

Kurzbericht des BMBF-geförderten Verbundprojektes

Analysesystem zum qualitätsmotivierten Inline-Monitoring für Schweißprozesse auf Basis von Methoden künstlicher Intelligenz

AI System for Incline Monitoring of Welding processes



Autoren: Robert Maack, Yannik Hahn, Hasan Tercan, Tobias Meisen, Guido Buchholz,
Matthias Angerhausen, Marion Purrio, Thorsten Twiehaus

Projektlaufzeit: 01.05.2022 - 30.04.2024

Konsortialführung: FEF GmbH

Verbundpartner: Bergische Universität Wuppertal

Förderkennzeichen: 01IS22022A und 01IS22022B

im Förderschwerpunkt KI4KMU.

Das diesem Bericht zugrunde liegende Vorhaben wurde mit Mitteln des Bundesministeriums für Bildung und Forschung unter den Förderkennzeichen 01IS22022A und 01IS22022B gefördert. Die Verantwortung für den Inhalt dieser Veröffentlichung liegt bei der Autorin/beim Autor.

Teil I: Kurzbericht

I.1 Aufgabenstellung

Das zentrale Ziel des Projektes war die Entwicklung von Deep Learning-Verfahren zur Qualitätsvorhersage in Schweißprozessen sowie die Erforschung und Entwicklung von Continual Learning Verfahren, um die trainierten Modelle über Prozessvarianten hinweg effizient nutzen zu können.

Die Modelle nehmen auf Basis von Daten aus dem Schweißprozess eine Prädiktion der zu erwartenden Schweißnahtqualität noch während der Schweißung vor. Um nicht nur auf der trainierten Schweißung angewendet werden zu können, werden Continual Learning Verfahren entwickelt, die dem Anwender ermöglichen, bereits trainierte Modelle zu nutzen und fortlaufend auf wenigen Prozessdaten weiter zu trainieren.

Zur erfolgreichen und effektiven Zielerreichung wurde das Projekt in fünf Arbeitspakete (AP) unterteilt, die im Folgenden erläutert werden.

I.2 Planung sowie Ablauf des Vorhabens

Zu Beginn des Projektes wurde eine **Anforderungsgenerierung (AP1)** durchgeführt, in welcher die zu entwickelnden Methoden (IKT, Datenverarbeitung, KI-basierte Qualitätsvorhersage, Continual Learning) evaluiert wurden. Weiterhin wurde die technische Infrastruktur und Schnittstellen zur Messtechnik definiert. Abschließend wurden KI-Verfahren recherchiert, die auf Grundlage der aufgestellten Anforderungen und Beschaffenheit der Daten eine Qualitätsvorhersage realisierbar machen.

Es folgte die **Umsetzung der Infrastruktur und das KI-Modelltraining (AP2)**. Hier wurde die Implementierung der zuvor definierten Infrastruktur und das anschließende KI-Modelltraining durchgeführt. FEF-seitig wurden Prozess- und Qualitätsdaten erhoben. Das TMDT implementierte erste Verfahren des Deep Learnings zur klassifizierenden Vorhersage von Schweißdefekten. Als Bewertungskriterien dienten die Vorhersagegüte sowie die Robustheit der Modellvorhersagen unter verschiedenen Schweißparameterkombinationen.

Anschließend wurden Methoden zur **Online-Auswertung und zum Continual Learning entwickelt (AP3)**. Dazu wurde getestet, ob die in AP2 trainierten KI-Modelle die Qualität ihrer Vorhersage bei sich ändernden Prozessbedingungen mit minimalmöglichem Daten- und Trainingsaufwand aufrecht erhalten können. Dazu wurden Produktionsanlagen mit Messtechnik ausgestattet und aus den so erhobenen Daten Qualitätsmerkmale auf Basis von Prozesskennwerten extrahiert. Die Bewertung erfolgt sowohl anhand der Skalierbarkeit und Dateneffizienz der Modelle als auch ihre *Vergesslichkeit* hinsichtlich älterer, bzw. vorheriger Lernaufgaben.

Die **Integration des Demonstrators (AP4)** markierte einen wichtigen Projektabschnitt, da hier die Überführung der Minimalmesstechnik und der modelltechnischen Einzellösungen in einen gemeinsamen Demonstrator realisiert wurde. Hierzu wurden zunächst die Einzellösungen von der Datenerhebung bis zur KI-Vorhersage zusammengestellt und erprobt. Im Anschluss erfolgte die Erweiterung des Gesamtsystems um eine Komponente zur automatisierten Modellbewertung hinsichtlich neuer Prozessvariationen und die Evaluierung dieses Gesamtsystems.

Zum Projektabschluss wurden **Tests und Optimierungen (AP5)** durchgeführt. Die Testphasen erfolgten im Produktivbetrieb der FEF. Verschiedene definierte schweißtechnische Versuchs- und Testszenarien wurden durchgeführt und die Ergebnisse der Schweißungen evaluiert. Die Qualitätsvorhersage sowie die Continual Learning Verfahren konnten dann hinsichtlich Vorhersagegenauigkeit, Dateneffizienz und Robustheit gegenüber dynamischen Prozessveränderungen im Produktivbetrieb geprüft, validiert und punktuell verbessert werden.

I.3 Projektergebnisse und Zusammenarbeit

Als relevante Prozessgrößen wurden der Schweißstrom und die Schweißspannung des Prozesses identifiziert. Diese wurden final mittels Messkarten mit 50 kHz pro Kanal aufgenommen. Die Datenübertragung zur Weiterverarbeitung erfolgte über ein eigens zu diesem Zweck entwickeltes Python-Skript. Als Schweißprozesse wurden Variationen von Impulslichtbogenprozessen genutzt. Zur Datenvorverarbeitung wurden nach einer Prozessanalyse die Prozessgrößen in verschiedene physikalisch begründete Phasen aufgeteilt.

Die Architektur des entwickelten KI-Modells ist in zwei Stufen aufgeteilt. Die erste Stufe beinhaltet das Erlernen einer diskreten Darstellung aus den einzelnen Schweißzyklen durch einen Vector Quantized Variational Autoencoder (VQ-VAE). In der zweiten Stufe konzentrieren wir uns auf das Training eines Transformer-Modells auf den aus dem VQ-VAE erhaltenen diskreten Darstellungssequenzen. Diese Stufe kombiniert sowohl eine Sequenzvorhersageaufgabe als auch eine Klassifizierungsaufgabe, um die prädiktive Genauigkeit und Generalisierbarkeit des Modells zu verbessern.

Um den Ansatz des Continual Learning zu evaluieren, wurden Versuche mit verschiedenen Variationen durchgeführt. Unter anderem wurde die Schweißstromquelle getauscht, die Stoßart und Blechdicke der Halbzeuge geändert und die Brennerausrichtung und Stromquellenparameter verändert. Um zu erkennen, wann Continual Learning notwendig ist wurde eine Out-of-Distribution (OOD)-Erkennung verwendet. Daraufhin wurde die Rehearsal-Methode des kontinuierlichen Lernens evaluiert, indem OOD-Schweißvorgänge für ein Training mit historischen Schweißdaten zu einem neuen Datensatz kombiniert wurden.

Die Datenerhebung, Vorverarbeitung sowie die zweistufige Modellierung wurden anschließend kombiniert und um ein Dashboard zur Anzeige der Prädiktionsergebnisse ergänzt. Das System wurde dann in der Serienfertigung getestet. Auf einem Testdatensatz erreichte der VQ-VAE-Transformer eine Genauigkeit von 0,793 und einen F1-Score von 0,822. Diese Ergebnisse belegen die hohe Qualität und Zuverlässigkeit des Modells bei der Klassifizierung und Vorhersage von Schweißergebnissen.

Diese Erfolge wären ohne die Förderung durch das BMBF nicht möglich gewesen, da der Entwicklungsaufwand andernfalls zu hoch gewesen wäre. Zudem wurde dank der engen und sehr guten Kooperation von FEF und TMDT eine zukunftssträchtige Grundlage für weitere Projekte geschaffen, aus welcher die Gründung eines neuen Unternehmens, der FusionIQ Systems GmbH hervorging.

Für die FEF bedeutete der Aufbau der KI-Kompetenz außerdem bereits jetzt eine Erweiterung ihres eigenen Produktportfolios durch weitere Datenanalysemethoden auf KI-Basis für schweißtechnische Prozessdaten.

Analysesystem zum qualitätsmotivierten Inline-Monitoring für Schweißprozesse auf Basis von Methoden künstlicher Intelligenz

AI System for Inline Monitoring of Welding processes



Autoren: Robert Maack, Yannik Hahn, Hasan Tercan, Tobias Meisen, Guido Buchholz,
Matthias Angerhausen, Marion Purrio, Thorsten Twiehaus

Projektlaufzeit: 01.05.2022 - 30.04.2024

Konsortialführung: FEF GmbH

Verbundpartner: Bergische Universität Wuppertal

Förderkennzeichen: 01IS22022A und 01IS22022B

im Förderschwerpunkt KI4KMU.

Das diesem Bericht zugrunde liegende Vorhaben wurde mit Mitteln des Bundesministeriums für Bildung und Forschung unter den Förderkennzeichen 01IS22022A und 01IS22022B gefördert. Die Verantwortung für den Inhalt dieser Veröffentlichung liegt bei der Autorin/beim Autor.

Teil II: Eingehende Darstellung

Inhaltsverzeichnis

II.1 Projektziele und Projektplan	3
AP 1 Anforderungsgenerierung	4
AP 2 Umsetzung Infrastruktur und KI-Modelltraining	4
AP 3 Entwicklung Online-Auswertung und Continual Learning	4
AP 4 Integration des Demonstrators	5
AP 5 Tests und Optimierung	5
II.2 Durchgeführte Arbeiten	6
Zu AP1: Anforderungsgenerierung	6
Zu AP2: Umsetzung Infrastruktur und KI-Modelltraining	9
Zu AP3: Entwicklung und Implementierung von Continual Learning Verfahren	11
Zu AP4: Integration des Demonstrators	14
Zu AP5: Tests und Optimierung	16
II.3 Projektergebnisse	17
Workshop 1 (24. November 2022)	18
Workshop 2 (03. Juli 2023)	18
Workshop 3 (05. Oktober 2023)	18
Workshop 4 (16. Januar 2024)	19
Workshop 5 (16. April 2024)	19
Zielerreichung und Abweichungen zum Projektplan	19
Wichtigste Positionen des zahlenmäßigen Nachweises	20
Notwendigkeit und Angemessenheit der geleisteten Projektarbeiten	20
Fortschritte auf dem Gebiet durch Dritte	21
II.4 Verwertung der Ergebnisse	21
Veröffentlichungen	22
Vorträge:	22
Nachrichten, Artikel und Social Media Beiträge	22
Referenzen:	23

