

BIG DATA IM BEREICH DER TECHNISCHEN SAUBERKEIT

Frank Herrmann^a, Jan Michael Kirschner^b, Dr. Thomas Kleinert^c and Harald Fritzsche^c

^a Ostbayerische Technische Hochschule Regensburg, Innovationszentrum für Produktionslogistik und Fabrikplanung, Galgenbergstraße 32, 93053 Regensburg

^b Ostbayerische Technische Hochschule Regensburg, Galgenbergstraße 32, 93053 Regensburg

^c Continental Automotive GmbH, Siemensstr. 12, 93055 Regensburg

KEYWORDS

Technische Sauberkeit, künstliche Intelligenz, Computer Vision, Partikeluläre Verunreinigung, Literaturforschung, Continental, cleanliness, KI, particle

ABSTRACT

Dieses Projekt befasst sich mit Fragestellungen zur Anwendung von künstlicher Intelligenz im Bereich der Technischen Sauberkeit. Durch Literaturforschungen, die einen Ablauf nach Fettke 2006 haben, werden KI-Anwendungen gesucht, die bereits im Zusammenhang mit der Technischen Sauberkeit verwendet werden. Die Forschungen konnten zwölf Literaturquellen ermitteln. Durch diese Literaturanalyse wurde festgestellt, dass 91 Prozent CV (Computer Vision) zur Partikelerkennung verwenden. Aus diesem Grund wurde anschließend ein CV Modell zur Partikelerkennung implementiert. Durch die Konfusionsmatrix konnte eine Treffergenauigkeit von 82 Prozent festgestellt werden. Daraus folgt, dass eine Partikelklassifikation möglich ist. Abschließend wurde eine weitere Literaturforschung zu Text Mining Applikationen durchgeführt, da der Bereich der Qualitätsanalyse im Monitoring laut Aufgabenstellung eingezogen werden sollte. In dieser konnte kein positives Ergebnis erzielt werden, da speziell nach fertigen Anwendungen gesucht wurde, die Analysetexte im Bereich der technischen Sauberkeit kategorisieren können.

1. EINLEITUNG

In den letzten 15 Jahren ist die Weiterentwicklung der Bauteile in der Automobilindustrie stark vorangeschritten. Infolgedessen sind dadurch neue Probleme in den Vordergrund getreten, wie z. B. technische Verunreinigungen, die durch Partikelablagerungen entstehen. Diese Ablagerungen, die die Funktion der Komponenten beeinträchtigen, werden in der Automobilindustrie als partikuläre Verunreinigung bezeichnet und unter dem Oberbegriff technische Sauberkeit behandelt (Holzapfel & Kreck Guido, 2013, S. 4). Bereits bei minimalen Verunreinigungen, wie auf den Abbildungen 1 und 2, von wenigen 100 Mikrometern kann es zu einem Ausfall oder erhöhtem Verschleiß des Gerätes kommen (Läpple R, 2009, 26ff). In der Automobilbranche werden vor allem partikuläre, filmische Verschmutzungen, sowie Fasern in den Mittelpunkt gestellt, da sich diese gegenüber von biologischen Verschmutzungen schädlich auf die Produkte auswirken können (Verband der

Automobilindustrie e. V [VDA], 2015, S. 14). Die technische Sauberkeit wird regulär überwacht und mit herkömmlichen Methoden ausgewertet. Vom Einsatz künstlicher Intelligenz bzw. Industrie 4.0 verspricht man sich eine deutliche Verbesserung der Analyseabläufe.

Projekte unter dem Titel Industrie 4.0 gewinnen in der Industrie immer mehr an Bedeutung. Vorreiter dieser Technologie sind die Branchen Automobilbau und Medizintechnik. Laut einer neuen Studie des Digitalverbundes Bitkom werden etwa 73 Prozent der befragten Unternehmen auf Digitale Plattformen umsteigen und sich somit ganze Geschäftsabläufe verändern (Thomas Siebel, 2020, S. 1). Zusätzlich sind unter dem Begriff vierte industrielle Revolution weitere wichtige technologische Ansätze vorhanden. Angefangen, wie soeben beschrieben, mit Digitalisierungsmöglichkeiten, Produktionsrobotern, Echtzeit-Kommunikation, Big Data Anwendungen, sowie vielen weiteren.

Daraus folgt, dass die digitale Fabrik immer mehr an Wichtigkeit gewinnt und auch neue Möglichkeiten bietet. Aus diesem Grund werden enorme Investitionen getätigt, die die Forschung solcher neuen Systeme fördern soll. Allerdings entstehen durch die neu gewonnenen Möglichkeiten auch neue, davor noch teilweise unbekannte Herausforderungen, die zu bewältigen sind.



