SACHBERICHT ZUM VERWENDUNGSNACHWEIS

Teil I: Kurzbericht

Zuwendungsempfänger:	Universität Bremen, Fachbereich 3, Zentrum für Industriemathematik
Projektleitung:	Prof. Dr. Andreas Rademacher
Förderkennzeichen:	03TR07W11A
Vorhaben:	T!Raum – #MOIN – Optical Analyzer, TP1: Uni Bremen
Laufzeit:	01.04.2024-30.06.2025

Ziel des Projekts war die Entwicklung eines ersten Prototyps für eine Anlage zur Online-Inspektion von Kabelummantelungen, die es ermöglicht, defektbehaftete Produkte im laufenden Produktionsprozess zuverlässig zu detektieren. Das System ist dabei nicht auf eine spezifische Kabelart oder -klasse beschränkt, sondern soll flexibel an unterschiedliche Kabeltypen beim Kunden anpassbar sein, ohne dass hierfür umfangreiche Rüstzeiten erforderlich sind. Hierfür werden vor dem Umrüstvorgang produktspezifische Bildaufnahmen der Kabelprodukte direkt beim Kunden erfasst. Diese dienen als Datengrundlage, um das System gezielt auf die neue Kabelart zu adaptieren. Nach erfolgreicher Anpassung soll das System in der Lage sein, Fehler und Abweichungen in der Kabelummantelung während der laufenden Produktion automatisiert und in Echtzeit zu detektieren. Es ist anzumerken, dass der im Projekt entwickelte Prototyp primär der Machbarkeitsstudie und Validierung der zugrunde liegenden Methoden unter praxisnahen Bedingungen dient. Aufbauend auf den gewonnenen Erkenntnissen soll die Anlage in weiteren Entwicklungsschritten nach Projektende bei Sikora zu einem marktfähigen System ausgebaut werden.

Die Entwicklung des Oberflächeninspektionsgeräts lässt sich in zwei zentrale Themenbereiche untergliedern: Zum einen die Konstruktion eines ersten Prototyps, der das Aufnahmesystem umfasst, und zum anderen die Entwicklung geeigneter Algorithmen zur Verarbeitung der aufgenommenen Bilddaten und zur Detektion von Defekten. Der Schwerpunkt der Arbeiten der Universität Bremen lag dabei auf der algorithmischen Entwicklung.

Zentraler Gegenstand der algorithmischen Entwicklung waren Verfahren zur Out-of-Distribution (OOD)- bzw. Anomaliedetektion**.** Dieses Themenfeld stellt ein aktives Forschungsgebiet mit einer Vielzahl jährlich erscheinender Publikationen dar [1, 2] und beschäftigt sich mit der Identifikation unerwarteter oder bislang unbekannter Daten. Im Rahmen des Projekts wurden insbesondere generative Modelle untersucht, die die Verteilung fehlerfreier Trainingsdaten erlernen und Abweichungen von dieser gelernten Verteilung zur Identifikation potenzieller Defekte nutzen.

Die in der Literatur beschriebenen Verfahren zur Anomaliedetektion weisen bereits eine hohe Performanz auf. Daher wurden im Rahmen des Projekts zwei besonders vielversprechende und für das geplante Anwendungsszenario geeignete Ansätze aus der Literatur ausgewählt, implementiert und gezielt für das vorliegende Problem weiterentwickelt. Der Fokus lag dabei auf drei zentralen Aspekten: (1) der Verbesserung der Performanz der Algorithmen, (2) der Untersuchung ihrer Robustheit, insbesondere im Hinblick auf den Einsatz bei unbekannten Kundendaten, sowie (3) der Analyse der Datenvorverarbeitung und deren Einfluss auf die algorithmische Leistungsfähigkeit. Die Robustheitsanalyse ist hierbei von besonderer Bedeutung, um sicherzustellen, dass die entwickelten Verfahren auch unter realen Einsatzbedingungen mit zuvor unbekannten Daten zuverlässig funktionieren.

Das diesem Bericht zugrundeliegende Vorhaben wurde mit Mitteln des Bundesministeriums für Forschung, Technologie und Raumfahrt gefördert. Die Verantwortung für den Inhalt der Veröffentlichung liegt beim Autor.

Es zeigte sich, dass die Algorithmen aus der Literatur bereits sehr leistungsfähige Ergebnisse liefern und weitere Anpassungen oder Modifikationen nur marginale Verbesserungen der Performanz bewirken. Hingegen hat sich die Datenvorverarbeitung sowie die Qualität der Eingangsdaten als entscheidender Faktor herausgestellt, um eine hohe Performanz zu erzielen. Insgesamt konnten die angepassten Algorithmen eine hohe Detektionsgenauigkeit bei gleichzeitig anwendungstauglichen Eigenschaften wie kurzer Trainingsdauer und schneller Ausführungszeit erreichen.

Neben der Entwicklung von Algorithmen zur Anomaliedetektion lag ein weiterer Schwerpunkt des Projekts auf der Generierung künstlicher Defektbilder. Dies ist von zentraler Bedeutung, da nur eine begrenzte Anzahl realer Defektbilder vorliegt, diese jedoch für die Anpassung und Validierung der Algorithmen unerlässlich sind. Zu diesem Zweck wurde ein sogenanntes Diffusionsmodell implementiert, das Defekte auf der Grundlage defektfreier Aufnahmen synthetisch in die Bilder einfügt.

Die entwickelten Algorithmen zur Anomaliedetektion sowie das generative Modell zur Erzeugung künstlicher Defektdaten wurden genutzt, um eine Pipeline für das Training und den Einsatz der Modelle direkt beim Kunden zu entwickeln. Dafür wurde folgendes Szenario zur Anpassung der Algorithmen, insbesondere der Neuronalen Netze, an die kundenspezifischen Produkte definiert: Die Neuronalen Netze werden ohne vorheriges Offline-Vortraining unmittelbar auf den Kundendaten trainiert. Anschließend erfolgt eine Feinjustierung zentraler Hyperparameter, welche die Art und Stärke der detektierten Defekte beeinflussen. Diese Hyperparameter können entweder ohne Kundenfeedback oder unter Einbeziehung von Rückmeldungen des Kunden angepasst werden. Im letzteren Fall kommt das generative Modell zur Erzeugung künstlicher Defektdaten zum Einsatz, das dem Kunden als Entscheidungshilfe dient.

Zusammenfassend konnten die entwickelten Algorithmen sowohl hinsichtlich ihrer Performanz als auch ihrer Anwendbarkeit überzeugen. Die weiterführende Entwicklung der Verfahren wird daher als vielversprechend eingeschätzt. Entscheidend für den weiteren Fortschritt ist die Erfassung zusätzlicher Datensätze bei Kunden unter realen Produktionsbedingungen. Dies ist notwendig, um die Verfahren unter praxisnahen, bislang unbekannten Einsatzszenarien zu validieren und mögliche Schwachstellen frühzeitig zu identifizieren.

Literaturverzeichnis

[1] Liu, J., Xie, G., Wang, J. *et al.*, „Deep Industrial Image Anomaly Detection: A Survey“, in *Mach. Intell. Res.* vol. 21, pp. 104–135 (2024). doi: 10.1007/s11633-023-1459-z.

[2] G. Xie *et al*., "IM-IAD: Industrial Image Anomaly Detection Benchmark in Manufacturing", in *IEEE Transactions on Cybernetics*, vol. 54, no. 5, pp. 2720-2733 (2024), doi: 10.1109/TCYB.2024.3357213.

Das diesem Bericht zugrundeliegende Vorhaben wurde mit Mitteln des Bundesministeriums für Forschung, Technologie und Raumfahrt gefördert. Die Verantwortung für den Inhalt der Veröffentlichung liegt beim Autor.

