revolutionize the Manufacturing Line: In-house Practice/Oyama Factory*. [Online]. Verfügbar unter: <http://journal.jp.fujitsu.com/en/2017/04/19/01/>.

[85] A. Richter, P. Heinrich, A. Stocker und W. Unzeitig, „Der Mensch im Mittelpunkt der Fabrik von morgen“, *HMD*, Jg. 52, Nr. 5, S. 690–712, 2015, doi: 10.1365/s40702-015-0173-x.

[86] Statistisches Bundesamt, *Unternehmen, Tätige Personen, Umsatz, Investitionen, Bruttowertschöpfung: Deutschland, Jahre, Unternehmensgröße, Wirtschaftsbereiche*. [Online]. Verfügbar unter: <https://www-genesis.destatis.de/genesis/online/link/tabelleErgebnis/48121-0002>.

[87] Bundesregierung, Hg., *Strategie Künstliche Intelligenz der Bundesregierung: AI Made in Germany*. [Online]. Verfügbar unter: <https://www.bmwi.de/Redaktion/DE/Publikationen/Technologie/strategie-kuenstliche-intelligenz-der-bundesregierung.html>

[88] BMBF, *Wissenschaftsjahr 2019 Künstliche Intelligenz*. [Online]. Verfügbar unter: <https://www.wissenschaftsjahr.de/2019/>.

[89] Bundesministerium für Bildung und Forschung (BMBF) Referat Grundsatzfragen der Innovationspolitik, *Die neue Hightech-Strategie Innovationen für Deutschland*. [Online]. Verfügbar unter: https://www.bmbf.de/upload_filestore/pub_hts/HTS_Broschüre_Web.pdf.

[90] A.-W. Scheer, *CeBIT 2014: Keynote zu Industrie 4.0*. [Online]. Verfügbar unter: <https://i40.de/cebit-2014-keynote-zu-industrie-4-0-von-prof-august-wilhelm-scheer/> (Zugriff am: 12. September 2018).

Autoren

Hendrik Mende, Faruk Ibrahim, Alexander Peters