Abbildungs- und Tabellenverzeichnis

Abbildung 1: Möglichkeiten der Erfassung für transiente Daten.....	6
Abbildung 2: Strom (gemessen), Spannung (gemessen) und Leistung (berechnet) eines Zyklus eines gepulsten Metall-Schutzgasschweißprozesses.	7
Abbildung 3: Qualitätsbestimmung einer Schweißung im Überlappstoß.	7
Abbildung 4: Ausschnitte aus der Phasenerlegung der FEF. Links: gestaffelte Darstellung der Spannungsdaten, rechts: Markierung der Hochstromphase.	9
Abbildung 5: Darstellung der KI Modellarchitektur	10
Abbildung 6: Versuchszelle für den Demonstrator	11
Abbildung 7: Eine Probe mit Fehlern erzeugt durch bewusstes Überschreiten des Prozessfensters.....	12
Abbildung 8: Vergleich der transienten Daten von zwei Stromquellen unterschiedlicher Hersteller.....	12
Abbildung 9: Infrastrukturdarstellung	14
Abbildung 10: Vergleich eines Schweißpulses einem vorher genutzten Impulslichtbogenschweißprozess (links) und eines Zyklus aus einem CMT-Prozess (rechts). Der Start und das Ende des Zyklus sind mit der gestrichelten roten Linie markiert.....	15
Abbildung 11: Screenshot der Webapplikation zur Darstellung der Qualitätsvorhersage	17
Tabelle 1: Der Projektplan zeigt die geplanten Laufzeiten der Arbeitspakete. Blau hinterlegte Felder symbolisieren den Abschluss eines jeden APs in Form eines Workshop, während welchem die Ergebnisse des APs abschließend diskutiert werden.	6
Tabelle 2: Versuchsaufbauten im Vergleich	8

II.1 Projektziele und Projektplan

Qualitätskontrollen in Schweißprozessen sind traditionell zeitaufwändig, kostenintensiv und zerstörend, da sie Stichprobenentnahmen und Materialprüfungen erfordern. Hier setzt das Potenzial datengetriebener Verfahren wie Deep Learning an. Durch die Analyse großer Mengen an Sensordaten aus dem Schweißprozess können komplexe Zusammenhänge zwischen Prozessparametern und der resultierenden Schweißnahtqualität aufgedeckt werden. Dies ermöglicht eine kontinuierliche, zerstörungsfreie Qualitätsüberwachung und eröffnet neue Möglichkeiten zur Prozessoptimierung und Effizienzsteigerung.

Das Projekt ASIMoW hat sich zum Ziel gesetzt, dieses Potenzial durch die Erforschung und die Entwicklung innovativer KI-Verfahren nutzbar zu machen. Der Fokus liegt auf Deep Learning Verfahren zur Online Qualitätsvorhersage in Schweißprozessen, sowie die Erforschung und Entwicklung von Continual Learning Verfahren, um die trainierten Modelle über Prozessvarianten hinweg nachhaltig und effizient nutzen zu können. Die Modelle werden in der Lage sein, auf Basis heterogener Daten aus dem Schweißprozess – hierzu zählen Stellgrößen, Sensordaten und Randbedingungen – eine Bewertung des aktuellen Schweißprozesszustandes vorzunehmen und eine quantitative Prädiktion der zu erwartenden Schweißnahtqualität abzuleiten.

Aufgrund von Veränderungen der Randbedingungen im Produktivumfeld müssen die eingesetzten neuronalen Netze kontinuierlich und dateneffizient neue qualitätsbestimmende Muster in den dargereichten Prozessdaten identifizieren. ASIMoW verfolgt daher nicht nur das Ziel, Continual Learning Verfahren umzusetzen und weiterzuentwickeln, sondern auch, angepasst auf produktionstypische Umgebungen und Herausforderungen, anzuwenden. Die Verfahren sollen den Anwendern ermöglichen, bereits trainierte und im Produktivumfeld eingesetzte Modelle bei sich stetig ändernden Bedingungen des Prozesses dynamisch anzupassen und fortlaufend auf wenigen Prozessdaten weiter zu trainieren.

Im Vorhaben werden vor allem drei Arten von Änderungen des Prozessgeschehens in Betracht gezogen, die häufig bei der industriellen Anwendung von Schweiß- und Fügeverfahren auftreten:

- 1) Veränderung qualitätsbestimmender Prozessparameter und Stellgrößen,
- 2) Aufkommen neuer Qualitäts- und Fehlergrößen und
- 3) Herstellerwechsel der Anlage, der Prozessart oder eines schweißnahtqualitätsbestimmenden Betriebsmittels

Ein weiteres Ziel von ASIMoW ist es, die Verfahren so auszulegen, dass deren Anwendung durch kleine und mittlere Unternehmen (KMU) mit begrenzter Expertise möglich ist. Momentan ist der Einsatz von Continual Learning Verfahren für konkrete Anwendungsfälle, vor allem in Bezug auf Sensordaten und Zeitreihendaten, jedoch mit dem aktuellen Stand der Wissenschaft und Technik nur begrenzt möglich. Durch das Vorhaben wird der KI-Technologietransfer aus der Forschung in den vorwettbewerblichen Bereich der Qualitätsüberwachung schweißtechnischer Systeme gebracht. Hier liefert das Projekt durch die Kombination aus Forschungstätigkeiten und praktischer Anwendung einen realen Mehrwert für die Durchdringung von KI-Methoden in der Wirtschaft.

Für den Einsatz von Schweißüberwachungssystemen in KMU sind Methoden des Continual Learning besonders geeignet. KMU müssen sich häufig schnell an den Markt anpassen und ihr Produktportfolio modifizieren, um am Markt zu bestehen. Zudem sind sie häufig hochspezialisiert auf schweißtechnische Sonderanwendungen. In beiden Fällen gilt es, Hindernisse durch Individuallösungen zu überwinden, die die Einführung und Umsetzung von KI-Technologien in diesen Unternehmen erschweren. Zudem sind KMU-spezifische IT-

Infrastrukturen zu beachten, die sich meistens durch weniger leistungsfähige Software- und Datenbanklösungen auszeichnen. Daher liegt ein Schwerpunkt des Vorhabens auf der Entwicklung von Continual Learning Methoden, die genau auf die Einsatzgebiete von KMUs mit Sonderanwendungen oder variierenden Anwendungen, für die nur eine geringe Anzahl von Initialdaten zur Verfügung stehen, spezialisiert sind.

Zur erfolgreichen und effektiven Zielerreichung wurde das Projekt in fünf Arbeitspakete (AP) unterteilt, die jeweils durch einen Workshop aus dem begleitenden Arbeitspaket AP0 abgeschlossen wurden. Die einzelnen Arbeitspakete (AP1 – AP5), ihre Ziele und ihr zeitlicher Rahmen sind in Tabelle 1 dargestellt und werden im Folgenden näher erläutert.

AP 1 Anforderungsgenerierung

Zu Beginn des Projektes war vorgesehen, die fachlichen und technischen Anforderungen an die zu entwickelnden Methoden (IKT, Datenverarbeitung, KI-basierte Qualitätsvorhersage, Continual Learning) zu formulieren. Es wurden Stellgrößen und Randbedingungen sowie die resultierenden Prozess- und Qualitätsdaten zur Erstellung der Prozessräume untersucht. Weiterhin beinhaltete dies die Definition von technischer Infrastruktur und Schnittstellen zur Messtechnik zum Zweck der Datenaufnahme. Die Daten wurden in einem von der Messtechnik unabhängigen Format abgespeichert, um eine möglichst reibungslose Integration der historischen Daten in das Training von KI-Modellen gewährleisten zu können. Darüber hinaus wurden Schnittstellen definiert, die über statische Datensätze hinaus eine Inline-Qualitätsvorhersage auf Streaming-Daten ermöglicht. Abschließend wurden Verfahren aus dem Stand der Wissenschaft recherchiert, die auf Grundlage der aufgestellten Anforderungen und Beschaffenheit der Daten eine Qualitätsvorhersage realisierbar machen. Deren Eignung wurde auf der konzeptionellen Ebene geprüft.

Meilenstein: Dokumentierte Anforderungsliste an Infrastruktur und KI-Methoden

AP 2 Umsetzung Infrastruktur und KI-Modelltraining

In diesem Arbeitspaket stand die Implementierung der zuvor definierten Infrastruktur samt des darauf anschließenden K-Modelltrainings im Vordergrund. Die Definition der Schnittstellen ermöglichte eine unabhängige Arbeitsweise der Projektpartner. Das FEF hatte vornehmlich die Verantwortung, Prozess- und Qualitätsdaten zu erheben und zu verarbeiten. Konkret sollten in den einzelnen Schritten die Erfassung, Analyse und Selektion bereits bestehender und realer, von unterstützenden Unternehmen bereitgestellter Datensätze durchgeführt werden. Dem TMDT kam die Aufgabe zuteil, erste Verfahren des Deep Learning zur Qualitätsvorhersage zu entwickeln und Deep Learning Verfahren zur numerischen Vorhersage von Schweißnahteneigenschaften sowie zur klassifizierenden Vorhersage von Schweißdefekten zu untersuchen. Die Modelle wurden mit den erzeugten und historischen Schweißprozessdaten trainiert und in umfangreichen Trainings- und Evaluierungsphasen iterativ verbessert. Als Bewertungskriterien dienten die Vorhersagegüte (Abweichung von realen Qualitätsgrößen bzw. Erkennungsrate von Defekten) sowie die Robustheit der Modellvorhersagen unter verschiedenen Schweißparameterkombinationen.

Meilenstein: DB/IKT-Infrastruktur sowie KI-Modelle zur Qualitätsvorhersage erprobt & umgesetzt

AP 3 Entwicklung Online-Auswertung und Continual Learning

Für diesen Abschnitt im Projekt wurden die in AP2 trainierten KI-Modelle dazu befähigt, die Qualität ihrer Vorhersage bei sich ändernden Prozessbedingungen mit minimalmöglichem Daten- und Trainingsaufwand aufrechtzuerhalten. Für die Erreichung dieses Ziels wurden die schweißtechnischen Produktionsschritte an Testanlagen mit der notwendigen Messtechnik

ausgestattet. Aus den dabei erhobenen Daten wurden Merkmale auf Basis von Prozesskennwerten extrahiert, mit welchen der Prozess überwacht werden konnte. Diese Daten unterscheiden sich von den in AP2 erhobenen Werten, da bei ihrer Erstellung eine gezielte Variation wesentlicher Kriterien möglich war. Folglich wurden individuelle Lösungsstrategien über verschiedene Prozessänderungen (Prozessparameter, Qualitätsgrößen, Anlagenhersteller) konzipiert, entwickelt und auf den erzeugten Schweißprozessdaten trainiert. Simultan erfolgte eine testweise Übertragung der Konzepte auf die Produktionsdaten externer Unternehmen. Letztlich wurde eine Evaluierung und iterative Verbesserung der Lernverfahren unter Rahmenbedingungen realer Produktivumgebungen ermöglicht. Hierbei wurden die verschiedenen Prozessänderungen für die Modelle mittels Variationen von Datenkombinationen simuliert und getestet. Die Bewertung erfolgte sowohl anhand der Skalierbarkeit und Dateneffizienz der Modelle als auch anhand ihrer Vergesslichkeit hinsichtlich älterer, bzw. vorheriger Lernaufgaben.