SACHBERICHT ZUM VERWENDUNGSNACHWEIS

Teil II: Schlussbericht

Zuwendungsempfänger:	Universität Bremen, Fachbereich 3, Zentrum für Industriemathematik
Projektleitung:	Prof. Dr. Andreas Rademacher
Förderkennzeichen:	03TR07W11A
Vorhaben:	T!Raum – #MOIN – Optical Analyzer, TP1: Uni Bremen
Laufzeit:	01.04.2024-30.06.2025

Ausführliche Darstellung der Arbeiten im Projekt insbesondere im Vergleich zur ursprünglichen Vorhabenbeschreibung

AP 1 (Projektorganisation, Datenakquise und Kunden-Feedback)

Im Berichtszeitraum fanden alle zwei Wochen Meetings (via MS Teams) mit dem Projektpartner statt, um den aktuellen Entwicklungsstand zu besprechen. Zusätzlich wurden separate Besprechungen durchgeführt, um Detailfragen mit den jeweiligen Beteiligten abzustimmen.

Die Meetings dienten der kontinuierlichen Abstimmung des wissenschaftlichen Anforderungsprofils, um eine zielgerichtete und erfolgreiche Entwicklung sicherzustellen. In diesem Kontext wurde eine Pipeline entwickelt, die die einzelnen Schritte zur Entwicklung eines Algorithmus zur Anomalieerkennung präzisiert. Der Begriff Pipeline bezieht sich hierbei auf die übergeordnete Gesamtstrategie zur Anomalieerkennung, während der Begriff Algorithmus das spezifische Berechnungsverfahren zur Erkennung von Anomalien bezeichnet. Im Detail wurde folgende Pipeline definiert:

1. Entwicklung eines Algorithmus zur Anomalieerkennung, der möglichst für eine Vielzahl unterschiedlicher Kabelprodukte geeignet ist.
2. Anpassung des Algorithmus beim Kunden an die spezifischen Produkte und Defekte. Hierfür ist besonderes Augenmerk auf die Robustheit des in Punkt 1 entwickelten Algorithmus zu legen, um eine erfolgreiche Adaption sicherzustellen.

Um eine erfolgreiche Anwendung im laufenden Betrieb beim Kunden sicherzustellen, wurden folgende Anforderungen an den Algorithmus definiert (siehe AP 1.5):

- Der Algorithmus muss eine hohe Genauigkeit erreichen. Dabei ist eine fehlerhafte Klassifikation eines defektbehafteten Samples als defektfrei kritischer zu bewerten als der umgekehrte Fall.
- Der Algorithmus – insbesondere das enthaltene neuronale Netz – muss innerhalb von etwa 15 Minuten direkt beim Kunden trainierbar sein.
- Der Algorithmus muss über eine ausreichende Berechnungsfrequenz verfügen, um einen Versatz zur Liniengeschwindigkeit zu vermeiden und eine Auswertung im laufenden

Das diesem Bericht zugrundeliegende Vorhaben wurde mit Mitteln des Bundesministeriums für Forschung, Technologie und Raumfahrt gefördert. Die Verantwortung für den Inhalt der Veröffentlichung liegt beim Autor.

Produktionsprozess zu ermöglichen. Konkret wurde von Sikora hierfür eine minimale Frequenz von 50–60 frames per second (FPS) im Worst-Case-Fall spezifiziert.

- Die trainierten Netzwerkparameter dürfen nicht zu groß sein, um die Speicherung aller beim Kunden trainierten Netze sicherzustellen.

AP 2 Versuchsaufbau und Messungen

Die Entwicklung des Versuchsaufbaus sowie die Durchführung der Messungen lagen in der Verantwortung von Sikora. Die Anforderungen an die Messaufnahmen, die für eine erfolgreiche Anomalieerkennung erforderlich sind, wurden gemeinsam abgestimmt. Hierbei wurde besonderes Augenmerk auf die Anforderungen der implementierten Algorithmen als auch auf die technische Umsetzbarkeit gelegt.

Konkret wurden folgende Merkmale der Kabel als besonders relevant für die Entwicklung der Algorithmen identifiziert: stark reflektierende und matte Oberflächen, Produkte mit und ohne Schriftzug, texturierte und glatte Kabel, verschiedenfarbige Ausführungen sowie Kabel unterschiedlicher Durchmesser. Dabei ist zu beachten, dass die Verfügbarkeit dieser Kabeltypen von den durch die Kunden von Sikora bereitgestellten Proben abhängig ist.

Die zur Verfügung stehenden Messdaten stellten die Algorithmen vor unerwartete Herausforderungen. Insbesondere ungewollte Reflexionen auf den Aufnahmen (ausgelöst durch den technischen Aufbau), eine unzureichende Kameraabdeckung des Produktes, eine begrenzte Verfügbarkeit von Aufnahmen realer Defekte sowie eine geringe Variation der Kabeltypen erschwerte die Entwicklung robuster Algorithmen.

Zudem konnten die realen Messdaten aus verschiedenen Gründen erst später als im Antrag vorgesehen bereitgestellt werden, was die Entwicklung und das Testen der Algorithmen auf realen Daten verzögerte.

AP 3 Datenvorverarbeitung, Modellierung und Augmentation

Nach einer projektinternen Absprache wurde zur Steigerung der Bearbeitungseffizienz entschieden, dass dieses AP federführend von dem SIKORA-Projektteam bearbeitet wird. Dieses Arbeitspaket führte u.a. zu einer gemeinsam betreuten Masterarbeit [E2].

Zur Generierung und Modellierung synthetischer Daten wurde seitens Sikora ein CAD- und Simulationsmodell in Blender entwickelt, das auf dem Aufbau des physischen Prototyps basiert. Dieses Modell ermöglicht die Erstellung realitätsnaher synthetischer Daten.

Eine eingehende Literaturrecherche zur Erstellung von Daten mit künstlichen Defekten ergab, dass Diffusionsmodelle state-of-the-art Ergebnisse liefern und für die vorliegende Aufgabe besonders geeignet sind. Daher wurde der Schwerpunkt auf diese Modelle gelegt. Die künstlich erzeugten Defektdaten der Diffusionsmodelle überzeugten visuell und wurden erfolgreich in AP 4 integriert (siehe AP 3.2-AP 3.4).

Die Diffusionsmodelle ermöglichen eine präzise Steuerung der Position, Form und Größe der Defekte mittels einer Maske, die als Input an das Netzwerk übergeben wird. Zusätzlich kann auch die Intensität der Defekte reguliert werden. Diese Funktionalität ist besonders für die Untersuchungen in AP 5 von Vorteil, da bei Kunden Defekte mit variierender Stärke und Größe auftreten können.

Die Umsetzung der Modelle zeigte, dass insbesondere das Training von Diffusionsmodellen zeitaufwendig ist was aus einem mehrstufigen Training des Modells resultiert. Die Generierung neuer Defekte mit einem trainierten Netzwerk erfolgt hingegen vergleichsweise schnell und kann auch direkt beim Kunden eingesetzt werden (siehe AP 5).

Das diesem Bericht zugrundeliegende Vorhaben wurde mit Mitteln des Bundesministeriums für Forschung, Technologie und Raumfahrt gefördert. Die Verantwortung für den Inhalt der Veröffentlichung liegt beim Autor.

Das erstellte Modell wurde verwendet, um gelabelte Datensätze mit künstlichen Defekten unterschiedlicher Größe und Stärke zu erzeugen, welche in AP 4 zur Evaluation der Algorithmen verwendet wurden.

