

KI-BASIERTE QUALITÄTSKONTROLLE IN DER INDUSTRIELLEN PRODUKTION



PRAXISNAHE ERKENNTNISSE UND
VORGEHENSMODELL AUS DEM
HUMAINE FORSCHUNGSPROJEKT

EINFÜHRUNG

Wie kann Künstliche Intelligenz (KI) dabei helfen, industrielle Prozesse effizienter, stabiler und nachhaltiger zu gestalten? Diese Frage stellen sich viele Unternehmen – insbesondere in Zeiten zunehmender Komplexität und steigender Qualitätsanforderungen in der Produktion.

Der vorliegende Leitfaden gibt Einblick in ein praxisorientiertes Vorgehensmodell, das im Rahmen des Forschungsprojekts HUMAINE gemeinsam mit wissenschaftlichen Partnern der Ruhr-Universität Bochum und dem VDEh-Betriebsforschungsinstitut (BFI) entwickelt und im betrieblichen Kontext bei thyssenkrupp erprobt wurde. Ziel des Forschungsprojekts war es, eine KI-Assistenzlösung zu entwickeln, die bei der Ursachenanalyse von Qualitätsabweichungen im Stahlwalzprozess unterstützt – und dabei nicht nur auf Daten, sondern auch auf das Wissen von Domänenexpert:innen zurückgreift.

Im Mittelpunkt steht der Anspruch, KI in industriellen Prozessen als Unterstützung einzusetzen, um Qualitätsabweichungen (frühzeitig) zu erkennen,

Rückschlüsse auf Fehlerquellen schließen zu können und dadurch frühzeitig Maßnahmen einzuleiten. Aus der mehrjährigen Projekterfahrung wurde deutlich, dass eine erfolgreiche Umsetzung nur durch das Zusammenspiel aller relevanten Fachbereiche gelingen kann.

Was Sie in diesem Leitfaden erwartet? Ein klar strukturiertes Vorgehensmodell, das einen kompakten und praxisnahen Überblick über die wesentlichen Schritte von der Problemdefinition über die Datenintegration und KI-Entwicklung bis hin zur betrieblichen Umsetzung und kontinuierlichen Verbesserung gibt. Ob Sie am Anfang stehen oder bereits erste Erfahrungen mit KI gemacht haben: Dieser Leitfaden soll inspirieren, Orientierung geben und Mut machen, den nächsten Schritt zu gehen.

ÜBERBLICK

- 02 EINFÜHRUNG
- 04 PROBLEMSTELLUNG UND ZIELSETZUNG
- 07 DATENBEREITSTELLUNG & -QUALITÄTSSICHERUNG
- 12 KI-ENTWICKLUNG & -TRAINING
- 17 INTEGRATION IN BETRIEBLICHE PROZESSE
- 22 EVALUATION & KONTINUIERLICHE VERBESSERUNG
- 24 SCHLUSSWORT



PROBLEMSTELLUNG & ZIELSETZUNG

KI IN DER INDUSTRIE

Die industrielle Produktion steht heute mehr denn je vor der Herausforderung, Qualität, Effizienz und Flexibilität gleichzeitig zu steigern. In diesem Spannungsfeld gewinnt der Einsatz von Künstlicher Intelligenz (KI) zunehmend an Bedeutung. Doch wie gelingt es, KI langfristig erfolgreich in betriebliche Prozesse zu integrieren?

Dieser Handlungsleitfaden richtet sich an Unternehmen, die sich dieser Frage stellen – und auf der Suche nach einem strukturierten, nachvollziehbaren und erprobten Vorgehen sind. Im Zentrum steht die Entwicklung und Einführung

einer KI-Assistenzlösung, die Unternehmen dabei unterstützt, die Ursachen von Qualitätsabweichungen in ihren Produktionsprozessen zu identifizieren und zu verstehen.

Eine wesentliche Herausforderung bei der Integration von KI in industrielle Produktionsumgebungen besteht darin, das über viele Jahre aufgebaute Fachwissen der Domänenexpert:innen nicht zu ersetzen, sondern es so nutzbar zu machen, dass es sinnvoll in die KI-gestützten Systeme einfließen kann und sie so ihrer tagtäglichen Arbeit Unterstützung erfahren.

EINBLICK IN DEN PRAXISFALL IN HUMAINE

Die hohe Qualität der Produkte ist für die Hersteller von Flachstahlprodukten von sehr großer Bedeutung im europäischen und internationalen Wettbewerb. Entsprechend hoch ist die Belastung der für den Produktionsprozess sowie die Produktqualität verantwortlichen Mitarbeitenden. Sie müssen eine sehr große Anzahl Informationen berücksichtigen (Prozessdaten, Qualitätsdaten, Verwendungszweck des Kunden, Reklamationen, Informationen des Vormaterials), um schnell und gezielt Ursachen von Abweichungen ermitteln und abstellen zu

können. Dabei kommen Expertinnen und Experten unterschiedlicher Domänen zusammen, um die Ursachen für die Probleme zu identifizieren und schnellstmöglich zu beheben.