Abbildung 1: metallischer Partikel



Abbildung 2: nicht metallischer Partikel

2. KÜNSTLICHE INTELLIGENZ

Der grundlegende Gedanke bei diesem Begriff ist, ob es möglich ist, dass eine Maschine ein ähnlich intelligentes Verhalten hat, wie ein Mensch selbst (Wolfgang Ertel, 2016, S. 1). Einer der ersten Entwickler war John McCarthy, der definierte 1955 die KI in etwa so:

„[...] die Wissenschaft und Technik der Schaffung intelligenter Maschinen, insbesondere intelligenter Computerprogramme“ (Felix Weber, 2020, S. 37)

Dennoch ist es schwierig, eine einheitliche Definition zu diesem Begriff zu finden, da die KI enorme

Möglichkeiten aufweist und unterschiedliche Meinungen dadurch zulässt (Wolfgang Ertel, 2016, S. 1). Im Automobilbereich gibt es bereits einige Systeme, die mit der KI zusammenarbeiten. Beispielsweise werden bereits Sprachassistenten entwickelt, die intelligentes Arbeiten ermöglicht (Prof. Dr. Peter Buxmann, Dr. Holger Schmidt, 2019, 173f).

Unter dem Begriff KI fällt auch der Begriff „maschinelles Lernen“. Maschinelles Lernen soll dem System ermöglichen, dass es sich selbst weiterbilden kann und sogar mit davor unbekanntem Daten arbeiten kann (Wolfgang Ertel, 2016, S. 195). Um dieses Ziel erreichen zu können, ist es möglich, die Algorithmen in drei Kategorien einzuteilen (Felix Weber, 2020, S. 39) (J. Frochte, 2018, S. 20) (F. Chollet, 2018, S. 129):

- Überwachtes Lernen
- Bestärktes Lernen
- Unüberwachtes Lernen

Ein weiterer wichtiger Begriff der eine Weiterentwicklung des maschinellen Lernens ist „Deep Learning“, das neuronale Netze und große Datenmengen verwendet (Alexandra Jorzig, 2020, S. 109). Mit diesem Verfahren kann Software beispielsweise Sprachen verstehen, Roboter können entwickelt werden, die die Umgebung wahrnehmen können und auch das automatisierte und vernetzte Fahren kann umgesetzt werden (Oliver Keßler, 2017, S. 1). Deep Learning bietet allgemein für die Automobilbranche großes Potenzial, da dieses Verfahren auch bei der Herstellung, Entwicklung oder auch bei dem Einkauf-, bzw. Verkaufsprozess unterstützen kann (Luckow, Andre Cook, Matthew Ashcraft, Nathan Weill, Edwin Djerekarov, Emil Vorster, Bennie, 2017, S. 1). Unter den Begriff Deep Learning fällt auch der Begriff Computer Vision, oder auch Bilder Klassifikationssysteme, wie Google Photo und Facebook (Luckow, Andre Cook, Matthew Ashcraft, Nathan Weill, Edwin Djerekarov, Emil Vorster, Bennie, 2017, S. 1).

3. PROBLEMSTELLUNG

3.1. Erste Forschungsfrage

In der Firma Continental AG wird noch keine Software im Bereich der technischen Sauberkeit eingesetzt, die die künstliche Intelligenz unterstützt. Es wird beispielsweise eine Software bzw. Datenbank zur Partikelerkennung und Datenspeicherung verwendet, die sich allerdings nicht von selbst weiterentwickelt und nur zwischen metallischen (glänzenden) Partikeln, nicht metallischen (nicht glänzenden) Partikeln und Fasern unterscheiden kann. Daher müssen Mitarbeiter, nach der Prüfschrift, oder abhängig der Situation, oft händisch die gefundenen Partikel nachanalysieren, um die Größe und genaue Herkunft zu bestimmen. Des Weiteren ist oftmals nicht klar, aus welchem Prozess die Partikel vereinzelt stammen und aus welchem Material diese Kontaminationen bestehen. Wenn es möglich wäre, diese Informationen zu erlangen, könnten gezielt die Fehlerquellen eliminiert werden. Außerdem geht durch

die händische Nachkontrolle enorm viel Zeit verloren und die Fehlerrate steigt. Aufgrund dieser Problematik soll eine Literaturrecherche durchgeführt werden. Mit dieser sollen KI-Anwendungen im Bereich der technischen Sauberkeit gefunden werden.

3.2. Zweite Forschungsfrage

Aus den Ergebnissen der ersten Forschungsfrage wurde die zweite Problemstellung abgeleitet und die Fragestellung verfasst.

Zur Überwachung der Technischen Sauberkeit der Produkte und Fertigungsprozessen wird eine regelmäßige Untersuchung/Überwachung der Sauberkeit der Produkte durchgeführt. Dabei werden partikuläre Verunreinigungen extrahiert und mittels Bildverarbeitung gezählt und klassifiziert. Das Ziel der Untersuchung ist es, die künstliche Intelligenz zur Ermittlung der Herkunft und weiteren Merkmalen heranzuziehen. Um den Ansatz zur automatischen Partikelanalyse mittels Computer Vision zu prüfen, soll ein Objekterkennungssystem implementiert und getestet werden, ob mit diesem System und den vorhandenen Bildern aus der Datenbank eine Partikelunterscheidung zwischen metallisch (glänzend) und nichtmetallisch (nicht glänzend) möglich ist.