Meilenstein: Minimalmesstechnik integriert sowie Continual Learning Verfahren erprobt und umgesetzt

AP 4 Integration des Demonstrators

In diesem Arbeitspaket erfolgte die Integration der Minimalmesstechnik und der modelltechnischen Einzellösungen in einen gemeinsamen Demonstrator zur Inline-Qualitätsvorhersage im Schweißprozess auf Basis von Sensor- und Prozessdaten. Hierzu wurden zunächst die Lösungen bestehend aus Datenmessung, Persistierung, Merkmalsextraktion, KI-Modelltraining auf historischen Daten und KI-Vorhersage auf aktuellen Daten zusammengeführt und erprobt. Im Anschluss erfolgte die Erweiterung des Gesamtsystems um eine Komponente zur automatisierten Modellbewertung hinsichtlich neuer Prozessvariationen und um die erprobten Continual Learning Verfahren zur Weiterbildung der Modelle auf jenen Variationen.

Zuletzt wurde das System hinsichtlich der Eignung für die Aufgabe der Online-Auswertung von Prozessdaten evaluiert, beispielsweise nach Kriterien der Datenübertragungsrate, Robustheit und Sicherheit. Dieses Vorgehen stellte sicher, dass das System zügig und effizient in bestehende Produktionsvorgänge integriert werden kann.

Meilenstein: Umsetzung des Demonstrators als Gesamtsystem erfolgt

AP 5 Tests und Optimierung

Im Rahmen umfangreicher Testphasen im Produktivbetrieb der FEF erfolgte abschließend die Evaluierung des Gesamtdemonstrators. Dazu wurden Anlagen für verschiedene Schweißprozessvarianten mit Messtechnik und IT-Infrastruktur ausgestattet. Unterschiedliche Applikationen mit Variationen in Material, Geometrie, Prozess und Art der Fügeaufgabe wurden geplant, und verschiedene definierte schweißtechnische Versuchs- und Testszenarien wurden angesetzt. Dabei wurden Daten erhoben und die Ergebnisse der Schweißungen quantifiziert. Die eingesetzten KI-Modelle zur Qualitätsvorhersage sowie die umgesetzten Continual Learning Verfahren wurden anschließend auf Basis der erhobenen Anforderungen hinsichtlich Vorhersagegenauigkeit, Dateneffizienz und Robustheit gegenüber dynamischen Prozessveränderungen im Produktivbetrieb geprüft, validiert und punktuell verbessert. Die Auswertung der Testergebnisse diente darüber hinaus der Generierung von Erkenntnissen hinsichtlich potenzieller Adaptionen- und Entwicklungsmöglichkeiten der Verfahren. Um die Auswirkung diverser Rahmenbedingungen evaluieren zu können, wurde das System darüber hinaus bei Industriepartnern der FEF in Schweißapplikationen implementiert. Die Performance des Systems wurde während des dortigen Betriebs durch die FEF und das TMDT evaluiert.

Die Ergebnisse dieser Evaluierung fließen in die weitere Optimierung des Systems mit ein.
Meilenstein: Erfolgreiche Testreihen am Demonstrator im Produktivbetrieb

	FEF (PM)	TMDT (PM)	Jahr 1												Jahr 2									
			1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22
AP1	6	3	■	■	■	■	■	■	■	■	■	■	■	■	■	■	■	■	■	■	■	■	■	■
AP2	11	6																						
AP3	11	6																						
AP4	12	5																						
AP5	6	3																						

Tabelle 1: Der Projektplan zeigt die geplanten Laufzeiten der Arbeitspakete. Blau hinterlegte Felder symbolisieren den Abschluss eines jeden APs in Form eines Workshops, während welchem die Ergebnisse des APs abschließend diskutiert werden.

II.2 Durchgeführte Arbeiten

Zu AP1: Anforderungsgenerierung

Kategorisierung und beschreibende Analytik von Datenarten im Kontext der Fügetechnik

Im Rahmen von AP1 erfolgte die Entwicklung eines Konzeptes für die generalisierte Prozessanalyse von Metall-Schutzgas-Impulslichtbogenschweißprozessen. Die einzelnen Impulslichtbogenderivate verschiedener Stromquellenhersteller sind in ihrer Stromformung unterschiedlich, folgen aber dem grundsätzlich gleichen prozessphysikalischen Muster. Die relevantesten Prozessgrößen eines Impulslichtbogenschweißprozesses sind Strom und Spannung. Abbildung 1 zeigt den skizzierten Aufbau einer Metall-Schutzgas (MSG)-Schweißanlage und mögliche Spannungsabgriffe.

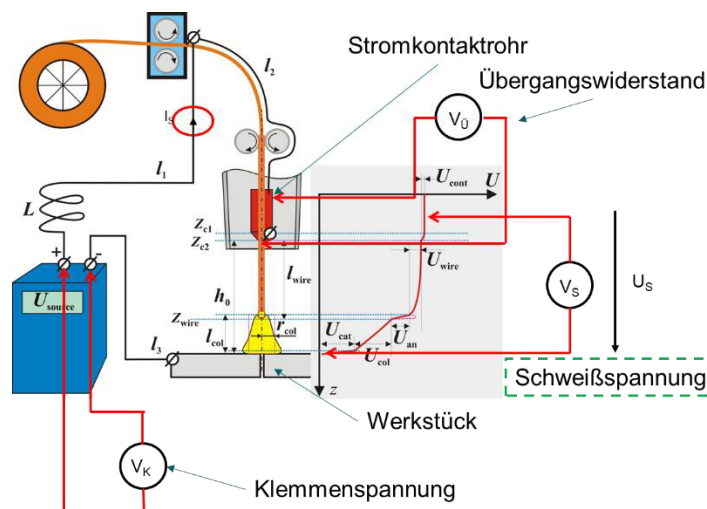


Abbildung 1: Möglichkeiten der Erfassung für transiente Daten.

Die Bestandteile der Anlage sind die Stromquelle (dunkelblau), Drahtelektrode (orange), Drahtfördereinheit (hellblau) sowie der Schweißbrenner mit Stromkontaktrohr (rot). Unterhalb des Stromkontaktrohres ist der eigentliche Schweißprozess mit dem skizzierten Lichtbogen (gelb) zwischen dem Ende der Drahtelektrode und dem Werkstück zu finden. Die Bezeichnungen der Spannung sind, je nach Abgriff an den roten Pfeilen zu finden.

Abbildung 2 zeigt exemplarisch einen Zyklus eines gepulsten MSG-Prozesses sowie verschiedene Phasen des Zyklus. Diese Schweißprozessvariante ist eine vielversprechende

Option für den Einsatz der KI im Projekt, da dieser Prozess sehr flexibel und für eine breite Anwendungsspanne geeignet ist, gleichzeitig aber wohldefinierte Prozesszustände aufweist, welche hinsichtlich der messbaren Daten gut klassifizierbar sind.

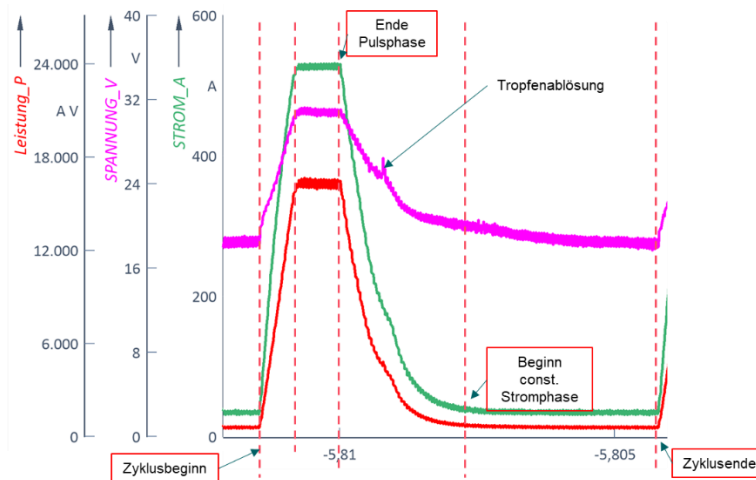


Abbildung 2: Strom (gemessen), Spannung (gemessen) und Leistung (berechnet) eines Zyklus eines gepulsten Metall-Schutzgasschweißprozesses.

Zur Variation der Prozessdatenbasis wurden umfangreiche Schweißversuche durchgeführt und die resultierenden Qualitätsgrößen erfasst und diskutiert. Es wurden u.a. die Schweißnahtvorbereitungen (Stoßarten) und Blechdicken variiert, wodurch ein umfangreicher Prozessraum aufgespannt wurde. Die erstellten Schweißnähte wurden zur Erfassung der Qualitätsgrößen fotografiert, per Sichtprüfung ausgewertet und final mittels Makroschliffen quantifiziert. Abbildung 3 zeigt beispielhaft einen solchen Makroschliff zu einem Überlappstoß. Zur fotografischen Dokumentation wurde eine Fotobox verwendet, um gleichmäßige Ausleuchtung zu garantieren. Für die Schlifferstellung wurden die Proben ausgesägt und im eigenen Labor eingebettet, präpariert und makroskopisch ausgewertet.




Abbildung 3: Qualitätsbestimmung einer Schweißung im Überlappstoß.

Anforderungsermittlung an die Infrastruktur der Datenerfassung

Zur Ermittlung der benötigten Minimalmesstechnik sind drei verschiedene Versuchsaufbauten umgesetzt, untersucht und verglichen worden. Aufgezeichnet wurden Strom und Spannung bei verschiedenen Prozessvarianten. Tabelle 2 zeigt die Varianten der Datenerfassungssysteme.

Messsystem	Aufnahmerate	Hardware	Software
------------	--------------	----------	----------

Transientenrekorder	100 kHz pro Kanal	Komplettsystem der Fa. Yokogawa	Interne Ausgabe im Format tdms
NI-Messkarten	50 kHz pro Kanal	Messkarten der Fa. NI in Rittalschrank, Messrechner (Tower)	NI Labview, eigenes Script
NI-DAQ	Max. 45 kHz über alle Kanäle, 20 kHz je Kanal Strom / Spannung	DAQ der Fa. NI, Messrechner (Microtower)	eigenes Python Script

Tabelle 2: Versuchsaufbauten im Vergleich

Nach Vergleich wurden die Messkarten und der DAQ als permanenter Versuchsaufbau etabliert, da die Validierung von Aufnahmezeit und Aufnahmegenaugigkeit mit Hilfe des deutlich performanteren Transientenrekorders zeigte, dass die Datenerhebung mittels Messkarten für alle Anwendungen ausreichen. Im weiteren Verlauf wurde die Datenerhebung mittels DAQ allerdings verworfen, weil diese wiederum nicht alle notwendigen Charakteristiken erkennen lässt.

Anforderungsermittlung an multimodale Fehlerklassifikation und Continual Learning

Die zunächst quantitativ mittels Makroschliff ermittelten Qualitätsdaten (siehe Abbildung 3) bedingen einander zum Teil und sind somit redundant. Zudem stellen sie zwar eine gängige und wichtige Methode der Qualitätsbestimmung dar, können aber naturgemäß nur eine Momentaufnahme der gesamten Schweißung abbilden.