Im Praxisfall von HUMAINE wurde die Herstellung von verzintem Feinstblech behandelt. Bis zur Fertigstellung durchläuft das Produkt eine lange Kette von unterschiedlichen Herstellungsprozessen. Diese umfassen die Erzeugung von flüssigem Stahl, das Gießen in sogenannten Brammen mit anschließendem

Warm- und Kaltwalzen, sowie das Beschichten und Konfektionieren auf Kundenanforderung in Bezug auf Länge und Breite des Stahlbandes (siehe Abbildung 1). Zu jeder Prozessstufe werden von Automatisierungssystemen sowie verschiedenen Messsystemen Daten erfasst und gespeichert. Diese Daten werden an den Anlagen lokal visualisiert und von den Domänenexpert:innen der

Anlagen analysiert und zur Bewertung sowohl des Prozesszustandes als auch der Produktqualität herangezogen. Die Auswahl der Daten erfolgt dabei durch die jeweiligen Domänenexpert:innen in Abhängigkeit von der Aufgabenstellung und durch die Erfahrung der Expert:innen/ der Experten. Diese können bereits durch die Analyse einiger weniger Signale die Produktqualität einschätzen.




Abbildung 1: Vereinfachte Darstellung der werksübergreifenden Prozesskette für die Herstellung von beschichtetem Stahlband¹

Im Rahmen des HUMAINE-Projektes sollte ein KI-Assistenz-System entwickelt werden, welches die vorhandenen Daten automatisch analysiert und Hinweise für das Auftreten einer Abweichung der Produktqualität von einem Normalzustand ausgibt. Im Idealfall werden bereits Hinweise für die Ursachen der Abweichungen detektiert. Für die Entwicklung der KI-Assistenz ist das Wissen der Domänenexpert:innen zu berücksichtigen und ein entsprechender Workflow für die Verlässlichkeit bei domänenübergreifender Nutzung von Daten & Wissen zu entwickeln.

Werden Qualitätsprobleme erkannt, müssen die Ursachen dafür schnellstmöglich erkannt und abgestellt werden, damit nicht noch mehr Produkte hergestellt werden, die unter Umständen nicht

an den Kunden ausgeliefert werden können. Die besondere Herausforderung dabei ist, dass die Ursachen bei den Anlagen der verschiedenen vorgelagerten Prozessstufen liegen können. Als Beispiel sind die sogenannten Innenfehler zu nennen. Diese können bereits beim Gießen des flüssigen Stahls zu Brammen (rechteckige Stahlbarren von ca. 9 m Länge x 3 m Breite x 30 cm Höhe) entstehen, wenn Verunreinigungen beim Gießen mitgezogen werden. Diese treten dann aber erst wieder in Erscheinung, wenn die Brammen zu einem sehr langen (bis zu 15 km Länge) und sehr dünnen (bis zu 0,1 mm Dicke) Stahlband gewalzt werden. Erst dann sind diese Verunreinigungen wieder zu erkennen und werden von Qualitätsmess- und -inspektionssystemen erfasst.


¹ Quelle: [thyssenkrupp](#)

Der Praxisfall bringt eine Vielzahl an weiteren Herausforderungen mit sich:


- Es wird eine Vielzahl an Stahlbändern produziert, die sich in Bezug auf Produktionszeitraum, Kunden bzw. Aufträgen, Materialien und Prozessparametern unterscheiden.
- Es werden Daten mit verschiedene Datentypen entlang des Produktionsprozesses (Produktionsstandorte der thyssenkrupp Steel Europe in Duisburg und der thyssenkrupp Packaging Steel in Andernach) erfasst, die aufeinander bezogen werden müssen, um Rückschlüsse auf mögliche Fehlerquellen ziehen zu können.
- Der Herstellungsprozess von beschichteten Stahlbändern besteht aus einer komplexe Produktionskette, die das Band an verschiedenen Stellen verändert (es wird verformt, gedreht, getrennt und neu zusammengeschweißt) und dadurch die Materialverfolgung erschwert.
- Die auftretenden Qualitätsprobleme können die unterschiedlichsten Ursachen haben und durch verschiedene Anlagen der Prozesskette verursacht werden.
- Die prozessstufenübergreifende Einbeziehung von Domänenexpert:Innen bedarf eines Höchstmaßes an Transparenz bei der Ergebnispräsentation und einer großen Flexibilität bei der Nutzerinteraktion.