AP 4 Out-of-distribution Detektion

Zur Bearbeitung dieses Arbeitspakets wurde zunächst eine umfassende Literaturrecherche zum Thema Out-of-Distribution- und Anomalieerkennung durchgeführt. Dies erwies sich als besonders relevant, da es sich um ein aktives Forschungsfeld mit einer hohen Zahl jährlich erscheinender Publikationen handelt. Die Literaturrecherche hat gezeigt, dass bereits eine Vielzahl leistungsfähiger Algorithmen für die industrielle Anomalieerkennung existiert, die auf gängigen Benchmark-Datensätzen teils nahezu perfekte Resultate erzielen konnten (vgl. [2, 4]). Vor diesem Hintergrund wurde im Rahmen der Algorithmenentwicklung auf bestehende, in der Literatur gut dokumentierte Verfahren zurückgegriffen, die hinsichtlich ihrer Eignung für die spezifischen Anforderungen des Projekts positiv bewertet wurden. Diese Verfahren wurden im weiteren Verlauf entsprechend angepasst und weiterentwickelt.

Insbesondere density-basierte Ansätze zur Anomalieerkennung wurden als für das Projektvorhaben besonders geeignet eingestuft. Dies steht im Einklang mit den im Antrag erwähnten Normalizing Flows (siehe AP 4.1 und 4.2). Im Zuge der weiteren Evaluierung stellte sich jedoch heraus, dass alternative Modelle eine höhere Eignung aufweisen als die in den Arbeitspaketen 4.5 bis 4.7 vorgesehenen score-based diffusion Modelle. Besonders hervorzuheben ist hierbei das sogenannte FastFlow Modell [5], welches anstelle der score-based Modelle implementiert wurde. Infolge dieser konzeptionellen Anpassung wurden die Arbeitspakete 4.5 bis 4.8 inhaltlich auf die Verwendung des *FastFlow*-Modells ausgerichtet.

Insgesamt wurden zwei Methoden aus dem Bereich der density-basierten Anomalieerkennung implementiert (siehe AP 4.1, 4.2 und 4.5 bis 4.7): Eine Methode von Rippel et al. [3], die eine Klassifizierungsaufgabe löst, sowie der oben erwähnte FastFlow, der eine Segmentierungsaufgabe löst. Die Auswertungs-Pipeline beider Algorithmen ist in **Fehler! Verweisquelle konnte nicht gefunden werden.** dargestellt.

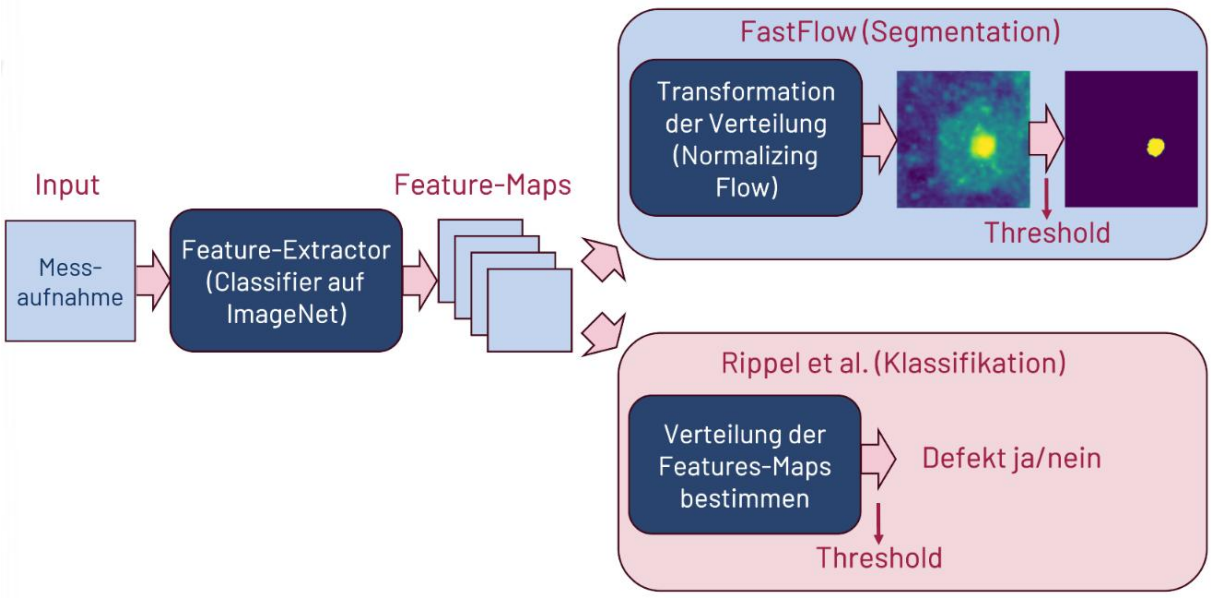

Abbildung 1 Übersicht über die Funktionsweise des FastFlow und des Modells von Rippel et al.

Wie in **Fehler! Verweisquelle konnte nicht gefunden werden.** dargestellt, wird im ersten Schritt ein F eature-Extraktor eingesetzt, um sogenannte Feature-Maps aus den Bilddaten zu extrahieren. Dabei handelt es sich um ein vortrainiertes Klassifikationsnetzwerk, das auf allgemeinen Bilddaten –

Das diesem Bericht zugrundeliegende Vorhaben wurde mit Mitteln des Bundesministeriums für Forschung, Technologie und Raumfahrt gefördert. Die Verantwortung für den Inhalt der Veröffentlichung liegt beim Autor.

unabhängig von Kabelbildern – trainiert wurde. Durch die Verwendung dieses Feature-Extraktors wird eine robustere und zugleich effizientere Anomaliedetektion ermöglicht.

Im zweiten Schritt wird auf Basis fehlerfreier Samples die Verteilung der extrahierten Feature-Maps erlernt. Das *FastFlow* Modell (oberer Zweig in **Fehler! Verweisquelle konnte nicht gefunden werden.**) t ransformiert diese Verteilung in eine multivariate Gaußverteilung. Im Gegensatz dazu modelliert der Ansatz von Rippel et al. (unterer Zweig in **Fehler! Verweisquelle konnte nicht gefunden werden.**) die V erteilung direkt unter der Annahme einer zugrunde liegenden Gaußverteilung, ohne eine explizite Transformation durchzuführen.

Beide Verfahren ermöglichen es, für ein neues Sample zu bewerten, ob dessen Feature Verteilung mit jener der Gut-Daten übereinstimmt (kein Defekt) oder signifikant davon abweicht (potenzieller Defekt). Zur Bewertung der Zugehörigkeit zur Gut-Daten Verteilung können unterschiedliche Kennwerte herangezogen werden, wie etwa die Likelihood**,** die Likelihood Ratio oder die Typicality (vgl. AP 4.2), jeweils in Kombination mit einem Schwellenwert, der als Entscheidungsgrenze für „Defekt“ vs. „kein Defekt“ fungiert und nach dem Training als Hyperparameter festgelegt wird.

In den Originalarbeiten des FastFlow Modells verwenden die Autoren die Likelihood als Kennwert, während bei dem Ansatz von Rippel et al. die Mahalanobis-Distanz eingesetzt wird. Erste Experimente mit alternativen Kennwerten – insbesondere der Likelihood Ratio und der Typicality (vgl. AP 4.2) – zeigten keine signifikanten Unterschiede in der Performanz. Daher wurde bei beiden Modellen auf die jeweils in der Originalarbeit vorgeschlagenen Metriken zurückgegriffen.

Aufgrund der bereits in der Literatur verfügbaren leistungsfähigen Algorithmen wurde der Schwerpunkt von Arbeitspaket 4 gegenüber der ursprünglich vorgesehenen grundlegenden algorithmischen Neuentwicklung verlagert. Der Fokus lag stattdessen auf der gezielten Anpassung und Optimierung bestehender Verfahren im Hinblick auf das vorliegende Anwendungsproblem. Konkret umfassten die Arbeiten die Analyse und Auswahl geeigneter Schwellenwerte (Thresholds), die Evaluierung sinnvoller Fehlermaße, Verbesserungen in der Datenvorverarbeitung sowie Untersuchungen zur Robustheit und Nachvollziehbarkeit (Plausibilisierung) der Modelle. Die im Rahmen dieser Arbeiten gewonnenen Erkenntnisse werden in den folgenden Abschnitten detailliert beschrieben.