3.3. Dritte Forschungsfrage

Des Weiteren befasst sich die technische Sauberkeit allerdings nicht nur mit den Produktionsbereichen oder Laborbereichen. Ein wichtiger Aufgabenbereich ist auch das Monitoring in der Qualitätsabteilung von technischen Sauberkeitsvorfällen, die zu einem Ausfall geführt haben. Nach dem jetzigen Verfahren erfolgt das Monitoring mit Hilfe eines separaten Tools, dem "CEP Searching tool". Dieses Programm zieht die aktuellen Werksdaten aus dem SAP-Tool und stellt die Datenreihen, ähnlich wie ein Exceldokument, dar. Die für das Tool zur Bewertung und für die spätere Analyse relevanten Daten werden den einzelnen Datenreihen hinzugefügt. Hierzu durchläuft die komplette Datentabelle eine Volltextsuche mit Hilfe von vordefinierten Schlüsselwörtern. Mit dieser Suche werden nur noch die Datenreihen angezeigt, in denen diese Wörter auch vorhanden sind. Hier entstehen die ersten Probleme, da die Volltextsuche keine Textbausteine unterscheiden kann, wie z. B. "kein Partikel gefunden". Nach der jetzigen Suche würde dieser Datensatz im Dokument auftauchen, da nur nach den Schlüsselwörtern gesucht wird. Um diese Textanalyse umzusetzen, soll nach bereits komplett anwendbaren KI-Systemen im Text Mining bzw. Qualitätsanalysen Bereich im Zusammenhang mit den Analysetexten der technischen Sauberkeit mittels einer zweiten Literaturrecherche gesucht werden.

4. ANWENDUNGEN DER KÜNSTLICHEN INTELLIGENZ IM BEREICH DER TECHNISCHEN SAUBERKEIT

4.1. Einführung in die Literaturrecherche

Um die beiden Literaturrecherchen strukturiert durchführen zu können und den neusten Stand der Technik zu erlangen, wird eine systematische Literaturanalyse in Anlehnung an (Peter Fettke, 2006, S. 260) vollzogen. Die Abbildung 3 soll den Ablauf der Forschung darstellen.

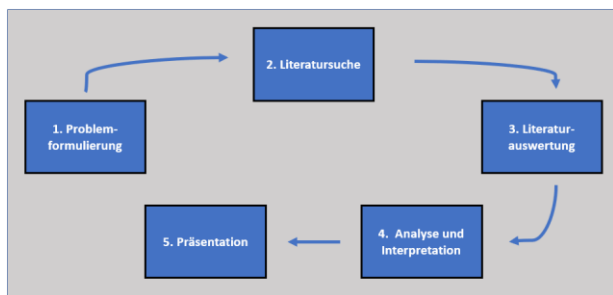


Abbildung 3: Ablauf der Literaturrecherche

Der erste Teil der Literaturrecherche wurde bereits in der Problemformulierung ausführlich beschrieben, um die daraus resultierenden Forschungsfragen zu bestimmen. Für den zweiten Teil, die Literatursuche, werden hauptsächlich wissenschaftliche und technische Suchportale (siehe Abschnitt 3.2.) verwendet, damit relevante Literatur gefunden werden kann. Die Literaturauswertung bzw. Bewertung wird schrittweise durchgeführt. Beim ersten Schritt in der Bewertungsphase werden Duplikate eliminiert, Titel durchgearbeitet und Abstracts gesichtet. Dadurch kann die erste Eliminierungsphase durchgeführt werden. Im zweiten Schritt wird der Inhalt auf die Relevanz überprüft, auf Basis einiger Kriterien.

Im letzten Schritt der Literaturbewertung soll die Suche nochmals von hinten aufgerollt werden. Dies bedeutet, dass die Inhaltsverzeichnisse nochmals nach den genannten Kriterien untersucht werden. Im vierten Analyseteil werden die Literaturquellen in Kategorien bzw. Merkmale eingeteilt und tabellarisch dargestellt (Abschnitt 3.4.). Abschließend wird Teil fünf ebenfalls in Abschnitt 3.4. beschrieben und durchgeführt.