Um diesen Herausforderungen zu begegnen wurde das Vorgehen in vier wesentliche Schritte unterteilt. In den folgenden Seiten werden die einzelnen Schritte im Detail behandelt. Dabei werden sowohl


die grundlegenden Überlegungen zu den einzelnen Schritten geteilt und deren Relevanz anhand des Praxisbeispiels verdeutlicht.



1) DATENBEREITSTELLUNG & -QUALITÄTSSICHERUNG



2) KI-ENTWICKLUNG & -TRAINING



3) INTEGRATION IN BETRIEBLICHE PROZESSE



4) EVALUATION & KONTINUIERLICHE VERBESSERUNG

DATENBEREITSTELLUNG & -QUALITÄTSSICHERUNG

Im Rahmen der Datenbereitstellung & -qualitätssicherung geht es darum (1) relevante Datenquellen für das betriebliche Vorhaben zu identifizieren, (2) die Qualität der ausgewählten Daten sicherzustellen und (3) die technische Infrastruktur für eine nahtlose Datenübertragung und -speicherung einzurichten.

(1) Identifikation relevanter Datenquellen

Dafür empfiehlt es sich zunächst den Produktionsprozess dahingehend zu analysieren, welche Daten vorhanden sind und bereits genutzt werden. Gleichzeitig kann es hilfreich sein zu prüfen, welche Daten die Domänenexpert:innen

benötigen, um die Produktqualität zu bewerten. Entscheidend ist der Schritt der Datenselektion, in dem nur Daten berücksichtigt werden, die für die betriebliche Zielsetzung relevant sind.

AUSGANGSSITUATION IM PRAXISFALL HUMAINE

An beiden thyssenkrupp-Standorten in Andernach und Duisburg existierte bereits bei Projektbeginn jeweils eine Datenbank, in der die Daten verschiedener Datenquellen in einem einheitlichen Format und auf ein normiertes Maß der Stahlbänder abgelegt werden. Durch eine integrierte Materialverfolgung (so genanntes Tracking) werden die Daten automatisiert umgerechnet, sodass alle Daten für die Anlagen des entsprechenden Werks lagerichtig vorliegen und ausgewertet werden können, auch wenn die Daten gar nicht an dieser Anlage erfasst

wurden. Da neben den Prozessdaten auch die Qualitätsdaten dort abgelegt werden, können die Domänenexpert:innen bereits durch die gemeinsame Visualisierung der Daten eine Korrelation optisch herstellen und auf die Ursachen von identifizierten Qualitätsabweichungen schließen. Die Datenselektion spielte in diesem Beispiel eine untergeordnete Rolle, da diese bereits beim Aufbau der Datenbanken berücksichtigt wurde.

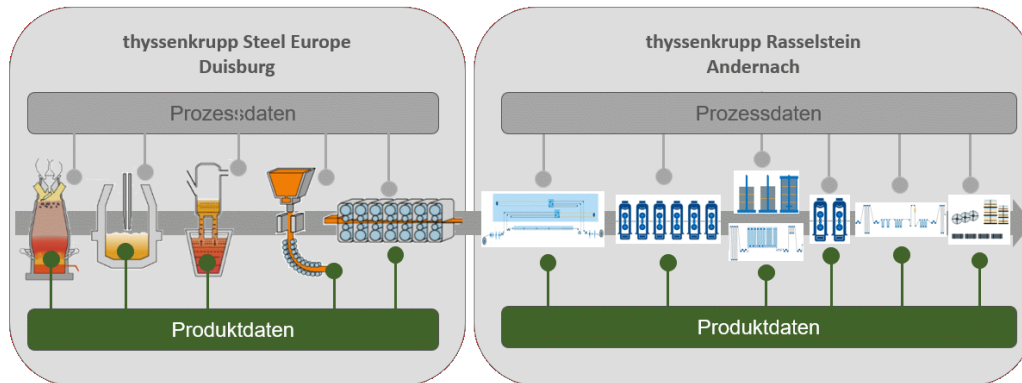


Abbildung 2: Erfassung von Prozess- und Produktdaten entlang der Prozesskette

(2) Sicherstellung der Datenqualität

Neben der grundsätzlichen Auswahl und Verfügbarkeit relevanter Daten spielt die Qualität der Daten eine entscheidende Rolle. Die Datenqualität kann z.B. durch Datenbereinigung und -harmonisierung verbessert werden. Im Zuge der Datenbereinigung werden fehlerhafte, inkonsistente oder unvollständige Daten entfernt. Die Datenharmonisierung dient dann dazu, dass Daten in eine

einheitliche und vergleichbare Struktur überführt werden, sodass sie z.B. für Datenanalysen verwendet werden können.