Daher wurden orts aufgelöste Qualitätsdaten anhand von Sichtprüfungen ermittelt, welche im weiteren Verlauf durch Oberflächenscans mittels Lasertriangulation unterstützt wurden. Zusätzlich wurden applikationsspezifische Qualitätsklassen bestimmt, welche die ausgewerteten Merkmale anhand von Regeln zusammenfassen, um Redundanzen zu vermeiden und eine Bewertung auf die wesentlichen Aspekte zu beschränken. Bewertet wurde aus Gründen der Realisierbarkeit einer validen Vorhersage letztendlich nach DIN EN ISO 5817 [1] mit der finalen Aussage, ob eine Schweißung in Ordnung (i.O.) oder nicht in Ordnung (n.i.O) war.

Die Anforderungsermittlung für die KI-Modelle hat gezeigt, dass diese in der Lage sein müssen, multivariate Sensordaten, insbesondere Strom und Spannung, in Echtzeit und mit hoher Frequenz (z.B. 50 kHz) zu verarbeiten. Diese Daten sind entscheidend für die Erfassung der Dynamik des Schweißprozesses und die Vorhersage der Schweißnahtqualität. Hierfür sind robuste Feature-Engineering-Techniken wie Feature Extraction und die Nutzung von Autoencodern erforderlich, um verschiedene Phasen des Schweißzyklus zu extrahieren und zu verarbeiten. Rekurrente neuronale Netze oder Transformer-basierte Ansätze sind notwendig, um zeitliche Abhängigkeiten innerhalb und über mehrere Zyklen hinweg zu erfassen.

Zusätzlich müssen die Modelle kontinuierlich lernen können, ohne vollständige Neutrainingszyklen bei neuen Bedingungen durchzuführen. Konkret ergeben sich die Anforderungen, dass die Modelle flexibel auf Veränderungen der qualitätsbestimmenden Prozessparameter (z.B. unterschiedliche Stromstärken und Spannungswerte) reagieren sollen, neue Arten von Schweißfehlern erkennen sollen, die nicht im ursprünglichen Trainingsdatensatz enthalten waren, sowie robust gegenüber unterschiedlichen Geräten und Schweißstromquellen sein sollen. Zudem sollen sie daten- und ressourceneffizient auf neue Bedingungen anpassbar sein und kontinuierlich lernen können, ohne das bereits erlernte Wissen zu verlieren (sog. Catastrophic Forgetting).

Zu AP2: Umsetzung Infrastruktur und KI-Modelltraining

Konzeption und Umsetzung der Infrastruktur und eines geeigneten Datenbankkonzeptes

Im Rahmen von AP2 ist ein permanenter Versuchsaufbau mit Messtechnik an einem Roboterschweißversuchsstand aufgebaut worden. Dieser Versuchstand besteht maßgeblich aus einer KUKA KRC4 Steuerung, eines als Schweißroboter genutzten KR 16 R210 und einem DKP400 als Bauteilmanipulator. Prozesstechnisch wird die Versuchsumgebung durch eine TPSi 400 des Herstellers Fronius komplettiert und stellt somit ein Schweißfertigungssystem gemäß dem Stand der Technik dar.

Zur Datenpersistierung der Strom- und Spannungsdaten, der fotografischen Aufnahmen zur Qualitätsbeurteilung sowie der technologischen Randbedingungen wurde seitens FEF eine Speicherung auf einem gesicherten Datenserver mit täglichen Backups gewählt.

Statistische Datenanalyse und Entwicklung Merkmalsextraktion aus Sensordaten

Die in AP1 beschriebene Zerlegung eines gepulsten Schweißprozesszyklus in Phasen ist durch die FEF und das TMDT automatisiert worden. In Abbildung 4 sind die Oberflächen der Auswertprogramme exemplarisch dargestellt.

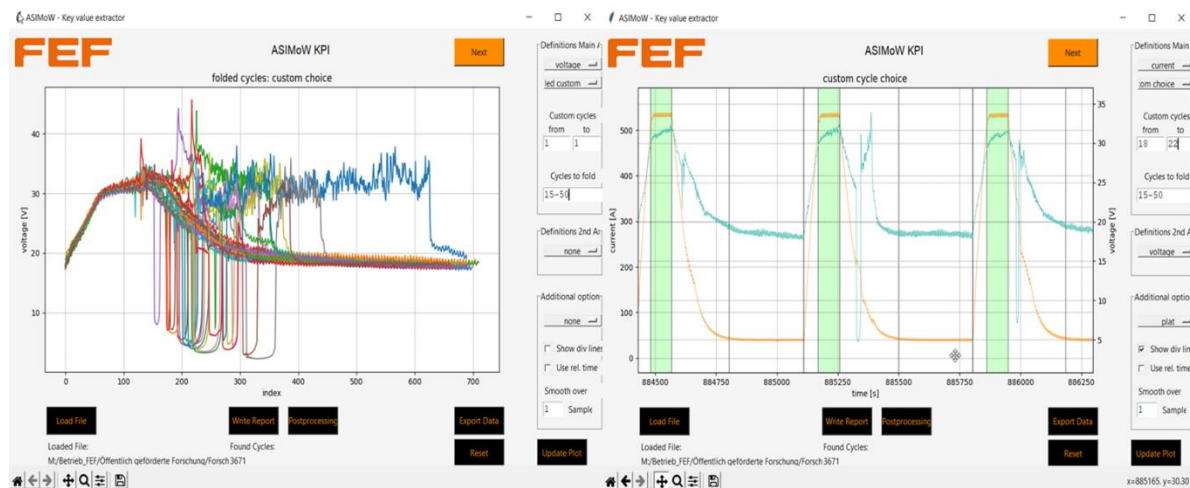


Abbildung 4: Ausschnitte aus der Phasenzерlegung der FEF. Links: gestaffelte Darstellung der Spannungsdaten, rechts: Markierung der Hochstromphase.

Als statistische Kenngrößen wurden Mittelwerte, Standardabweichung, Maxima und die Dauer der einzelnen Phasen ermittelt und ausgewertet. Als relevante Merkmale wurde beispielsweise das Auftreten und die Dauer von Kurzschlüssen, Schwankungen in der Grundphase sowie der Moment der Tropfenablösung identifiziert.

Im Folgenden wurde die Arbeitshypothese verfolgt, dass eine Häufung von Auffälligkeiten innerhalb eines Zeitraumes zu örtlichen Veränderungen der Schweißnaht führt.

Entwicklung von Lernverfahren und Training von KI-Modellen zur Qualitätsvorhersage

Im Rahmen von AP2 wurde ein Deep Learning Modell zur Qualitätsvorhersage erforscht und entwickelt. Wie in AP1 herausgearbeitet wurde, soll das Modell einerseits auf hochfrequenten Sensordaten operieren, andererseits die dynamischen Phasen des Schweißzyklus differenzieren und zeitliche Abhängigkeiten innerhalb und zwischen den Zyklen erfassen können. Auf Basis einer Literaturrecherche zum Stand der Forschung konnte festgestellt werden, dass es bisher kaum Lösungsansätze oder Forschungsarbeiten gab, welche diese Herausforderungen adressieren. Daher wurde im Rahmen des Projekts eine eigene Modellarchitektur entwickelt und im Vergleich zu Zeitreihenmodellen des Standes der

Forschung evaluiert. Sie basiert auf einem sorgfältig konzipierten Prozess, der aus den folgenden Unterpunkten besteht:

1. Extraktion von Zyklen mittels eines regelbasierten Algorithmus.
2. Datenbereinigung und Längennormalisierung und
3. Normalisierung der Zeitreihendaten für einen robusten Trainingsprozess

Die entwickelte Modellarchitektur ist in zwei Stufen aufgeteilt. Die erste Stufe beinhaltet das Erlernen einer diskreten Darstellung aus den einzelnen Schweißzyklen durch einen Vector Quantized Variational Autoencoder (VQ-VAE). Die zweite Stufe konzentriert sich auf das Training eines Transformer-Modells auf den aus dem VQ-VAE erhaltenen diskreten Darstellungssequenzen. Diese Stufe kombiniert sowohl eine Sequenzvorhersageaufgabe als auch eine Klassifizierungsaufgabe, um die prädiktive Genauigkeit und Generalisierbarkeit des Modells zu verbessern.

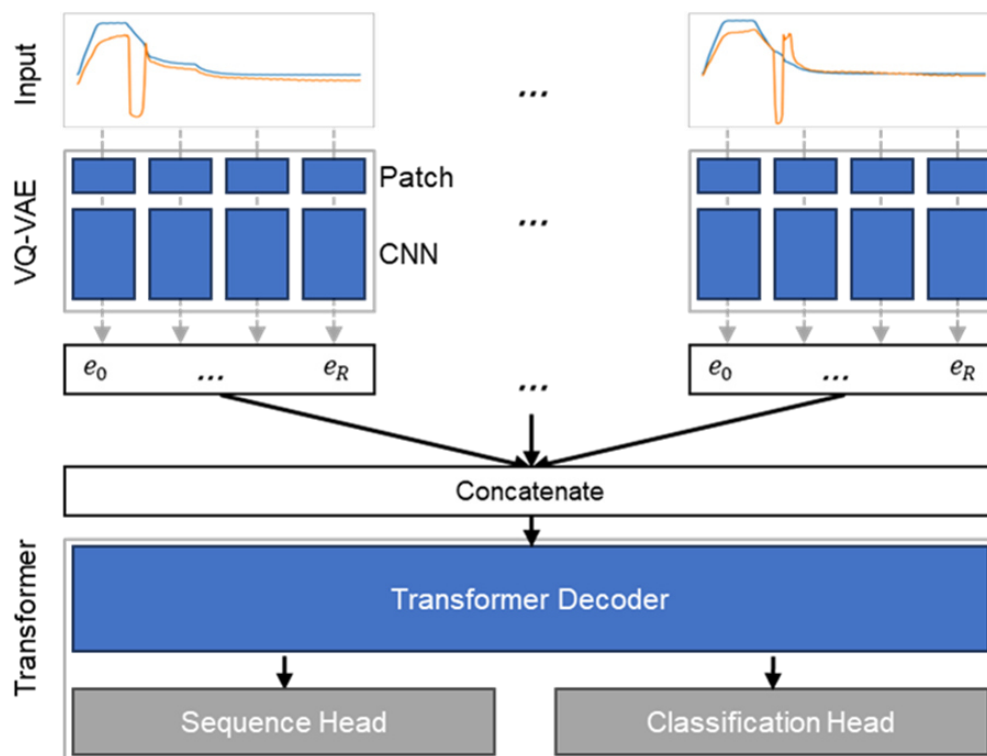


Abbildung 5: Darstellung der KI Modellarchitektur

Evaluierung und Optimierung auf historischen Daten hinsichtlich Robustheit und Güte

Das entwickelte Modell, der VQ-VAE Transformer, wurden mit verschiedenen rekurrenten Modellen, wie z.B. Transformer [2], TS2Vec [3] oder Timesnet [4] verglichen. Die Modelle wurden auf einem Datensatz trainiert und evaluiert, welcher aus den aufgenommenen Daten des Projektes mit Überlappstoß und T-Stoß bestehen.