4.2. Literaturrecherche

Um die bedeutendsten Beiträge finden zu können, wurden die Schlüsselwörter hauptsächlich auf den wissenschaftlichen und technischen Suchportalen, „regensburger-katalog“, „statistica“, „springer-professional“ und „hackster.io“ eingegeben. Durch diese Suchportale konnten automatisch noch viele weitere Literaturportale mit in die Suche eingebunden werden, da diese miteinander verknüpft sind (Beispielsweise Scencedirect, DeGruyter). Während der Literatursuche auf diesen großen Portalen hat sich die Schlagwörter Trefferselektion nicht nur auf den Titel begrenzt, sondern

auch auf die Abstracts. Die Keywords wurden jeweils im englisch- sowie deutschsprachigen verwendet, um Methoden der KI im Bereich der technischen Sauberkeit zu finden. Die Schlüsselwörter wurden systematisch verfeinert. In Tabelle 1 werden Schlüsselwörter und Treffer dargestellt.

4.3. Literaturbewertung

Kriterien:

- Betrachtender Zeitraum von 30 Jahren (1990 - 2020)
- TC im Zusammenhang mit KI
- Anwendungsbereiche in Produktion, Labor oder Logistik
- Schlüsselwörter für TC

Schlagwörter	Artikel, Bücher, Zeitschriften
Artificial intelligence and technical cleanliness	8
Automatic particle classification with AI in automotive	709
Künstliche Intelligenz in Reinräumen	7
Artificial intelligence and contamination	240
Artificial intelligence and water contamination	270
Methoden der Künstlichen Intelligenz Partikel Klassifikation	12
Gesamt mit doppelten Treffern:	1246

Tabelle 1: Schlagwörter und Literaturtreffer für die Literaturrecherche über KI-Anwendungen im Bereich der Technischen Sauberkeit




Abbildung 4: Ablauf des Literaturbewertungsprozesses für Anwendungen im Bereich KI

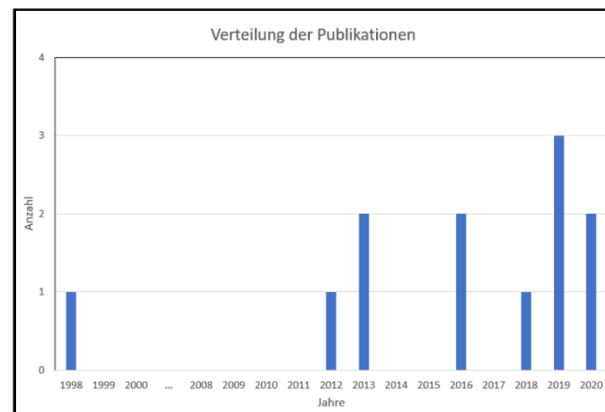


Abbildung 5: Balkendiagramm zur Abbildung der Verteilung der Publikationen

Nachdem von den 1246 gefundenen Quellen die Duplikate entfernt und die Abstracts auf Relevanz überprüft wurden, konnte die Anzahl auf 40 Quellen reduziert werden, da diese keinen Zusammenhang mit der technischen Sauberkeit aufwiesen. Dieser enorme Sprung lässt sich darauf zurückverfolgen, dass der Begriff "KI" oder „AI“ eine große Trefferanzahl mit sich bringt, allerdings ohne direkten Bezug auf die Technische Sauberkeit. Nachdem im zweiten Schritt die Inhalte auf Basis der genannten Kriterien überprüft wurden, wurden nur mehr zehn relevante Quellen festgestellt. Durch die anschließende Rückwärtssuche konnten nochmals drei neue Quellen gefunden werden und die Anzahl auf zwölf relevante Literaturquellen festgelegt werden, die mit dem Thema der Technischen Sauberkeit und KI in Verbindung stehen. Die zwölf Literaturquellen stammen aus zwölf unterschiedlichen Büchern und Zeitschriften.

4.4. Analyse und Interpretation

Die zwölf Literaturquellen wurden zu Beginn in ihre Anwendungsgebiete unterteilt. In diesem Bereich fiel auf, dass noch eine größere Lücke bei der Produktion besteht. Die Anwendungen in diesem Bereich sind nur mit 33 Prozent vertreten, anders als im Labor, wo bereits einige Analyseverfahren angewendet bzw. getestet werden. Das nächste Merkmal unterscheidet die unterschiedlichen Lernalgorithmen im Bereich des ML. Hier wurde vermehrt das überwachte Lernen verwendet, um die Algorithmen umzusetzen. Zusätzlich kann festgestellt werden, dass alle Lernmethoden ihren Einsatz fanden, dadurch entsteht eine breitere Umsetzbarkeit für die Algorithmen. Ein weiteres wichtiges Teilgebiet wurde als nächstes Merkmal angenommen, das Deep Learning, das 57 Prozent der gefundenen Quellen verwenden. Dies bedeutet, dass die Hälfte der gefundenen Quellen beispielsweise neuronale Netze verwenden, um die Algorithmen umzusetzen. Schließlich wurden die Schwerpunkte der einzelnen Quellen in Betracht gezogen, bei denen sich eine eindeutige Tendenz abspiegelt hat, da sich 91 Prozent der Literatur auf den Bereich CV fixieren.