Fehlermaße und Performanz-Vergleich des FastFlow Modells und des Modells von Rippel et al.

Das in AP 4.3 angegebene Fehlermaß (AUROC) wurde für die Aufgabe nicht als ausreichendes Kriterium zur Bewertung der Performanz identifiziert. Zusätzlich wurden daher die Fehlermaße AUPRC (area under precision recall curve), Fβ-score und balanced accuracy betrachtet.

Die Modelle von Rippel et al. sowie das FastFlow-Modell wurden auf defektfreien Kabelbildern trainiert und anschließend hinsichtlich ihrer Fehlermaße evaluiert. Die Auswertung erfolgte auf Kabelbildern mit und ohne realen Defekten sowie auf künstlich erzeugten Defektbildern aus Arbeitspaket 3. Der Vergleich der Fehlermaße zwischen dem Modell von Rippel et al. und dem FastFlow-Modell zeigte, dass FastFlow durchgängig höhere Fehlerwerte erzielte und somit eine bessere Performanz bei der Defekterkennung aufweist (vgl. AP 4.3). Aus diesem Grund konzentrieren sich die nachfolgenden Untersuchungen überwiegend auf das FastFlow-Modell, wenngleich die entsprechenden Ansätze – soweit technisch möglich – auch auf das Modell von Rippel et al. übertragen und umgesetzt wurden (dies wird an geeigneten Stellen jeweils kurz vermerkt).

Wahl des Threshold

Die im vorherigen Abschnitt beschriebenen Fehlermaße werden herangezogen, um einen geeigneten Threshold für das jeweils trainierte Netzwerk bzw. Verfahren zu bestimmen. Wie bereits erläutert, fungiert der Threshold als Hyperparameter, der die Einstufung eines Eingabebildes als „defektfrei“ oder „defektbehaftet“ steuert.

Das diesem Bericht zugrundeliegende Vorhaben wurde mit Mitteln des Bundesministeriums für Forschung, Technologie und Raumfahrt gefördert. Die Verantwortung für den Inhalt der Veröffentlichung liegt beim Autor.

Grundsätzlich kann zwischen zwei Ansätzen zur Bestimmung des Thresholds unterschieden werden: einem klassifikationsbasierten und einem segmentierungsbasierten Ansatz. Beim klassifikationsbasierten Threshold erfolgt eine Bewertung des gesamten Eingabebildes, auf deren Grundlage entschieden wird, ob ein Defekt im Eingabebild vorliegt. Im Gegensatz hierzu ermöglicht der segmentierungsbasierte Threshold eine pixelweise Analyse, bei der jeder Bildpunkt individuell hinsichtlich seiner Anomalie-Wahrscheinlichkeit beurteilt und klassifiziert wird. Es ist dabei zu beachten, dass das Modell von Rippel et al. ausschließlich die Anwendung eines klassifikationsbasierten Thresholds unterstützt, da es keine Vorhersage einzelner Pixel generiert.

Der Vergleich der Fehlermaße in Abhängigkeit von der jeweiligen Threshold-Wahl zeigte, dass der segmentierungsbasierte Ansatz dazu neigt, eine übermäßige Anzahl von Pixeln als defektbehaftet zu klassifizieren. Im Worstcase führt dies dazu, dass vermehrt in defektfreien Bildern einzelne Pixel fälschlicherweise als Anomalien erkannt werden, was wiederum zur fehlerhaften Einstufung des gesamten Bildes als defektbehaftet führen kann. Dieses Problem lässt sich durch den Einsatz eines klassifikationsbasierten Thresholds weitgehend vermeiden. Unsere Untersuchungen haben gezeigt, dass dieser Ansatz im Mittel eine bessere Performanz aufweist. Daher ist der klassifikationsbasierte Threshold für das FastFlow Modell als die geeignetere Wahl zu bewerten.

Darüber hinaus wurden Untersuchungen durchgeführt, um die Wahl des Thresholds beim FastFlow Modell robuster zu gestalten. Ausgangspunkt dieser Arbeiten waren Artefakte, die bei den Vorhersagen des FastFlow Modells beobachtet wurden. Konkret zeigen die Vorhersagen ein charakteristisches, wolkenartiges Muster (vgl. mittlere Abbildung im FastFlow-Zweig in **Fehler! V erweisquelle konnte nicht gefunden werden.**), das die Anwendung des Thresholds negativ beeinflussen kann. Ziel war es daher, dieses Muster durch ein zusätzliches Preprocessing der Netzwerkvorhersagen vor der Anwendung des Thresholds zu reduzieren und so die Qualität der Klassifikation zu verbessern. Hierzu wurden verschiedene filterbasierte Verfahren sowie Methoden zur Normalisierung bzw. Standardisierung der FastFlow Ausgaben evaluiert. Unter den getesteten Ansätzen erzielten insbesondere eine Median Filterung**,** sowie eine Division bzw. Subtraktion des Medians der Vorhersagen die besten Ergebnisse. Diese führten zu einer geringfügigen Verbesserung der Fehlerwerte im Vergleich zur unveränderten Netzwerkausgabe. Allerdings ist in diesem Zusammenhang kritisch abzuwägen, ob der zusätzliche Rechenaufwand und die potenzielle Einführung weiterer Hyperparameter durch das Preprocessing im Verhältnis zu den (geringen) Leistungsgewinnen steht – insbesondere im Hinblick auf ein späteres Training und eine Anwendung beim Kunden, wo Einfachheit und Robustheit im Vordergrund stehen sollten. Aus diesem Grund beziehen sich alle nachfolgenden Fehleranalysen auf die originalen Netzwerkvorhersagen ohne zusätzliches Preprocessing.

Darüber hinaus wurde untersucht, ob die Vorhersagen des Netzwerks auf den einzelnen Feature Maps separat für die Threshold Bestimmung genutzt werden können. Hintergrund dieser Überlegung ist, dass die Verteilung jeder einzelnen Feature Map des Feature-Extraktors zunächst separat von dem Netzwerk gelernt wird. Für die in **Fehler! Verweisquelle konnte nicht gefunden werden.** dargestellten V orhersagen werden die Ausgaben des Netzwerks auf den einzelnen Feature Maps zunächst auf Bildgröße hochskaliert (Upsampling) und anschließend gemittelt. Dabei ist jedoch unklar, ob diese Mittelung zu einem Informationsverlust führt, der die optimale Wahl des Thresholds negativ beeinflussen könnte. Zudem ist ein Upsampling auf Bildebene für die Anwendung eines klassifikationsbasierten Thresholds grundsätzlich nicht erforderlich.

Vor diesem Hintergrund wurde untersucht, ob sich die Performanz der Vorhersagen des FastFlow Modells verbessern lässt, wenn die Feature Maps separat ausgewertet und ihre individuellen Vorhersagen erst im Anschluss zu einer Entscheidung auf Bildebene zusammengeführt werden. Abhängig von der gewählten Fusionsstrategie kann dieser Ansatz jedoch zusätzliche Hyperparameter erfordern, was insbesondere im Hinblick auf Robustheit und Einfachheit problematisch ist. Die

Das diesem Bericht zugrundeliegende Vorhaben wurde mit Mitteln des Bundesministeriums für Forschung, Technologie und Raumfahrt gefördert. Die Verantwortung für den Inhalt der Veröffentlichung liegt beim Autor.