Die Ergebnisse der Versuche haben gezeigt, dass der VQ-VAE Transformer eine Genauigkeit von 80 % und einen durchschnittlichen F1-Score von 0,77 bei Tests auf Daten mit unbekanntem Kombinationen von Schweißparametern erreicht. Hierbei hat der VQ-VAE Transformer eine höhere Genauigkeit im Vergleich zu den Modellen des Standes der Forschung gezeigt.

Dieses Ergebnis unterstreicht die Robustheit des Modells und sein Potenzial, signifikante Beiträge zu Fortschritten in der Schweißtechnologie zu leisten. Die Ergebnisse wurden in einer wissenschaftlichen Publikation dokumentiert, die auf der Conference on Information and Knowledge Management (CIKM 2024) akzeptiert wurde. Weitere Details zur Modellarchitektur,

zu den durchgeführten Versuchen und den experimentellen Ergebnissen sind in der Veröffentlichung zu finden. Im Rahmen dessen wurde der in ASIMoW erstellte Datensatz darüber hinaus öffentlich zugänglich gemacht, um die wissenschaftliche Reproduzierbarkeit der Ergebnisse zu gewährleisten. Dieser kann über die Online-Plattform Zenodo¹ abgerufen werden. Der Quellcode wurde öffentlich auf GitHub zur Verfügung gestellt². Im Rahmen von AP2 wurde projektintern eine Software zur visuellen Darstellung und Validierung der Sensordaten- und Qualitätsdaten erstellt. Im Sinne der Öffentlichkeitsarbeit wurde diese Software in Form einer Demo-Webseite³ ebenso zur Verfügung gestellt.

Zu AP3: Entwicklung und Implementierung von Continual Learning Verfahren

Entwurf und Integration der Minimalmesstechnik zur In-Line Erfassung, Speicherung und Auswertung von primären Prozessgrößen

Im Rahmen dieses Arbeitspakets umfassten die wesentlichen Tätigkeiten alle Vorbereitungen zur Integration des Demonstrators in den Prozess (vgl. AP4). Dazu wurde die zuvor evaluierte Messtechnik in die beschriebene Versuchsumgebung integriert, wobei darauf geachtet wurde, dass dies keine signifikanten Einschränkungen des Arbeitsbereichs des Roboters zur Folge hat.



Abbildung 6: Versuchszelle für den Demonstrator

Entwicklung von Methoden zur Online-Datenexploration und -aggregation in Fügeprozessen

Für die Online-Übertragung wurden die Strom- und Spannungsdaten aus den Kanälen der NI-Messkarten mittels Python an einen Rechner übertragen. Dazu wurden die von NI bereitgestellten Treiber verwendet. Die ebenfalls von NI bereitgestellten Methoden zum Ansprechen der Messkarten und zum Datentransfer wurden so angepasst, dass die Aufzeichnung mittels einer Benutzeroberfläche gestartet und gestoppt und direkt nach der Schweißung angezeigt werden konnte. Im Verlauf des Projektes wurden die Funktionen zum

¹ <https://zenodo.org/records/10017718>

² <https://github.com/tmdt-buw/VQ-VAE-Transformer-Arc-Welding>

³ <https://welding-ai.tmdt.uni-wuppertal.de/>

Übertragen der Schweißprozessdaten so angepasst, dass die aufgezeichneten Daten direkt batchweise zur weiteren Verarbeitung an die Auswerteeinheit gestreamt werden konnten.

Entwicklung und Implementierung von Continual Learning Verfahren

Continual Learning wird eingesetzt, um ein Modell an Input-Daten mit neuen Mustern anzupassen, ohne bereits gelerntes Wissen zu vergessen. Im Kontext eines Schweißprozesses können beispielsweise wechselnde Schweißparameter zu einem solchen Verhalten führen.

So wurden in einem experimentellen Aufbau bewusst Unregelmäßigkeiten in den Schweißprozess induziert, die zu qualitativ minderwertigen Stellen in der Schweißnaht führen (siehe Abbildung 7).



Abbildung 7: Eine Probe mit Fehlern erzeugt durch bewusstes Überschreiten des Prozessfensters.

In einem weiteren Schritt wurde anschließend die Schweißstromquelle durch eine Titan XQ 400 Puls des Herstellers EWM ausgetauscht. Da verschiedene Hersteller individuelle Kennlinien für die Prozesssteuerung verwenden, läuft der Schweißprozess auch bei identischen Prozessparametern unterschiedlich ab. Abbildung 8 zeigt den Unterschied in der Stromformung beider Stromquellen bei gleichen Prozessparametern. So wurden in kontrollierter Umgebung Strom-Spannungs-Daten von beiden Stromquellen unter vergleichbaren Randbedingungen gesammelt.

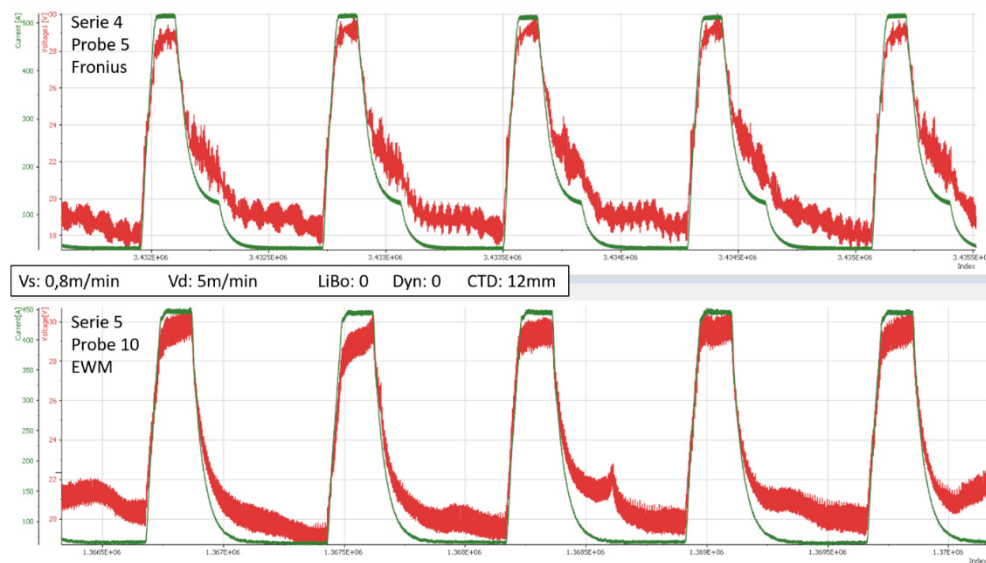


Abbildung 8: Vergleich der transienten Daten von zwei Stromquellen unterschiedlicher Hersteller

Wie Datenanalysen zeigen konnten, führt allerdings nicht jede Parameteränderung zu einer Änderung der Input-Daten. Um zu bestimmen, wann Continual Learning notwendig ist und wann ein neues, potenziell kostenintensives Training nicht erfolgen muss, wurde eine Out-of-Distribution (OOD)-Erkennung entwickelt und genutzt. Diese Methode ermöglicht es, Input-Daten, die stark von den gelernten Daten abweichen, automatisiert zu erkennen.

Sowohl die Rekonstruktionsqualität des VQ-VAE als auch die Genauigkeit des Transformers für die Vorhersage von Sequenzen des in AP2 entwickelten Modells können als Indikatoren für OOD-Daten verwendet werden. Abweichungen von den erwarteten Leistungen in diesen Bereichen können auf Daten hinweisen, die außerhalb der Verteilung der Trainingsdaten liegen. In AP 3 wurden drei OOD-Ansätze experimentell miteinander verglichen:

1. Es kann der Fehler berechnet werden, welcher angibt, wie stark der vom Modell encodierte Input von gelernten Repräsentationsvektoren abweicht (Embedding-Fehler).
2. Außerdem kann der Rekonstruktionsfehler bestimmt werden.
3. Des Weiteren kann die Sequenzvorhersageaufgabe des Transformer-Modells verwendet werden, um eine Abweichung der Sequenz von den gelernten Sequenzen zu bestimmen (Autoregressive-Fehler).

Dazu wurden Schweißdaten von Überlappstößen als Trainingsdaten und Schweißdaten von T-Stößen als Testdaten verwendet. Diese Datenaufteilung beinhaltet sowohl unterschiedliche Schweißparameterkombinationen als auch die unterschiedlichen Schweißarten. Die Ergebnisse zeigten, dass der dritte Ansatz, welcher den Autoregressive-Fehler verwendet, die höchste Genauigkeit bei der Erkennung von außerhalb der Verteilung liegenden Daten aufweist.

Auf Grundlage einer Literaturrecherche zu aktuellen Ansätzen des Continual Learning wurden Rehearsal-Methoden als vielversprechend für die genannten Anforderungen identifiziert. Bei diesen Methoden werden für das Neutraining eines Modells historische Trainingsdaten zusammen mit neuen Daten in einem Zwischenspeicher verwendet. In AP3 wurde eine entsprechende Rehearsal-Methode evaluiert, indem OOD-Schweißvorgänge für ein Training mit historischen Schweißdaten zu einem neuen Datensatz kombiniert wurden. Hierbei wurde die Genauigkeit von sowohl OOD-Schweißvorgängen als auch In-Distribution-Schweißvorgängen verbessert, ohne eine Verschlechterung der Vorhersagequalität auf den zuvor gelernten Daten zu zeigen. Die Vorhersagegüte des Modells konnte hierdurch von einer Genauigkeit von 69% auf 81% erhöht werden.

Das Konzept für das Continual Learning Verfahren in einem Schweißprozess wurde in einer wissenschaftlichen Publikation ausgearbeitet und im Oktober 2023 auf der CIRP CMS vorgestellt. Eine weitere Publikation, in welcher die Evaluationsergebnisse des Continual Learning und der OOD-Erkennung dokumentiert sind, befindet sich gerade in der Phase der Verschriftlichung.

Evaluierung und Optimierung auf historischen Daten hinsichtlich Dateneffizienz und Transfer

Zur Optimierung des Datentransfers wurde die Datenerfassung derart angepasst, dass Daten in kleinen Paketen fester Größe der Auswertung zugeführt werden können. So ist es möglich, eine kontinuierliche Schweißung in Datenpakete mit einer festen Aufnahmefrequenz und definierten Dauer direkt während der Aufnahme als Eingangsdaten für das Modell bereitzustellen. Eine Paketgröße von 50.000 Datenpunkten pro Kanal hat sich für die Übertragung hinsichtlich der Aufzeichnungs- und Übertragungsrates bewährt. Dies entspricht einem Datenpaket pro Sekunde bei einer Aufnahmefrequenz von 50 kHz.

Zu AP4: Integration des Demonstrators

Integration der Einzellösungen für die Online-Auswertung am Beispiel der Schweißnahtprädiktion

Während der gesamten Projektlaufzeit wurde bei der Entwicklung der Software auf eine möglichst reibungslose Einbindung in die Produktivumgebung der FEF geachtet. Insofern wurde bei der Integration der Forschungsergebnisse auf Virtualisierungslösungen gesetzt, die eine betriebssystemunabhängige Einbettung in bestehende monolithische Systeme ermöglicht. Zu diesem Zweck wurden Anpassungen an der Netzwerkinfrastruktur vorgenommen, um den Betrieb der entwickelten Software auf einem Rechner lauffähig zu machen. An die Eigenschaften des Rechners wurden zunächst keine speziellen Anforderungen gestellt.