Für die Literaturquellen (Schöch et al., 2019), (Demircioglu et al., 2013), (De Luca, Nicholas Sato, Koichi, 2012), (Roman Möhle, B.Sc. Simon Frentrup, Univ.-Prof. Dr.-Ing. Jochen Deuse, Dipl.-Wirt.-Ing. Ronny Zwinkau, 2018), (Ronny Zwinkau, Simon Frentrup, Roman Möhle, Jochen Deuse, 2020), (Kucera et al., 2016), (Sarah Han, Izu Sotani, Peter Ma, Natka Wojcik, Justin Shenk, 2020), (Z. Peng, 1998), (Phan Quoc Bao, Sung-Lim Ko, 2016), (Norousi, 2013) (Jakobs et al., 2019) wurden für die Literaturanalyse die nachfolgenden Tabelle 2 mit ihren Merkmalen erstellt.

Quellen	Anwendungsgebiete		Maschinelles Lernen			Teilgebiet von ML	Themenschwerpunkte		
	Produktion	Labor	Überwachtes Lernen	Bestärktes Lernen	Unüberwachtes Lernen		Deep Learning	Computer Vision	Sensorik
(Schöch2019)		✓			✓		✓		
(Demirciolu2013)	✓		✓				✓		
(DeLuca2012)	✓		k. A.	k. A.	k. A.		✓	✓	
(Möhle2018)		✓		✓		✓	✓		
(Zwinkau2019)	✓	✓		✓		✓	✓		
(Zwinkau2020)		✓		✓		✓	✓		
(Kucera2016)		✓	✓			✓	✓		
(Han2020)		✓	✓			✓	✓		
(Peng1998)		✓	✓		✓	✓	✓		
(Phan2016)	✓			✓		✓	✓		
(Norousi2013)		✓	✓				✓		
(Jakobs2019)		✓	✓			✓			✓
n = 12	4	9	6	4	2	8	11	1	1
	33 %	75 %	50 %	33 %	1%	57 %	91 %	8 %	8 %

Tabelle 2: Literaturanalyse für KI-Anwendungen im Bereich der TC mit ihren Merkmalen

5. ANWENDUNG EINES COMPUTER VISION MODELLS ZUR ANALYSE PARTIKULÄRE VERUNREINIGUNGEN

Die Methoden der Computer Vision werden in der Zukunft viele Arbeitsbereiche verändern, da es damit möglich ist, sehr arbeitsaufwendige Tätigkeiten zu unterstützen. Zusätzlich können automatische Bilderkennungssysteme, auch bei der Entdeckung von Kontaminationen oder anderen Unreinheiten, hilfreich sein. Ein Bereich, bei dem diese Technik in der Automobilbranche bereits Anwendung findet, ist das autonome Fahren (Patrick Zschech, Christoph Sager, Philipp Siebers, Maik Pertermann, 2020, S. 3).

5.1. Darstellung der Systemumgebung

Für das Training des Modells wurde die Webbasierte Systemumgebung „Continental - datalake“ verwendet. Dieses System bietet eine benutzerfreundliche Umgebung, die das Speichern, Rechnen und Visualisieren innerhalb der AWS Cloud ermöglicht (Continental-intern). Durch die Webbasierte Anwendung wurde anschließend eine neue Jupyter Notebook Applikation gestartet. Mit Jupyter Notebook ist es möglich, die Programmiersprache Python programmieren und ausführen zu können. Um das Computer Vision Modell umzusetzen, wurden vier CPUs (je 2.5 GHz Intel Scalable-Prozessor) mit 16 GB Arbeitsspeicher und einer 30 GB Datenträgergröße kombiniert. Um die Klassifikation auf der Systemumgebung durchführen zu können, wurde hier das Computer Vision Modell YoloV3 („You only look once“) ausgewählt, da dieses Modell die nachfolgend genannten Vorteile aufweist. In einer Studie von 2018 schnitt YoloV3 gegenüber anderen R-CNN Modellen im Bereich der Geschwindigkeit eindeutig besser ab, aber auch bei der Genauigkeit lag YoloV3 im oberen Mittelfeld, trotz dieser hohen Geschwindigkeit (Tsung-Yi Lin, Goyal Priya, Girshick Ross, Kaiming He, Piotr Dollar, 2018, S. 1).