Ergebnisse der Untersuchungen zeigten, dass die Performanz im Wesentlichen vergleichbar mit jener der Standardmethode (Upsampling und Mittelung) ist und somit keine signifikanten Vorteile erzielt werden. Insbesondere aufgrund der möglichen zusätzlichen Hyperparameter wurde daher auf eine separate Behandlung der Feature Maps verzichtet.

Datenvorverarbeitung

Die aufgenommenen Bilder können auf unterschiedliche Weise vorverarbeitet werden, bevor sie dem Algorithmus zur Klassifikation bzw. Segmentierung übergeben werden. Beispielsweise ist es vorteilhaft die Kabelprodukte aus den aufgenommenen Bildern auszuschneiden, um potenzielle Störeinflüsse durch den Bildhintergrund zu minimieren.

Dieser Vorverarbeitungsschritt wurde seitens Sikora implementiert. Infolgedessen war eine Anpassung der Auswertungs-Pipeline der beiden Netzwerke erforderlich, da diese eine feste Eingabegröße erwarten, die durch das Zuschneiden der Bilder nicht mehr gewährleistet war.

Zu diesem Zweck wurden drei verschiedene Vorverarbeitungsstrategien getestet und miteinander verglichen:

1. Resizing der Bilder auf eine einheitliche Zielgröße,
2. Padding der Bildränder mit Nullen zur Erzeugung gleich großer Eingabebilder,
3. die Verwendung eines Patch-basierten Ansatzes**.**

Beim Patch-basierten Verfahren wird das zuvor ausgeschnittene Kabelbild in mehrere kleinere Bildausschnitte (sogenannte *Patches*) mit fester Größe unterteilt. Diese Patches dienen anschließend als Eingabe für das Netzwerk. Die Fehlermaße – exemplarisch dargestellt anhand von AUROC und Balanced Accuracy für das FastFlow-Modell – sind in Tabelle 1 aufgeführt.

Tabelle 1 Fehlerwerte des FastFlow basierend auf den folgenden Input Daten: volle Aufnahmen mit Hintergrund, resized Aufnahmen, zero-padded Aufnahmen und Patches. Die Fehlerwerte basieren auf einer Zwischenversion des Algorithmus.

	AUROC	**Balanced Accuracy**
Aufnahme (mit Hintergrund)	0.835	0.847
Resizing	0.906	0.879
Zero-Padding	0.918	0.881
Patches	0.943	0.915

Aus der Tabelle geht hervor, dass der Patch-basierte Vorverarbeitungsansatz die besten Fehlerwerte erzielt. Diese Beobachtung ließ sich auch beim Modell von Rippel et al. bestätigen. Auf Grundlage dieser Ergebnisse wurden alle weiteren Untersuchungen unter Verwendung des Patch-basierten Ansatzes durchgeführt.

Im Rahmen der Untersuchungen zur Vorverarbeitung wurde neben der Entfernung des Bildhintergrundes auch der Einfluss von Krümmungen an den Rändern der Produkte auf die Performanz der Algorithmen analysiert. Hierfür wurde ein zuvor definierter Bereich der Randpixel entfernt und bei der Vorhersage nicht berücksichtigt. Dieser Ansatz ist jedoch nur dann umsetzbar, wenn die Kameras sich überlappende Bildbereiche erfassen, da andernfalls Teile des Kabels nicht klassifiziert werden können. Die Untersuchungen haben gezeigt, dass Krümmungen an den Rändern

Das diesem Bericht zugrundeliegende Vorhaben wurde mit Mitteln des Bundesministeriums für Forschung, Technologie und Raumfahrt gefördert. Die Verantwortung für den Inhalt der Veröffentlichung liegt beim Autor.

die Performanz beider Algorithmen negativ beeinflussen und daher, sofern möglich, nicht für die Vorhersage verwendet werden sollten.

Robustheit und Plausibilisierung

Die Robustheit der Verfahren wurde als besonders entscheidend eingestuft, da der finale Algorithmus beim Kunden auf bislang unbekannten Daten trainiert und eingesetzt werden soll (vgl. AP 4.4). Um eine zuverlässige und konsistente Defekterkennung zu gewährleisten, ist daher ein hohes Maß an Robustheit erforderlich.

Neben der gezielten Analyse fehlklassifizierter Bilder (vgl. AP 4.4) wurde die Robustheit der Verfahren in diesem Projekt auf unterschiedlichen Ebenen untersucht: Sowohl aus einer theoretisch-forschungsbasierten Perspektive als auch aus einer anwendungsorientierten Sichtweise.

Die theoretische Perspektive stützt sich auf die Ergebnisse unserer eigenen Forschungsarbeit [E1], in der sogenannte invertible residual networks (iResNets) untersucht wurden. Der Fokus dieser Arbeit lag insbesondere auf den Eigenschaften Stabilität und Invertierbarkeit solcher Architekturen. Die Ergebnisse zeigten unter anderem, dass iResNets eine erhöhte Robustheit gegenüber sogenannten *Adversarial Examples* (siehe unten) aufweisen und dass ihre inhärente Invertierbarkeit die Interpretierbarkeit der gelernten Modelle deutlich verbessert. iResNets lassen sich beispielsweise in *Normalizing Flow*-Architekturen einsetzen - wie sie auch im FastFlow-Modell verwendet werden - die auf einem invertierbaren Netzwerkdesign basieren. Da jedoch das FastFlow-Modell zusätzliche Komponenten wie den Feature-Extraktor enthält, ist unklar, inwieweit die Ergebnisse aus [E1] direkt auf diese konkreten Modelle übertragbar sind und ob sie unter praxisnahen Bedingungen zu robusteren oder interpretierbareren Ergebnissen führen. Im Rahmen dieses Projekts wurde daher untersucht, ob und in welchem Ausmaß sich die Erkenntnisse aus [E1] - insbesondere in Bezug auf Adversarial Examples und Invertierbarkeit - auf die im Projekt verwendeten Modelle anwenden lassen.

Das Konzept der Adversarial Examples basiert auf gezielten, minimalen Änderungen am Eingabebild – in diesem Fall den Kabelaufnahmen – mit dem Ziel, die Vorhersage des Modells in Richtung einer Fehlklassifikation zu beeinflussen. Unsere Untersuchungen mit dem FastFlow Modell sowie dem Modell von Rippel et al. zeigten, dass deutlich sichtbare Veränderungen im Bild notwendig sind um die Vorhersage signifikant zu beeinflussen. Diese Beobachtung ist positiv zu bewerten**,** da sie auf eine hohe Robustheit der Modelle gegenüber kleineren Bildveränderungen und potenziellen Aufnahmefehlern hinweist – ein entscheidender Aspekt für den Einsatz unter realen Bedingungen.

Gleichzeitig stellt sich die Frage nach der praktischen Relevanz klassischer Adversarial Examples, da diese künstlich erzeugten Störmuster in der Regel nicht natürlich auftreten. Deutlich aufschlussreicher wäre es, realistische Bildveränderungen zu identifizieren, die zu Fehlklassifikationen führen. Solche Beispiele könnten wertvolle Hinweise auf spezifische Fehlerarten liefern, die vom Modell (noch) nicht zuverlässig erkannt werden – insbesondere, wenn sie im Trainings- oder Testdatensatz nicht repräsentiert sind und somit unbemerkt bleiben.

Im Rahmen des Projekts wurde daher untersucht, ob die Generierung von Adversarial Examples dahingehend erweitert werden kann, dass realitätsnähere Störungen erzeugt werden. Obwohl erste Ansätze in diese Richtung vielversprechend waren, erwies sich die Umsetzung als nicht trivial, und die bislang getesteten Methoden führten weiterhin zu visuell unrealistischen Modifikationen. Die Weiterentwicklung solcher Methoden stellt jedoch eine interessante Perspektive für zukünftige Arbeiten dar, insbesondere im Hinblick auf die Absicherung von Modellen gegenüber bisher unberücksichtigten Fehlerarten.