Bei ersten Integrations-Tests zeichnete sich allerdings ab, dass dedizierte Hardware zur Beschleunigung der Qualitätsbestimmung notwendig werden würde. Daher wurde eine dedizierte Grafikkarte eingesetzt, auf deren Architektur das trainierte KI-Modell beschleunigt ausgeführt werden kann. Dies ermöglichte eine Echtzeitvorhersage der Schweißnahtqualität während des laufenden Schweißprozesses.

Abbildung 9 zeigt schematisch die in ASIMoW umgesetzte Infrastruktur sowie die Entwicklungsarbeiten zwischen der FEF und dem TMDT. Bei der FEF wurden historische Schweißdaten einschließlich der zugehörigen Qualitätsmerkmale erfasst. Die Daten wurden in einer Datenbank des TMDT gespeichert, um das oben beschriebene KI-Modell zu trainieren. Anschließend wurde eine Hyperparametersuche durchgeführt, das daraus resultierende beste Modell ausgewählt, gespeichert und zusammen mit der Datenverarbeitungs pipeline in einem portablen und plattformunabhängigen Docker-Container bereitgestellt. Dieses Vorgehen ermöglichte ein effektives Ausrollen von Änderungen an den Eingangsdaten, der Datenvorverarbeitung oder der KI-Architektur.

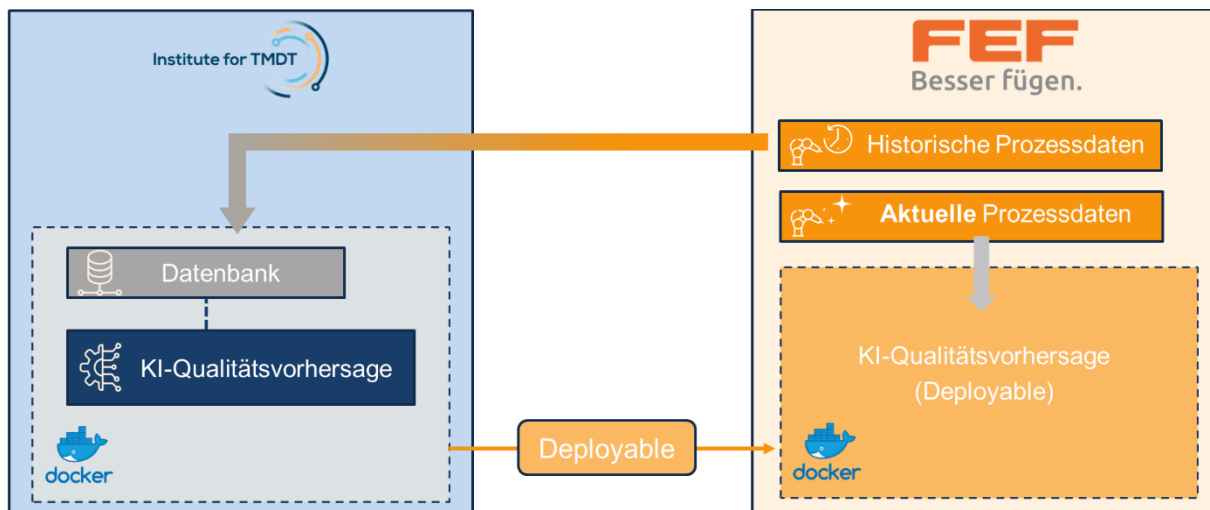


Abbildung 9: Infrastrukturdarstellung

Das im Container bereitgestellte Modell wird zur Online Qualitätsbewertung auf aktuellen Prozessdaten genutzt. Konkret wird auf einem lokalen Rechner ein Skript gestartet, das die Messdaten von dem Messgerät empfängt und im Sekundentakt über einen Websocket als Daten-Chargen an den Docker Container sendet. Die folgenden Schritte werden durchlaufen:

1. Vorverarbeitung der Sensordaten, inklusive Extraktion der Schweißzyklen,

2. Vorhersage des Modells auf Datenfenster mit n Zyklen, wobei eine Vorhersage für jeden Zyklus vorgenommen wird,
3. Mehrheitsvotum über die Schweißnahtqualität für das gesamte Datenfenster und Bestimmung der Konfidenz der Vorhersage und
4. Visualisierung der Vorhersage in einer webbasierten Applikation

Integration von Methoden zur automatisierten Bewertung und Weiterbildung der Methoden

Ein zentraler Aspekt des Projekts war die Entwicklung von Methoden zur automatisierten Bewertung und kontinuierlichen Weiterbildung der KI-Modelle. Diese ermöglichen eine flexible Anpassung an neue Daten und veränderte Bedingungen, was insbesondere bei der Übertragung auf andere Anwendungsbereiche von entscheidender Bedeutung ist.

Ein konkretes Beispiel hierfür ist die erfolgreiche Adaption des entwickelten und trainierten Modells auf eine Cold Metal Transfer (CMT)-Schweißanlage in der Automobilindustrie. Diese Anpassung umfasste sowohl die Sicherstellung, dass die Daten im gleichen Format in das KI-Modell eingespeist werden, als auch den erfolgreichen Transfer des KI-Modells, welches eine vergleichbare Performance wie in den Arbeitspaketen 2 und 3 erzielte. CMT ist ein Schweißverfahren mit geringem Wärmeeintrag, das aufgrund seiner Vorteile wie minimalem Verzug und reduzierten Wärmeeinflusszonen häufig für empfindliche Materialien eingesetzt wird. Das CMT-Verfahren zeichnet sich durch eine komplexe Prozessregelstruktur aus, welche unter reproduzierbaren Randbedingungen reproduzierbare Qualitäten erzeugt. Aufgrund der reduzierten Prozessenergien reagiert der Prozess allerdings sehr stark auf Änderungen der Prozessrandbedingungen, welches wiederum zu Veränderungen der Schweißnahtqualitäten führt. Vor diesem Hintergrund lässt sich somit die Forderung nach einer präzisen Überwachung und Steuerung des Prozessverhaltens und damit der resultierenden Schweißnahtqualität formulieren.

Um eine zuverlässige Anwendung des in AP2 vorgestellten Modells im CMT-Prozess zu ermöglichen, war eine Anpassung der Datenverarbeitungspipeline notwendig. Insbesondere die Zyklus-Extraktion, ein entscheidender Schritt zur Identifizierung und Analyse einzelner Schweißzyklen, musste an die spezifischen Eigenschaften des CMT-Verfahrens angepasst werden. Im CMT-Prozess gibt es einen charakteristischen zweiten Stromanstieg, welcher im Extraktionsalgorithmus berücksichtigt werden musste. Ein Beispiel für die unterschiedlichen Eigenschaften der Zyklen wird in Abbildung 10 dargestellt. Durch diese gezielten Anpassungen konnte eine robuste und zuverlässige Datenbasis für die Modellanwendung geschaffen werden.




Abbildung 10: Vergleich eines Schweißpulses einem vorher genutzten Impulslichtbogenschweißprozess (links) und eines Zyklus aus einem CMT-Prozess (rechts). Der Start und das Ende des Zyklus sind mit der gestrichelten roten Linie markiert.

Die erfolgreiche Übertragung des Modells auf den CMT-Prozess in der Automobilindustrie, welche in AP5 detailliert beschrieben wird, unterstreicht die Flexibilität und Anpassungsfähigkeit der entwickelten Methoden. Sie demonstriert das Potenzial der KI-

gestützten Schweißqualitätsüberwachung in einem breiten Spektrum industrieller Anwendungen.

Zu AP5: Tests und Optimierung

Vorbereitung geeigneter Prüfumgebungen mit wechselnden Rahmenbedingungen

In AP5 wurden die Verfahren zur Qualitätsvorhersage für ihren Einsatz unter realen Bedingungen validiert. Für die Untersuchungen konnte ein Automobilhersteller gewonnen werden, welcher für ASIMoW Schweißdaten bereitstellte, die im Rahmen der Fertigung von Karosseriebauteilen erfasst wurden. Bei der Analyse der Daten wurde deutlich, mit welchen Herausforderungen eine Anwendung in realer Produktion konfrontiert ist:

- Da der Brenner der Anlage nicht zugänglich war, wurden die Spannungsdaten direkt an der Schweißstromquelle erhoben. Dies führte zu einem veränderten Spannungsverlauf, zu dessen Auswertung das Modell ebenfalls befähigt wurde.
- Die einzelnen Schweißungen waren Teil einer definierten Roboterfahrt. Zwischen den Schweißungen wurde nicht gestoppt, so dass das Modell in der Lage sein musste, Roboterfahrten ohne Schweißung und andere Leerläufe, welche datenseitig trotzdem aufgezeichnet wurden, als irrelevantes Rauschen zu interpretieren.

Durch nicht planbare Umstände war es beim Unternehmen nicht möglich, Qualitätsdaten zu den durchgeführten Schweißnähten zu sammeln. Aus diesem Grund konnte keine Validierung der Qualitätsvorhersage durchgeführt werden. Dies wurde im Produktivbetrieb der FEF (siehe nächster Schritt) nachgeholt.

Durchführung von Online-Tests im Produktivbetrieb der FEF

Bei diesem Setup lag der Fokus nicht auf der Datenerhebung, sondern auf der Nutzung der Anwendung in Produktionsumgebung. Zur Übertragung des Modells wurden zunächst einige Versuche mit gezielt eingebrachten Störungen betrachtet. Die Störungen umfassten:

- Falsche Brennerposition,
- Fehlpositionierung der Halbzeuge,
- Verschmutzungen der Halbzeuge,
- Kontaktrohr mit zu großem Durchmesser (kann zu Fehlkontaktierung des Drahtes führen),
- Prozessunterbrechungen und
- falsche Prozessparametrierung.

Bereits bei der Qualitätsprüfung der Bauteile zeigte sich, dass einige dieser Versuche trotz der eingebrachten Störungen zu einer guten Bauteilqualität führten. Daher wurden diejenige Versuche, die auch zu einer mangelhaften Schweißnaht führten, in einer zweiten Versuchsreihe zur statistischen Absicherung mehrfach wiederholt. Diese Daten fließen in das im Folgenden beschriebene Modelltraining ein.

Durchführung von Tests, Validierung und Plausibilitätsprüfung der KI-Modelle und Qualitätsvorhersagen

Der VQ-VAE-Transformer wurde auf einem neuen, umfangreichen CMT-Datensatz von 40.313 Schweißzyklen feinabgestimmt und neu trainiert. Dieser Datensatz zeichnet sich durch seine Vielfalt aus, da er 102 verschiedene Schweißvorgänge, einschließlich diverser Sonderfälle mit Randbedingungen, abdeckt.

Auf einem Testdatensatz erreichte der VQ-VAE-Transformer eine Genauigkeit von 0,793 und einen F1-Score von 0,822. Diese Ergebnisse belegen die hohe Qualität und Zuverlässigkeit des Modells bei der Klassifizierung und Vorhersage.