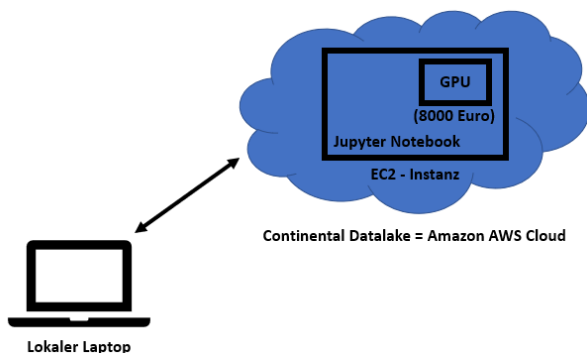


Abbildung 6: Darstellung der Systemumgebung




Abbildung 7: Trainingsverlauf mit Darstellung des durchschnittlichen Verlustfehlers

5.2. Validierung und Interpretation

Rahmenbedingungen:

- 1017 Partikelbilder wurden dem Modell antrainiert. Davon waren grundsätzlich 646 metallische Partikel und 371 nichtmetallische Partikel.
- Reduktion der Trainingslaufzeit auf maximal drei Stunden.
- 1064 Partikelbilder werden dem Programm zum Test gezeigt. Diese wurden dazu auch gelabelt als metallische- und nichtmetallische Partikel.
- Zehn Bilder werden dem Modell zum Test vorgezeigt, die davor nicht gelabelt wurden.

Für die Trainingsabläufe bzw. Trainingsrunden werden bei CNN Modellen zwischen Examples, batch-size, Iterationen und Epochen unterschieden. So sind beispielsweise 4000 Examples und 500 batch-sizes, 8 „Iterationen“ und 1 Epoche. Daraus folgt, dass eine Epoche vollendet ist, wenn das Modell alle vorhandenen Examples einmal durchlaufen (SAGAR SHARMA, 2017, S. 1). Zum Start der Validierung zeigt das Diagramm 7 den durchschnittlichen Verlustfehler für die Trainingsiterationen. Der durchschnittliche Verlustfehler bzw. AP (Average precision/Durchschnittliche Präzision) ist eine beliebte Methodik, um die Genauigkeit eines Computer Vision Modells zu messen.

	Durch Modell prognostizierte Klasse		Zeilensumme	
	metal (Anzahl)	nonmetal (Anzahl)		
	Σ			
Tatsächliche Klasse	metal (Anzahl)	456 (TP)	43 (FN)	499 (TP + FN)
	nonmetal (Anzahl)	146 (FP)	419 (TN)	565 (FP + TN)
Spaltensumme	Σ	602 (TP + FP)	462 (FN + TN)	82,24 %

Tabelle 3: Konfusionsmatrix i. A. a. (Kohl M, 2012, S. 79)

Damit solch eine Beurteilung mittels Konfusionsmatrix umgesetzt werden kann, muss das Modell mit bekannten Werten bzw. Bildern getestet werden. Dadurch kann festgestellt werden, ob die Ergebnisse richtig oder falsch sind (Lanquillon Carsten, 2019, 89ff). TP (true positiv)

bedeutet, dass die prognostizierte Klasse richtig zur tatsächlichen Klasse eingestuft wurde. TN (true negativ) ist hier, wenn die tatsächliche Klasse negativ war und diese auch richtig als negativ eingestuft wurde. Bei FN (false negativ) Fällen, wurden die Bilder als negativ gelabelt, allerdings falsch bewertet. FP (false positiv) gibt im Gegenzug die positiv gelabelten an, die falsch, also als negativ eingestuft wurden. Zusätzlich zur Konfusionsmatrix wurden weitere Berechnungen durchgeführt (Zwinkau, 2019, S. 45):

$$\text{Genauigkeit} = \frac{TP + TN}{TP + FP + FN + TN} \quad (1)$$

$$\text{Genauigkeit} = \frac{(456 + 419)}{(456 + 43 + 146 + 419)} = 82,24\text{Prozent} \quad (2)$$

Es konnte gezeigt werden, dass das CNN Modell YoloV3 bereits ähnliche und vergleichbare Ergebnisse liefert, wie das in der Literatur gefundene CNN Modell von (Zwinkau, 2019, S. 110). Zwinkau, 2019, S. 110 verglich sein Modell mit einem Metall-/Nichtmetall-Klassifikationsmodell mit Polarisationsfiltern gemäß der VDA 19.1. und kam mit seiner Auswertung auf ein vergleichbares Ergebnis. Daraus folgt, dass dieses implementierte Modell auch vergleichbare Ergebnisse zu diesem Verfahren liefern kann, da die Bilderqualität ähnlich war, wie bei den Testversuchen von Zwinkau, 2019, S. 111. Des Weiteren konnte dargestellt werden, dass die Integration dieses Modells keine komplexen Softwarestrukturen benötigt und deshalb leicht durch die bestehenden Bauteile nachgestellt werden kann. Damit ist die zweite Forschungsfrage beantwortet. Die nachfolgenden Bilder zeigen Ausgaben von unbekanntem Testbildern, die richtig oder falsch klassifiziert wurden. Unbekannte Testbilder bedeutet hier, dass diese Bilder nicht gelabelt wurden.