Des Weiteren wurde untersucht, inwieweit die Invertierbarkeit des Normalizing Flows im FastFlow Modell zur Plausibilisierung der Vorhersagen beitragen kann. Die Invertierbarkeit ermöglicht es von den Modellvorhersagen eindeutig auf die Eingabedaten zurückzuschließen, was einen wichtigen Schritt hin zu mehr Nachvollziehbarkeit und Transparenz darstellt. Im FastFlow Modell beschränkt sich

Das diesem Bericht zugrundeliegende Vorhaben wurde mit Mitteln des Bundesministeriums für Forschung, Technologie und Raumfahrt gefördert. Die Verantwortung für den Inhalt der Veröffentlichung liegt beim Autor.

die Invertierbarkeit allerdings auf die Feature-Ebene, welche für Anwender nur eingeschränkt interpretierbar ist. Vor diesem Hintergrund wurde geprüft, ob der Feature Extraktor zusätzlich invertierbar gestaltet oder durch ein zusätzliches Netzwerk ergänzt werden kann, das eine Plausibilisierung der Feature ermöglicht. Diese Untersuchungen wurden sowohl für das FastFlow Modell als auch für den Ansatz von Rippel et al. durchgeführt.

Ähnlich wie bei den Untersuchungen zu Adversarial Examples haben unsere Ergebnisse gezeigt, dass der unmittelbare Mehrwert für Anwender derzeit noch unklar ist - insbesondere aufgrund der Unsicherheiten, die durch das zusätzliche Netzwerk entstehen und die im Live-Betrieb beim Kunden nicht unmittelbar überprüfbar sind.

Zusammenfassend haben die theoretisch motivierten Untersuchungen gezeigt, dass die Modelle auf theoretischer Ebene wünschenswerte Eigenschaften besitzen und eine erhöhte Robustheit gegenüber beispielsweise Adversarial Examples aufweisen. Die konkreten praktischen Vorteile aus Anwendersicht sind jedoch bislang noch nicht abschließend geklärt.

Ergänzend zu den theoretisch motivierten Untersuchungen wurden auch praxisorientierte Analysen durchgeführt, mit dem Ziel, die Interpretierbarkeit der Modellvorhersagen zu verbessern und die Robustheit im Anwendungskontext beim Kunden zu erhöhen. Im Fokus stand hierbei die Frage, ob ein Zusammenhang zwischen dem Maximum der Vorhersage des FastFlow Modells (vor der Anwendung des Thresholds) und der tatsächlichen Stärke eines Defekts besteht. Ein solcher Zusammenhang würde eine gezielte Steuerung des Thresholds für erkannte Defekte ermöglichen – etwa durch die Vorgabe eines gewünschten Grenzwerts für die zulässige Defektstärke seitens des Kunden (vgl. AP 5). Zur Überprüfung dieses Zusammenhangs wurde das Maximum der Vorhersage des FastFlows den Defektstärken synthetisch erzeugter Defektbilder aus Arbeitspaket 3 gegenübergestellt (siehe Abbildung 2). Die Defektstärke selbst stellt hierbei einen steuerbaren Parameter im zugrunde liegenden generativen Netzwerk aus AP 3 dar.

Die Abbildung zeigt, dass derzeit kein eindeutiger Zusammenhang zwischen dem Maximum der Modellvorhersage und der tatsächlichen Defektstärke besteht. Dies war allerdings zu erwarten, da das Modell ausschließlich mit Defekt-freien Bildern trainiert wurde. Auf Basis dieser Beobachtung wurde als potenzieller Verbesserungsansatz identifiziert, den Trainings-Loss des Netzwerks gezielt zu erweitern. Insbesondere wird vorgeschlagen, ein ergänzendes Training oder Fine-tuning zu integrieren, das ein stärkeres Alignment zwischen Vorhersagemaximum und Defektstärke fördert. Ein möglicher Ansatz wäre dabei die Einführung eines zusätzlichen L^2-Penalty-Terms auf die Differenz zwischen dem Vorhersagemaximum und der bekannten Defektstärke. Dies könnte die Sensitivität des Modells gegenüber unterschiedlichen Defektstärken erhöhen und eine trennscharfe Unterscheidung zwischen den einzelnen Defektstufen ermöglichen.

Das diesem Bericht zugrundeliegende Vorhaben wurde mit Mitteln des Bundesministeriums für Forschung, Technologie und Raumfahrt gefördert. Die Verantwortung für den Inhalt der Veröffentlichung liegt beim Autor.

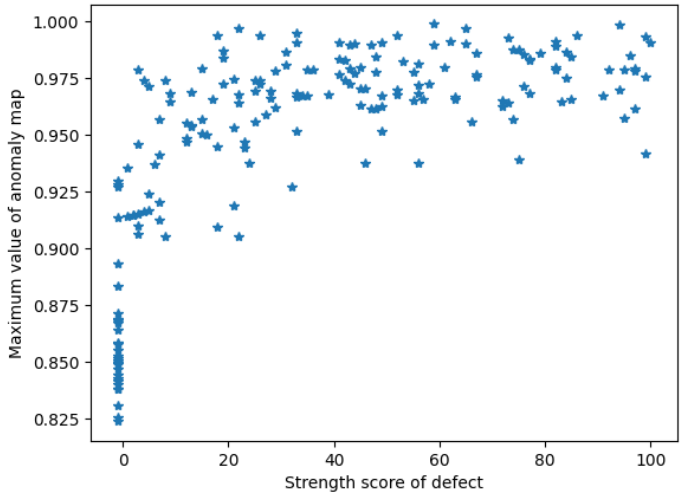

Abbildung 2 Darstellung des Zusammenhangs zwischen dem Maximum der Vorhersage (als Anomaly Map bezeichnet) und der Stärke des Defektes. Defektfreie Bilder sind mit -1 kodiert.

Architektur-Optimierung und Vergleich mit Standardverfahren von Sikora

Die Modelle wurden auf Basis von Kabelbildaufnahmen – sowohl mit als auch ohne realen Defekten sowie mit künstlich erzeugten Defekten aus AP 3 – angepasst und optimiert (siehe AP 4.9). Dies umfasste einerseits die Optimierung der Modellarchitektur, insbesondere des im FastFlow verwendeten Normalizing Flow, sowie andererseits eine systematische Untersuchung geeigneter Feature-Extraktoren für sowohl das FastFlow-Modell als auch den Ansatz von Rippel et al.

Im Rahmen dieser Analyse wurde die Performanz unter Verwendung verschiedener Feature-Extraktoren verglichen, darunter *Wide_ResNet50_2*, *EfficientNetB4* und *EfficientNetB5*. Die Ergebnisse zeigten, dass *EfficientNetB5* die höchste Performanz bei der Defekterkennung auf den Kabelbildern erzielte.

Die final ausgewählten Architekturen wurden im Rahmen von AP 4.8 mit etablierten Verfahren aus der Literatur verglichen. Grundlage hierfür bildete die öffentlich verfügbare Bibliothek *Anomalib* [1], die eine Vielzahl bewährter Standardverfahren zur Anomalieerkennung beinhaltet. Diese wurde von Sikora in das dort bestehende Framework integriert.

Um eine einheitliche Vergleichsbasis zu schaffen, wurden sowohl das FastFlow Modell als auch der Ansatz von Rippel et al. entsprechend angepasst und in das Framework bei Sikora eingebunden. Hierbei hat sich gezeigt, dass das FastFlow Modell eine überzeugende Detektionsgenauigkeit liefert bei gleichzeitig schneller Auswertungs-Geschwindigkeit.