Abbildung 11: Screenshot der Webapplikation zur Darstellung der Qualitätsvorhersage

Evaluierung und Bewertung des Systemkonzepts bei Partner- und Kundenunternehmen der FEF

Ein weiterer wichtiger Meilenstein des Projekts war die gemeinsame Prüfung und Evaluierung des Modells sowie der gesamten Datenverarbeitungspipeline. Das entwickelte Dashboard (siehe Abbildung 11), welches in React implementiert wurde, dient der Echtzeit-Visualisierung der Schweißqualitätsvorhersage. Jede Sekunde an Schweißdaten wird in einer eigenen Karte dargestellt, wobei die Farbe der Karte die Qualität anzeigt: Grün für gute Qualität und Rot für schlechte Qualität. Unter dem Label "Confidence" wird in Prozent angegeben, wie sicher das Modell in seiner Vorhersage für die jeweilige Datensekunde ist. Diese Visualisierung ermöglicht eine intuitive Einschätzung der Zuverlässigkeit der Vorhersage.

Das Dashboard aktualisiert sich sekundlich, wobei neue Karten rechts von den bestehenden hinzugefügt werden. Dadurch wird eine kontinuierliche Vorhersage ermöglicht, die bereits während des Schweißprozesses sichtbar wird. Der "Remove All"-Button bietet die Funktionalität, alle angezeigten Karten zu entfernen, um das Dashboard für die nächste Schweißnaht oder Analyse zurückzusetzen.

Das Mess- und Auswertesystem sowie das Dashboard sind bei der FEF fest installiert und können Kunden- und Partnerunternehmen bei deren Besuch vorgeführt werden.

II.3 Projektergebnisse

Im Rahmen dieses Forschungsprojekts wurde erfolgreich ein KI-basiertes Modell zur Vorhersage der Schweißqualität entwickelt und implementiert. Das Modell erreichte eine Genauigkeit von 80% auf ungesesehenen Schweißparameterkombinationen und übertraf damit bisherige Methoden. Darüber hinaus wurde gezeigt, dass ein gezieltes Neutrainieren des Modells durch Continual Learning zu einer erhöhten Genauigkeit auf neuen Daten führt. Die Datenverarbeitung, das KI-Modell und die Messtechnik wurden in einem Demonstrator gebündelt, der direkt mit einer Schweißanlage verbunden werden kann und die Qualitätsvorhersagen des KI-Modells in einem Dashboard visualisiert.

Um den Wissenstransfer zu gewährleisten und die praktische Anwendung der Projektergebnisse zu fördern, wurden eine Reihe von Workshops zwischen den Projektpartnern FEF und TMDT durchgeführt. Diese Workshops zielten darauf ab, die Erkenntnisse aus der Modellentwicklung und dem Continual Learning didaktisch

aufzubereiten, zu diskutieren und in konkrete Handlungsempfehlungen zu überführen. Darüber hinaus erhielten die Teilnehmer praktische Einblicke in die Anwendung von Deep Learning Frameworks, wie beispielsweise Pytorch in Python, zur Lösung realer Problemstellungen. Ein weiterer Schwerpunkt lag auf der kritischen Bewertung der Übertragbarkeit der entwickelten Lösungen auf neue Anwendungsbereiche und Systeme. Abschließend wurden konkrete Handlungsempfehlungen unter Berücksichtigung der Bedürfnisse der Kunden der FEF erarbeitet. Die in den Workshops erarbeiteten Meilensteine werden im Folgenden detailliert vorgestellt und im Kontext der jeweiligen Arbeitspakete erläutert.

Workshop 1 (24. November 2022)

Der erste gemeinsame Workshop fand im November 2022 beim TMDT statt. Die Themen des Workshops waren unter anderem

- Tools und Methoden der Datenverarbeitungspipeline
- Aufbau von Prozessverständnis
- Vorgehen zur Phasenunterteilung in den Schweißzyklen
- Konzeptionierung der Modellbildung
- Datenvisualisierung

Für die FEF ergaben sich aus diesem Workshop neben Informationen und Absprachen zum weiteren Vorgehen neue Erkenntnisse zur Faltung und zum Vergleich der Pulse untereinander und die nachfolgende Befähigung, die Python-Bibliothek Pytorch zur Erstellung eigener KI-Modelle einzusetzen. Mit letzterem war es seitens FEF möglich, ein erstes KI-Modell auf einem Pytorch-Testdatensatz sowie einen Datenimport zu einem KI-Modell auf einem eigenen Bilddatensatz zu implementieren. Dabei wurden die Anforderungen an das KI-Modell und die Infrastruktur gesammelt (Meilenstein 1).

Workshop 2 (03. Juli 2023)

Ziel dieses Workshops war die Validierung der Methodik zum Einlesen der Rohdaten aus den Messsystemen der Schweißanlagen sowie die Herstellung eines Kontextbezugs zwischen den ersten Ergebnissen aus den Qualitätsvorhersagen der tatsächlichen Qualität der Schweißungen. Dazu wurde der regelbasierte Algorithmus zur Bestimmung der Grenzen von Zyklen innerhalb der Messreihen der Schweißvorgänge vorgestellt und analysiert. Grenzfälle der Zuverlässigkeit der Zyklusextraktion wurden diskutiert und die Einstellparameter der Algorithmen entsprechend angepasst. Darüber hinaus wurde die Güte der Qualitätsvorhersage anhand verschiedener Kombinationen aus Trainings-, Validierungs- und Testdaten besprochen und die Aussagekraft einzelner Modelle kritisch bewertet (Meilenstein 2).

Workshop 3 (05. Oktober 2023)

Der Fokus dieses Workshops lag in der Befähigung der FEF, die vom TMDT entwickelte Codebasis langfristig nutzen zu können. Der Quellcode umfasste zum Zeitpunkt des Workshops die Routinen, die für das Einlesen der Rohdaten aus der Schweißmaschine genutzt werden, als auch die Modellarchitekturen, die für das Antrainieren eines KI-Modells zur Bewertung der Schweißqualität verwendet werden. Die gesamte Software wurde mittels Containervirtualisierung mit Docker zu einem plattformunabhängigen Paket zusammengefasst. Noch während des Workshops konnte die Software erfolgreich auf einem der FEF-eigenen Rechner installiert werden. Über die Realisierung eines geschützten Zugriffs der FEF auf die Daten eines internen Servers des TMDT konnte eines der aktuellen KI-Modelle geladen und verwendet werden. Darüber hinaus wurde die Ausführbarkeit der

Datenverarbeitungspipeline sowie das Modelltraining verifiziert, die FEF zur selbstständigen Verwendung der Software befähigt und die Minimalmesstechnik integriert. Die Erprobung und Umsetzung des Continual Learning Verfahrens wurde im nächsten Workshop 4 behandelt (Meilenstein 4).

Workshop 4 (16. Januar 2024)

Der vierte Workshop markierte einen entscheidenden Meilenstein im Projekt, indem er den Wissenstransfer intensivierte, die Praxistauglichkeit des Modells an der Schweißanlage evaluierte und die Inbetriebnahme des Systems vorbereitete. Zunächst wurde das Ergebnis aus der Anwendung von Continual Learning unter Einsatz von OOD-Detektion demonstriert und diskutiert. Auf Grundlage dessen wurden die Anforderungen und Rahmenbedingungen für den Einsatz des Modells im Produktivbetrieb definiert und ein Umsetzungsplan erstellt. Der konkrete Anwendungsfall diente als Pilotprojekt zur Validierung Modells unter realen Produktionsbedingungen.

Ein zentrales Element des Workshops war zudem der umfassende Test der gesamten Datenpipeline, angefangen bei der Messung der Schweißparameter bis hin zur Übertragung der Daten in den Docker-Container, der das ausführbare KI-Modell beinhaltet. Dieser Test ermöglichte die Identifizierung und Behebung potenzieller Schwachstellen in der Datenverarbeitung und gewährleistete eine reibungslose Integration des Modells in die bestehende Infrastruktur. Somit wurde das Modell erfolgreich an der Schweißanlage als Gesamtsystem in Betrieb genommen (Meilenstein 4).

Workshop 5 (16. April 2024)

Ein Schwerpunkt des Workshops lag auf der umfangreichen Evaluierung des Modells im spezifischen Anwendungsfall für das Schweißverfahren Cold Metal Transfer (CMT). Dabei wurden sowohl die Leistungsfähigkeit als auch die Robustheit des Modells unter realen Produktionsbedingungen eingehend geprüft. Es wurde einer umfassenden Bewertung unterzogen, bei der verschiedene Fehlerquellen sowohl im Anwendungsfall der Automobilindustrie (CMT) als auch bei Überlappstoß-Schweißungen berücksichtigt wurden. Diese Evaluierung ermöglichte eine detaillierte Analyse der Stärken und Schwächen des Modells in unterschiedlichen Szenarien. Die Ergebnisse zeigten, dass das Modell in der Lage ist, Schweißfehler zuverlässig anhand von Strom- und Spannungsdaten zu identifizieren. Darüber hinaus wurde im Workshop das entwickelte Dashboard zur Visualisierung und Analyse der Schweißergebnisse intensiv getestet. Dabei standen die Benutzerfreundlichkeit, die Informationsdichte und die Funktionalität des Dashboards im Fokus.

Insgesamt lieferte der fünfte Workshop wertvolle Erkenntnisse für die weitere Optimierung und Anpassung des Modells und insbesondere eine Diskussion über die Erklärbarkeit des Modells. Die erfolgreiche Evaluierung unter realen Bedingungen im Produktivbetrieb unterstreicht das Potenzial der KI-gestützten Schweißqualitätsüberwachung für die Steigerung der Effizienz und Qualität in der industriellen Fertigung (Meilenstein 5).

Zielerreichung und Abweichungen zum Projektplan

Die Zeitplanung dieses Projektes sowie alle Meilensteine, wie in den oben beschriebenen Abschnitten zu den jeweiligen Workshops, konnten eingehalten werden. Somit wurden alle Projektziele erreicht.

Zu der ursprünglichen Vorhabensbeschreibung gab es weder inhaltliche, terminliche oder formale Abweichungen.

Jedoch stand der anvisierte Industriepartner zum Arbeitspaket 5 („Test und Optimierung“) nach der Prozessdatenerhebung aus betriebsinternen Gründen nicht mehr als Validierungspartner zur Verfügung, so dass die Validierung des Qualitätsprädiktionssystems sehr kurzfristig an einer anderen Produktionsstätte erfolgen musste. Trotzdem konnten bereits aus der Datenerfassung wertvolle Erkenntnisse beim Einsatz in realer Produktion gewonnen werden.

Wichtigste Positionen des zahlenmäßigen Nachweises

Hinsichtlich der Ausgaben sind FEF-seitig in zwei Bereichen weniger Kosten angefallen als geplant: Die Personalkosten sind geringer ausgefallen als zunächst angenommen, da durch eine intern notwendige Umstrukturierung zunächst weniger Stunden abgerufen wurden als geplant. Die notwendigen Arbeiten konnten aber durch den eingesetzten Mitarbeiter auch in der kürzeren Zeit durchgeführt werden, so dass dies keinen Einfluss auf das Projektergebnis hatte. Außerdem wurden Investitionen nicht im projektierten Rahmen abgerufen, da Bestandsanlagen und Equipment sich für die Experimente als geeignet und ausreichend herausgestellt haben. Diese konnten auch über die gesamte Projektlaufzeit als Ressource genutzt werden.