Abbildung 8: metallischer Partikel




Abbildung 9: metallischer Partikel2




Abbildung 10: metallischer Partikel3




Abbildung 11: metallischer Partikel4



Abbildung 12: nicht metallischer Partikel



Abbildung 13: nicht metallischer Partikel2

Es lässt sich feststellen, dass das Modell Schwierigkeiten besitzt, wenn mehrere Partikel auf einen Bild vorhanden sind. Ein weiteres Problem tritt bei filmischen Verunreinigungen auf, wie in Abbildung 10 aufgezeigt. Diese werden ebenso nur teilweise erkannt. Außerdem zeigt Abbildung 9 die Problematik mit dem Hintergrund, da dieser auch meist glänzend ist und eine Unterscheidung erschwert. Abbildungen 8, 11, 12 und 13 zeigen gute Ergebnisse.

6. WEITERE TEXT MINING ANWENDUNGEN IM BEREICH DER TECHNISCHEN SAUBERKEIT

Die Literaturbewertung (Abbildung 14) zeigt, dass es noch keine Applikation zur Bewertung von Analysetexten gibt, die die technische Sauberkeit betrifft. Allerdings konnte festgestellt werden, dass enorme Potenziale des Text Mining und NLP vorhanden sind.




Abbildung 14: Ablauf des Literaturbewertungsprozesses für Text Mining Applikationen für TC Analyseberichte

7. ZUSAMMENFASSUNG UND AUSBLICK

Im Rahmen der Bearbeitung der Forschungsfrage wurde festgestellt, dass nur ein kleiner Teil der relevanten Veröffentlichungen auf Fertigungsbelange fokussiert. Für Anwendungen im Bereich der Fertigungsanalyse besteht weiterer Forschungsbedarf. Um die zweite Forschungsfrage beantworten zu können wurde ein CNN Modell (YOLOv3) implementiert, trainiert und getestet. Es kann festgestellt werden, dass das implementierte Modell es ermöglicht, eine Unterscheidung zwischen metallischen und nichtmetallischen Partikeln durchführen zu können. Damit wurde der Grundstein für weitere Untersuchungen gelegt. Für die dritte Literaturfrage wurde eine weitere

Literaturforschung zur Suche nach fertigen KI-Anwendungen durchgeführt, die zur Analyse von Texten mit dem Kontext zur TC verwendet werden können. Hier besteht ebenfalls weiterer Forschungsbedarf. Künftige Arbeiten können dieses Projekt als Grundlage verwenden und hierauf aufsetzen. Das implementierte Modell kann dahingehend modifiziert und weitere Partikelklassen mit mehreren Bildern dem Modell antrainiert werden. Beispielsweise könnte das Programm lernen, die Partikel auch dem Prozess zuzuordnen bzw. eine weitere Analyse für die genaue Herkunft zu ermöglichen. Durch solche eine Analyse könnten auch weitere Daten miteinander verknüpft werden, wie Merkmale des Partikels, Produktionswerk, Produktionslinie oder auch welches Produkt betroffen war. Zusätzlich zu dieser Erweiterung der Analyse könnte die Bildvorverarbeitung vereinfacht werden, wenn eine Schnittstelle von dem Modell zu der Jomesa Datenbank aufgebaut wird. Dadurch wäre eine automatische Extraktion der Partikelbilder möglich. In diesem Projekt konnte gezeigt werden, dass Methoden der künstlichen Intelligenz zur Verbesserung der Analyse der technischen Sauberkeit zur Anwendung gebracht werden können. Allerdings befindet sich diese Thematik erst in ihren Anfängen.