AP 5 Konzeption und Aufbau eines Frameworks zur kundenseitigen Adaption: Training und Optimierung des Gesamtverfahrens

Die entwickelten Verfahren sollen im finalen Anwendungskontext beim Kunden auf zuvor unbekannten Daten trainiert werden, um eine zuverlässige Erkennung von Fehlern und Anomalien sicherzustellen. Im ursprünglichen Projektantrag war vorgesehen, zunächst bei Sikora vortrainierte neuronale Netze einzusetzen und diese anschließend mittels Transfer Learning an die spezifischen Daten des jeweiligen Kunden anzupassen. Ein Training auf Basis uninitialisierter, nicht vortrainierter Netze war in diesem Zusammenhang nicht vorgesehen (vgl. AP 5.2).

Die Umsetzung dieses Ansatzes erfordert das Vorhandensein eines ausreichend umfangreichen und diversifizierten Datensatzes bei Sikora. Aufgrund der hohen Produktvariabilität in den Kundenanwendungen sowie der begrenzten Verfügbarkeit repräsentativer Kabelprodukte im Bestand bei Sikora konnte ein solcher Datensatz jedoch nicht bereitgestellt werden. Daher wurde entschieden,

Das diesem Bericht zugrundeliegende Vorhaben wurde mit Mitteln des Bundesministeriums für Forschung, Technologie und Raumfahrt gefördert. Die Verantwortung für den Inhalt der Veröffentlichung liegt beim Autor.

das Training der neuronalen Netze direkt beim Kunden auf Basis uninitialisierter Modelle durchzuführen, um eine optimale und unbeeinflusste Anpassung an die spezifischen Produktcharakteristika zu ermöglichen.

Die resultierende Vorgehensweise beim Kunden lässt sich wie folgt darstellen (vgl. AP 5.1 und AP 5.2):

1. Erfassung defektfreier Daten in der Produktionslinie des Kunden.
2. Training der Neuronalen Netze (initial untrainiert) auf den erfassten Daten.
3. Festlegung eines Anomalie-Thresholds**,** wofür zwei Ansätze vorgesehen sind:

   A. Verwendung eines vordefinierten Thresholds**:** Hierbei wird ein zuvor bestimmter Schwellenwert genutzt (z. B. die in AP 4 ermittelten Thresholds). Dieser Ansatz erfordert kein Feedback des Kunden und bildet die grundlegende Funktionsweise des Systems ab.

   B. Kundenbasiertes Threshold-Tuning: Der Kunde bewertet anhand von Referenzbildern mit Defekten, welche Defektarten und -intensitäten als relevant zu detektieren sind. Basierend auf dieser Rückmeldung wird der Threshold wie in AP 4 beschrieben angepasst.

Beim kundenbasierten Threshold-Tuning (Schritt 3.B) werden defektbehaftete Referenzbilder benötigt. Diese werden mithilfe des in AP 3 entwickelten Diffusionsmodells synthetisch erzeugt. Das Modell generiert auf Basis der beim Kunden aufgenommenen defektfreien Aufnahmen künstliche Defektbilder mit variabler Defektstärke. Anhand dieser Referenzbilder kann der Kunde festlegen, welche Defektarten und -intensitäten toleriert werden und welche als relevante Defekte zu klassifizieren sind.

Dieser Ansatz setzt eine eindeutige Korrelation zwischen dem Maximum der Modellvorhersagen und der tatsächlichen Defektstärke voraus (vgl. die Untersuchung in AP 4). Nur so kann gewährleistet werden, dass Defekte mittels eines geeigneten Thresholds zuverlässig und trennscharf detektiert werden. Sollte diese Korrelation nicht ausreichend stark ausgeprägt sein, ist gegebenenfalls ein gezieltes Nachtraining der Netze erforderlich, um die Modellvorhersagen an die Defektstärken anzupassen, wie bereits in AP 4 vorgeschlagen.

Darüber hinaus kann nicht vollständig ausgeschlossen werden, dass die in Schritt 1 erfassten Aufnahmen bereits Defekte enthalten. Daher wurde untersucht, ob diese potenziell defektbehafteten Bilder auch nach ihrer Verwendung im Training detektiert und somit zur Bereinigung des Datensatzes herangezogen werden können. Zu diesem Zweck wurden die Ansätze von Rippel et al. sowie das FastFlow Modell auf einem realen Datensatz trainiert, der während eines Kundenbesuchs von Sikora bei einem Kabelhersteller aufgenommen wurde. Anschließend wurden die Aufnahmen anhand der Maxima der Modellvorhersagen sortiert und visuell analysiert. Die Ergebnisse zeigen, dass Bilder mit den höchsten Vorhersage-Maxima kleinere Fehler oder Anomalien aufweisen, während Aufnahmen mit niedrigen Vorhersage-Maxima keine erkennbaren Defekte enthalten.

Diese Beobachtung ermöglicht es, den beim Kunden erfassten Datensatz vor dem Training zu bereinigen. Hierfür eignet sich insbesondere der Ansatz von Rippel et al., da er eine kurze Trainingszeit aufweist. Nach Abschluss des Trainings können die Aufnahmen mit den höchsten Vorhersage-Maxima identifiziert werden. Diese Bilder können entweder direkt aus dem Datensatz entfernt oder dem Kunden im Rahmen von Schritt 3.B zur Sichtung vorgelegt werden. Der Kunde entscheidet anschließend, ob es sich tatsächlich um Defekte handelt, woraufhin der Datensatz entsprechend angepasst werden kann.

Die beschriebenen Erweiterungen und Anpassungen sollen im späteren Projektverlauf (nach Abschluss der Förderprojektes) in das Verfahren integriert werden. Zunächst wurde der grundlegende Ansatz umgesetzt und optimiert, der auf der Annahme vollständig defektfreier Aufnahmen basiert und ein Training ohne Kundenfeedback unter Verwendung eines vordefinierten Thresholds vorsieht. Dieses Vorgehen entspricht dem in AP 4 untersuchten Szenario.

Das diesem Bericht zugrundeliegende Vorhaben wurde mit Mitteln des Bundesministeriums für Forschung, Technologie und Raumfahrt gefördert. Die Verantwortung für den Inhalt der Veröffentlichung liegt beim Autor.

Diese schrittweise Vorgehensweise dient der gezielten Reduktion von Komplexität in den frühen Projektphasen und ermöglicht eine fokussierte Evaluation der Basismethodik, bevor zusätzliche Komponenten wie kundenspezifisches Threshold-Tuning oder Datensatzbereinigung integriert werden. Eine Auswertung der der im Rahmen der Basismethodik trainierten Modelle hat gezeigt, dass diese Defekte zuverlässig detektieren und effizient an die spezifischen Produkte des Kunden angepasst werden können.

AP 6 Evaluation und Umsetzung des Labor-Demonstrators

Der Vergleich des in AP 1 spezifizierten Anforderungsprofils sowie der konzipierten Verfahrens-Pipeline mit den in AP 4 und AP 5 erzielten Entwicklungen und Erkenntnissen zeigt, dass der Einsatz eines einzelnen Algorithmus nicht ausreicht, um robuste und verlässliche Ergebnisse zu erzielen. Stattdessen sollte zur Erhöhung von Stabilität, Robustheit und Generalisierbarkeit eine Kombination mehrerer Algorithmen genutzt werden. Durch diesen Ansatz können Ausreißer und potenzielle Fehlklassifikationen einzelner Algorithmen identifiziert und deren Einfluss reduziert werden, wodurch die Gesamtvorhersage signifikant stabilisiert und verbessert wird.

Zudem wurde deutlich, dass eine Anpassung eines vortrainierten Netzwerks an die beim Kunden erfassten Daten aufgrund der begrenzten Datenverfügbarkeit derzeit nicht umsetzbar ist. Stattdessen sollte das Modell beim Kunden vollständig neu trainiert werden.