In folgender Tabelle finden sich die wichtigsten Positionen des zahlenmäßigen Nachweises.

Position	Wert
Personalkosten	451.241,30 €
Materialkosten	7.852,21
Reisekosten	3.514,43 €

Die durch das TMDT empfangenen Fördermittel wurden planmäßig für Personal- und Reisemittel aufgewendet. Das Budget für die Reisekosten wurde nicht vollständig ausgeschöpft, da eine geplante Reise für eine Konferenz für eine im Kontext des Projektes entstandenen Veröffentlichung nicht mehr innerhalb der Projektlaufzeit durchgeführt wurde. Kosten für Geräte und Gegenstände sind nicht entstanden.

In folgender Tabelle finden sich die wichtigsten Positionen des zahlenmäßigen Nachweises.

Position	Wert
Personalkosten	141.186,36 €
<ul style="list-style-type: none"> • Davon Entgeltgruppe E12 – E15 • Davon Entgeltgruppe E1 – E11 	<ul style="list-style-type: none"> • 141.186,36 € • 0 €
Reisekosten	911,75 €

Notwendigkeit und Angemessenheit der geleisteten Projektarbeiten

Mit Hilfe des Förderprogramms KI4KMU war es der FEF und dem TMDT möglich, das Projekt „ASIMoW“ durchzuführen. Dadurch konnte die FEF ihr Dienstleistungsportfolio breiter gestalten und neben technischer Schweißprozessexpertise nun auch zunehmend IT-fokussierte Themen wie modellbasierte Prozessüberwachung und Qualitätsprädiktion anbieten. Die projektierten Arbeiten waren dazu in ihrem Umfang und ihrer Ausführung notwendig. Da zu Beginn des Projektes nicht gesichert war, dass entwickelbare und (kommerziell) verwertbare Ergebnisse erzielt werden können, wäre dieses Projekt ohne die Unterstützung des BMBF seitens FEF nicht in diesem Umfang und Ergebnishöhe realisierbar gewesen.

Fortschritte auf dem Gebiet durch Dritte

Im Bereich der Schweißtechnik sieht die FEF eine zunehmende Fokussierung auf das Thema der Qualitätsprädiktion mittels Methoden der künstlichen Intelligenz. Im Stand der Forschung finden sich Publikationen, in denen KI-Modell auf Grundlage der elektrischen Leistungsaufnahme trainiert werden. Diese beschränken sich jedoch in allen Fällen auf aggregierte stochastische Merkmale über mehrere Schweißzyklen hinweg. Eine Detailbetrachtung der Prozessverhaltens auf Grundlage einzelner Schweißzyklen – so wie es in diesem Projekt erfolgreich eingesetzt werden konnte – gibt es bisher nicht. Im Bereich kommerzieller Lösungen wird immer noch größtenteils auf die Bildauswertung gesetzt. Hochauflösende transiente Prozessdaten kommen hier kaum zum Einsatz.

Darüber hinaus lassen sich Ansätze finden, die verschiedene Datenarten kombinieren. So wurde auf dem DVS-Congress dem Thema der „Digitalisierung in der Schweißtechnik“ eine eigene Session gewidmet, bei welcher sowohl übergreifende Themen wie Plattformen und Systemkomponenten (siehe z.B. [5]) als auch sehr konkrete Anwendungsfälle wie das Überschweißen von Heftnähten behandelt wurden (siehe z.B. [6]).

II.4 Verwertung der Ergebnisse

Demonstrator: Die Auswertung der Qualitätsprädiktion zu Projektabschluss war erfolgreich, so dass der installierte Demonstrator auch für zukünftige Produktionen weiterhin eingesetzt wird. Dazu wird laufend Bedienerfeedback eingeholt und das System auch nach Projektende weiter optimiert, um bestmöglich genutzt zu werden. Da dieser Prototyp bereits industriell einsetzbar ist, wird mit einer fertigen Lösung in weniger als einem Jahr gerechnet.

Publikationen: Bereits während des Projektes ist das Projekt auf Konferenzen und Messen beworben worden (siehe folgende Abschnitte „Veröffentlichungen“, „Vorträge“ sowie „Nachrichten, Artikel und Social Media Beiträge“). Auch nach Projektende ist eine Veröffentlichung und Darstellung der Ergebnisse auf schweißtechnischen Konferenzen geplant.

Ausgründung: Aufgrund der guten Zusammenarbeit der Projektpartner und des hohen Verwertungspotenzials der Projektergebnisse haben Mitglieder des TMDT und der FEF, die auch aktiv am Projekt mitgearbeitet haben, gemeinsam das Unternehmen FusionIQ Systems GmbH⁴ gegründet. Das Unternehmen spezialisiert sich auf die Realisierung und Vermarktung von datengetriebenen Lösungen und Dienstleistungen in der Schweißtechnik.

Kompetenzaufbau: Für die FEF bedeutete der Aufbau der KI-Kompetenz bereits jetzt eine Erweiterung ihres eigenen Produktportfolios durch weitere Datenanalysemethoden auf KI-Basis für schweißtechnische Prozessdaten.

Diese Erfolge wären ohne die Förderung nicht möglich gewesen, da der Forschungs- und Entwicklungsaufwand andernfalls zu hoch gewesen wäre. Zudem ist die Gründung der FusionIQ Systems GmbH eine direkte Folge aus der Zusammenarbeit in diesem Projekt und den Projektergebnissen.

⁴ <https://www.fusioniq-systems.de>

Veröffentlichungen

- Y. Hahn, R. Maack, H. Tercan, T. Meisen, G. Buchholz, M. Purrio, M. Angerhausen "Quality Prediction in Arc Welding: Leveraging Transformer Models and Discrete Representations from Vector Quantised-VAE", 2024, Proceedings of the 33rd ACM International Conference on Information and Knowledge Management, (pp. 4522-4529)
- Y. Hahn, T. Langer, R. Meyes, T. Meisen, "Time Series Dataset Survey for Forecasting with Deep Learning." *Forecasting* 5.1 (2023): 315-335.
- Y. Hahn, R. Maack, G. Buchholz, M. Purrio, M. Angerhausen, H. Tercan, T. Meisen: „Towards a Deep Learning-based Online Quality Prediction System for Welding Processes“, Elsevier Ltd, 2023, in: ScienceDirect - Procedia CIRP, www.sciencedirect.com
- M. Angerhausen, M. Purrio, G. Buchholz, R. Maack, Y. Hahn, H. Tercan, T. Meisen: „Ortsaufgelöste Qualitätsprädiktion aus transienten Schweißprozessdaten“, DVS Media, in: DVS-Berichte 2023, ISSN: 0418-9639
- T. Langer, V. Welbers, Y. Hahn, M. Wönkhaus, R. Meyes, T. Meisen, (2022, April). Visual Interactive Exploration and Labeling of Large Volumes of Industrial Time Series Data. In *International Conference on Enterprise Information Systems* (pp. 85-108). Cham: Springer Nature Switzerland.
- M. Angerhausen, G. Buchholz, M. Purrio: „Leitfaden für die Digitalisierung fügetechnischer Teilprozesse“, DVS-Berichte 2022

Vorträge:

- *Leitfaden für die Digitalisierung fügetechnischer Teilprozesse* – DVS Congress (19.9.2022)
- *Digitalisierung in der Schweißtechnik* – DVS Congress (19.9.2022)
- *Heavy Metal meets KI* – IHK-Arbeitskreis Wirtschaft/Wissenschaft (8.2.2023)
- *Analysesystem zum qualitätsmotivierten Inline-Monitoring für Schweißprozesse auf Basis von Methoden künstlicher Intelligenz* – ISF-Kolloquium Wissenstransfer
- *Ortsaufgelöste Qualitätsprädiktion aus transienten Schweißprozessdaten* – DVS Congress (12.9.2023)
- *Towards a deep learning-based Online Quality Prediction System for Welding Processes* – CIRP CMS 23 (25.10.2023)
- *Methoden zur Qualitätsprädiktion und Prozessbewertung beim Metallschutzgasschweißen* – DVS Congress (16.09.2024)
- *Learning Discrete Representations from Continuous Industrial Sensor Data: A VQ-VAE Approach for Quality Prediction* – VDE-ITG-Fachgruppe Signalverarbeitung und maschinelles Lernen (27.9.2024)

Nachrichten, Artikel und Social Media Beiträge

Das TMDT hat seine Präsenz in den sozialen Medien im Berichtszeitraum aktiv ausgebaut und dabei auch die mediale Aufmerksamkeit für das ASIMoW-Projekt erhöht. Dies zeigt sich in den Veröffentlichungen "Heavy Metal meets KI" in der Pressestelle der BUW (24.06.2022) und der Wuppertaler Rundschau (27.06.2022). Über den offiziellen LinkedIn-Account des TMDT mit über 800 Followern wurden 13 Beiträge mit konkretem Bezug zum ASIMoW-Projekt geteilt, um die Community über aktuelle Projektergebnisse, Veranstaltungen und Neuigkeiten zu

informieren. Ergänzend wurden über den offiziellen LinkedIn-Account der FEF sechs weitere Posts veröffentlicht.

Darüber hinaus wurden zehn Beiträge auf Instagram veröffentlicht, welche vor allem eine jüngere Zielgruppe, insbesondere Studierende aus dem Umfeld der Bergischen Universität Wuppertal, ansprachen. Auf X (ehemals Twitter) wurden acht Beiträge geteilt, um kurze Updates und Diskussionen zu fördern.

Referenzen:

- [1] DIN e.V. (Hrsg.) (DIN EN ISO 5817:2023-07): DIN EN ISO 5817:2023-07, Schweißen - Schmelzschweißverbindungen an Stahl, Nickel, Titan und deren Legierungen (ohne Strahlschweißen)- Bewertungsgruppen von Unregelmäßigkeiten (ISO 5817:2023); Deutsche Fassung EN ISO 5817:2023
- [2] Vaswani, Ashish, et al. "Attention is all you need." *Advances in neural information processing systems* 30 (2017).
- [3] Yue, Zhihan, et al. "Ts2vec: Towards universal representation of time series." *Proceedings of the AAAI Conference on Artificial Intelligence*. Vol. 36. No. 8. 2022.
- [4] Wu, Haixu, et al. "Timesnet: Temporal 2d-variation modeling for general time series analysis." arXiv preprint arXiv:2210.02186 (2022).
- [5] S. Mann et. al. „Vernetzte, digitalisierte, schweißtechnische Fertigung – Praktische Lösungen im Sinn der Industrie 4.0“ DVS-Berichte Band 395, 2024, S.291 ff
- [6] F. Jurke et. al. “Heftnahtüberschweißung beim Metall-Schutzgasschweißen – Überwachungs-, Erkennungs- und Regelalgorithmus für ein Schweißen mit konstanter Streckenenergie”. DVS-Berichte Band 395, 2024, S. 305 ff