Literaturverzeichnis

- Alexandra Jorzig, F. S. (2020). Künstliche Intelligenz und Robotik. *Digitalisierung im Gesundheitswesen*, 107–168.
- Continental-intern (abgerufen am 2020, August). Continental datalake documentation. <https://docs.datalake.conti.de>.
- De Luca, Nicholas Sato, Koichi. (2012). *AUTOMATED MONITORING AND CONTROL OF CLEANING IN A PRODUCTION AREA* (Patent number: G08B 23/00). Espacenet (European Patent Office).
- Demircioglu, P., Bogrekci, I. & Durakbasa, N. M. (2013). Micro scale surface texture characterization of technical structures by computer vision. *Measurement*, Vol.46(6), 2022–2028.
- F. Chollet. (2018). *Deep Learning mit Python*. MITP.
- Felix Weber. (2020). *Künstliche Intelligenz für Business Analytics*. Springer Fachmedien Wiesbaden.
- Holzapfel, Y. & Kreck Guido (2013). Technische Sauberkeit: Bestimmung der partikulären Reinheit - von der Automobilindustrie bis zur Medizintechnik. *Reinraum printline*, 4–9.
- J. Frochte. (2018). *Maschinelles Lernen - Grundlagen und Algorithmen in Python*. Carl Hanser Verlag GmbH & Co. KG.
- Jakobs, M. A. H., Dimitracopoulos, A., Franze, K., Bassereau, P. & Malhotra, V. (2019). KymoButler, a deep learning software for automated kymograph analysis. *eLife*, Vol.8.
- Kucera, M., Ales, Z., Pavlu, J. & Hnilicova, M. (2016). Applying of Automatic Laser Particle Counter as Technique to Morphology Assessment and Distribution of Wear Particles during Lifetime of Transmission Oils. *Key Engineering Materials*, Vol.669, 417–425.
- Lanquillon Carsten. (2019). Grundzüge des maschinellen Lernens. In Erschienen in: Blockchain und maschinelles Lernen (Hrsg.) (S. 89–142). Springer Berlin Heidelberg.
- Läpple R (2009). Mit steigender Präzision wird die Sauberkeit wichtiger; Saubere Produkte leben länger. *Quality Engineering*, S. 26 - 29.
- Luckow, Andre Cook, Matthew Ashcraft, Nathan Weill, Edwin Djerekarov, Emil Vorster, Bennie (2017). Deep Learning in the Automotive Industry: Applications and Tools. *BMW Group, IT Research Center, Information Management Americas, Greenville, SC 29607, USA*, 1–10. <https://arxiv.org/pdf/1705.00346.pdf>
- Norouzi, R. (2013). *Automatic approaches for microscopy imaging based on machine learning and spatial statistics*. München, Univ., Diss.
- Oliver Keßler (2017). Intelligente Roboter – neue Technologien im Einsatz. *MMR 2017*, 589. <https://beck-online.beck.de/Dokument?vpath=bibdata/zeits/mmr/2017/cont/mmr.2017.589.1.htm&anchor=Y-300-Z-MMR-B-2017-S-589-N-1>
- Patrick Zschech, Christoph Sager, Philipp Siebers, Maik Pertermann (2020). Mit Computer Vision zur automatisierten Qualitätssicherung in der industriellen Fertigung: Eine Fallstudie zur Klassifizierung von Fehlern in Solarzellen mittels Elektrolumineszenz-Bildern. *HMD Praxis der Wirtschaftsinformatik*.
- Peter Fettke (2006). State-of-the-Art des State-of-the-Art. *Wirtschaftsinformatik*, 257–266.
- Phan Quoc Bao, Sung-Lim Ko (2016). Improvement of particle classification using particle expert system in automotive production. *The International Journal of Advanced Manufacturing Technology > Ausgabe 5-8*, 1443–1455.
- Prof. Dr. Peter Buxmann, Dr. Holger Schmidt. (2019). 11: Künstliche Intelligenz - Mit Algorithmen zum wirtschaftlichen Erfolg. In (S. 173–185). Springer Berlin Heidelberg.
- Roman Möhle, B.Sc. Simon Frentrup, Univ.-Prof. Dr.-Ing. Jochen Deuse, Dipl.-Wirt.-Ing. Ronny Zwinkau (2018). Metall/Nichtmetall-Klassifikation von Partikeln mit Deep Learning. *JOT Journal für Oberflächentechnik*, Ausgabe 10, 50–57.
- Ronny Zwinkau, Simon Frentrup, Roman Möhle, Jochen Deuse (2020). Automatic Particle Classification Through Deep Learning Approaches for Increasing Productivity in the Technical Cleanliness Laboratory. *Advances in Human Factors and Systems Interaction*, 34–44.
- SAGAR SHARMA (2017). Epoch vs Batch Size vs Iterations. *towards data science*, abgerufen am

24.08.2020. <https://towardsdatascience.com/epoch-vs-iterations-vs-batch-size-4dfb9c7ce9c9>

Sarah Han, Izu Sotani, Peter Ma, Natka Wojcik, Justin Shenk (2020). Jetson Clean Water AI - Using AI object detection to detect water contamination. <https://www.hackster.io>.

Schöch, A., Perez, P., Linz-Dittrich, S., Bach, C. & Ziolek, C. (2019). Automated discrimination of surface imperfections and adhered particles on customer-specific optical elements. *tm - Technisches Messen*, Vol.86(7), 399–403.

Thomas Siebel (2020). Die digitale Fabrik etabliert sich in der Industrie. *Industrie 4.0*.

Tsung-Yi Lin, Goyal Priya, Girshick Ross, Kaiming He, Piotr Dollar. (2018). *Focal Loss for Dense Object Detection*. Facebook AI Research (FAIR).

Verband der Automobilindustrie e. V. (2015). *VDA 19 Teil 1 - Inspection of Technical Cleanliness*. Henrich Druck + Medien GmbH.

Wolfgang Ertel. (2016). *Grundkurs Künstliche Intelligenz*. Springer Fachmiedien Wiesbaden.

Z. Peng, T. K. (1998). Automatic wear-particle classification using neural networks. *Tribology Letters* > Ausgabe 4, 249–257.

Zwinkau, R. (2019). *Adaption von Verfahren der Bilderkennung auf die Regelung partikelsensibler Produktionssysteme* (TU Technische Universität Dortmund, Hg.). Shaker Verlag.