Gleichzeitig konnte jedoch nachgewiesen werden, dass das eingangs definierte Anforderungsprofil grundsätzlich erfüllt werden kann. Insbesondere ist ein erfolgreiches Training der Modelle innerhalb annehmbarer Zeit möglich, und die geforderte minimale Berechnungsfrequenz wird von den meisten der untersuchten Algorithmen deutlich überschritten. Darüber hinaus sind die erzielten Fehlerwerte als vielversprechend zu bewerten.

Insgesamt wird das Potenzial der entwickelten Verfahren zur erfolgreichen OOD-Detektion als hoch eingeschätzt, sodass eine Fortführung und weiterführende Optimierung der Ansätze als sehr erfolgversprechend angesehen wird.

Als entscheidend für die weitere Entwicklung wird die Erfassung zusätzlicher Datensätze bei Kunden unter realen Produktionsbedingungen angesehen. Dies ist erforderlich, um die entwickelten Verfahren unter praxisnahen, bislang unbekannten Einsatzbedingungen zu validieren und potenzielle Schwachstellen zu identifizieren, die in der bisherigen Entwicklungs- und Testumgebung nicht erkennbar waren.

Öffentlichkeitsarbeit:

Im Rahmen des MOIN-Projekts wurde ein Imagefilm erstellt, der die Ziele und Inhalte des Projekts anschaulich vermittelt. Darüber hinaus fanden im Jahr 2024 mehrere Treffen aller MOIN Projekt statt, bei denen der aktuelle Entwicklungsstand des Projekts präsentiert wurde.

Angaben zu Positionen des zahlenmäßigen Nachweises

Die Personalkosten im Projekt beliefen sich auf 142.436,76 € (20,5 PM). Die beantragten und bewilligten Personalkosten in Höhe von 166.837,17 € (26,27 PM) konnten nicht vollständig ausgeschöpft werden. Dies ist auf den personellen Wegfall von Alexander Denker zurückzuführen. Weitere Mittel wurden nicht beantragt.

Angaben zur Notwendigkeit und Angemessenheit der geleisteten Projektarbeiten

Optical Analyzer war grundsätzlich als ein schneller Transferansatz geplant, um neue mathematische Algorithmen aus dem Bereich der künstlichen Intelligenz innerhalb einer kurzen Zeitspanne in die industrielle Anwendung zu bringen. Dieser Ansatz erfordert eine andere Herangehensweise, um die

Das diesem Bericht zugrundeliegende Vorhaben wurde mit Mitteln des Bundesministeriums für Forschung, Technologie und Raumfahrt gefördert. Die Verantwortung für den Inhalt der Veröffentlichung liegt beim Autor.

hohe Transfergeschwindigkeit zu erzielen. Dementsprechend wurde hier eine Aufgabenstellung betrachtet, bei der das Potential für eine Umsetzung der oben genannten Ziele erkennbar war. Ein weiterer wichtiger Bestandteil ist die Wahl eines geeigneten Industriepartners, der insbesondere schon über Erfahrungen im Transfer in diesem Bereich verfügen sollte. Im Projekt Optical Analyzer ist es gelungen, ein ausgezeichnetes Team für diese übergeordnete Zielstellung im Rahmen einer angemessenen Aufgabenstellung zusammenzuführen. Aufgrund des engen Zeitrahmens, haben sich die Arbeiten auf die Weiterentwicklung und für die gegebene Aufgabenstellung Nutzbarmachung von bekannten Ansätzen konzentriert, was in diesem Fall sehr gut gelungen ist.

Angaben zum voraussichtlichen Nutzen

Die im Rahmen des Projektes gewonnenen Erkenntnisse, insbesondere aus AP 4, zeigen welche Algorithmen besonders zur Detektion von Anomalien bzw. Fehlern geeignet sind und welche potenziellen Fehlerquellen auftreten können. Dieses Wissen kann in zukünftigen Projekten mit ähnlichen Fragestellungen genutzt werden und so die Entwicklung deutlich beschleunigen und vereinfachen. Da die Anomaliedetektion in zahlreichen Anwendungen von Interesse ist, sind die Ergebnisse des Projektes nicht auf Kabelprodukte beschränkt, sondern besitzen ein potenziell breites Einsatzspektrum.

Angaben zum Fortschritt auf dem Gebiet des Vorhabens bei anderen Stellen

Den Projektbeteiligten sind keine Publikationen oder neuen Erkenntnisse bekannt geworden, die eine grundlegende Anpassung der Projektziele oder -methoden erforderlich gemacht hätten. Es sei jedoch betont, dass es sich bei der Anomalieerkennung um ein sehr dynamisches und aktives Forschungsfeld handelt, in dem kontinuierlich neue Arbeiten veröffentlicht werden - siehe exemplarisch die Überblicksartikel [2, 4].

Besonders hervorzuheben ist das Open-Source-Repository *Anomalib* [1], das eine Vielzahl leistungsstarker Anomalieerkennungsverfahren implementiert. Sikora nutzte *Anomalib* gezielt für initiale Vergleichsstudien zwischen verschiedenen Verfahren.

Im Allgemeinen ist hervorzuheben, dass viele aktuelle Anomalieerkennungsverfahren in industriellen Anwendungskontexten bereits eine sehr hohe Leistungsfähigkeit aufweisen. Dies ermöglichte es dem Projekt, auf etablierten Methoden aufzubauen und gezielte Anpassungen sowie Weiterentwicklungen vorzunehmen. Insbesondere führte dies zu einer leichten Neuausrichtung von Arbeitspaket 4 (siehe oben).

Im Berichtzeitraum fertiggestellte Abschlussarbeiten und Veröffentlichungen

[E1] C. Arndt and J. Nickel, „Invertible ResNets for Inverse Imaging Problems: Competitive Performance with Provable Regularization Properties". Zur Veröffentlichung akzeptiert in SIAM Journal on Imaging Science. Preprint ArXiv:2409.13482 (2025).

[E2] T. Sauerland, „Synthetic Sample Generation and Anomaly Detection for Surface Defects". Masterthesis (2025).

Literaturverzeichnis

[1] Anomalib: https://github.com/open-edge-platform/anomalib?tab=readme-ov-file

[2] Liu, J., Xie, G., Wang, J. *et al.*, „Deep Industrial Image Anomaly Detection: A Survey", in *Mach. Intell. Res.* vol. 21, pp. 104–135 (2024). doi: 10.1007/s11633-023-1459-z.

Das diesem Bericht zugrundeliegende Vorhaben wurde mit Mitteln des Bundesministeriums für Forschung, Technologie und Raumfahrt gefördert. Die Verantwortung für den Inhalt der Veröffentlichung liegt beim Autor.

[3] O. Rippel, P. Mertens and D. Merhof, „Modeling the Distribution of Normal Data in Pre-Trained Deep Features for Anomaly Detection“, in 2020 25th International Conference on Pattern Recognition (ICPR), Milan, Italy, 2021, pp. 6726-6733, doi: 10.1109/ICPR48806.2021.9412109.

[4] G. Xie *et al*., „IM-IAD: Industrial Image Anomaly Detection Benchmark in Manufacturing“, in *IEEE Transactions on Cybernetics*, vol. 54, no. 5, pp. 2720-2733 (2024), doi: 10.1109/TCYB.2024.3357213.

[5] J. Yu et al., „FastFlow: Unsupervised Anomaly Detection and Localization via 2D Normalizing Flows.”. ArXiv abs/2111.07677 (2021).

Das diesem Bericht zugrundeliegende Vorhaben wurde mit Mitteln des Bundesministeriums für Forschung, Technologie und Raumfahrt gefördert. Die Verantwortung für den Inhalt der Veröffentlichung liegt beim Autor.