Im Praxisfall spielte insbesondere die Datenharmonisierung über die beiden thyssenkrupp Werke eine besondere Rolle. Dazu wurde zunächst ein Web-Service als Bindeglied zwischen den beiden Werken durch das BFI entwickelt.

DER WEB-SERVICE ALS BINDEGLIED ZWISCHEN ZWEI WERKEN

Die bisherige Auswertung von Prozess- und Qualitätsdaten beschränkte sich auf die einzelnen Werke. Um eine werksübergreifende Datensynchronisation und -auswertung zu ermöglichen wurde ein Web-Service entwickelt, der zwischen den existierenden Datenbanken der beiden Werke vermittelt (Abbildung 3). Die Firewalls beider Werke mussten entsprechend konfiguriert werden, so dass die Domänenexpert:innen auf die Daten

des jeweils anderen Werks zugreifen können. Dies betrifft sowohl die Verbindung des Web-Services zu den Datenbanken als auch die Berechtigung der beteiligten Personen. Als zeitraubende Teilaufgabe stellte sich das Tracking der Produkte zwischen den beiden Werken bedingt durch historisch gewachsene unterschiedliche Ansätze der Informationstechnik.

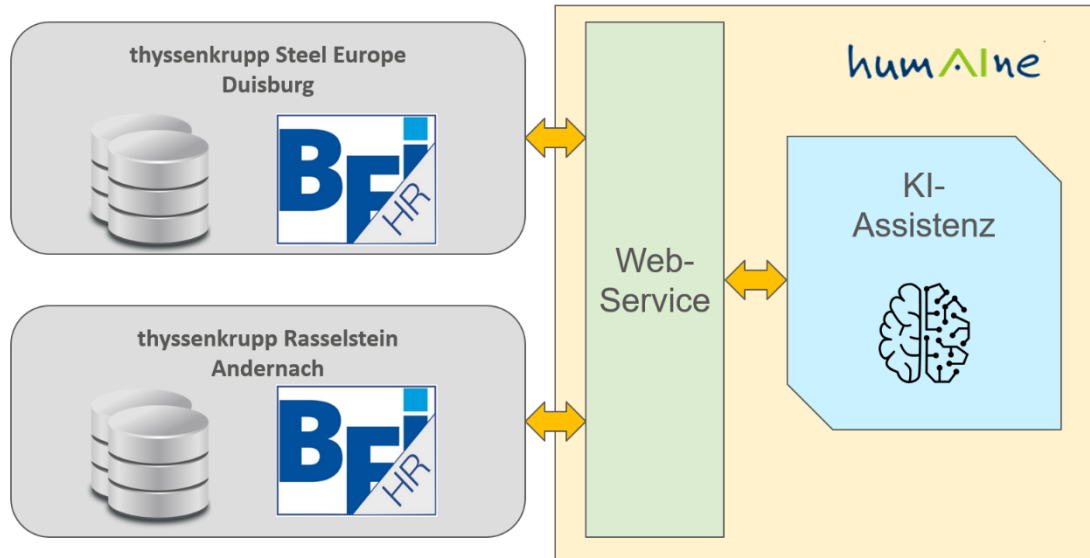


Abbildung 3: Web-Service als Verbindung der werkseigenen Datenbanken

Die nun technisch geschaffene Verbindung zwischen den Datenbanken der beiden Werke führte schnell zu einer neuen Herausforderung: **Die werks-/firmenübergreifende Datensynchronisation stellt besondere Anforderungen an die**

Datenqualität. Im Praxisfall wurden in den Werken unterschiedliche Datensysteme verwendet, sodass sich die Daten z.B. in Bezug auf ihre Benennung von Qualitätsfehlerklassen oder Anlagen unterschieden.

ANGLEICHUNG UNTERSCHIEDLICHER DATENBANKEN

Die beiden Werke in Duisburg und Andernach gehören zum thysenkrupp Konzern, haben aber jeweils eine lange Geschichte der Zugehörigkeit zu verschiedenen Unternehmen. Damit verbunden wurden die folgenden Herausforderungen identifiziert, die für die Umsetzung des Projektes behandelt bzw. harmonisiert werden mussten:

- unterschiedliches Namensschemata der Anlagen,
- unterschiedliche Identifikatoren für die Produkte,
- unterschiedliche Namen für die Qualitätsfehlerklassen,

- stark unterschiedliche Anzahl von Qualitätsfehlerklassen,
- unterschiedliche Umsetzung bei der Entwicklung der lokalen Datenbanken durch die Einschränkungen der Datenbanksoftware (z.B. konnten die Anlagennamen oder Messsignalnamen nicht in den Datenbanken als Spaltennamen verwendet werden, da hier Umlaute und Leerzeichen nicht zulässig sind und die Länge beschränkt ist)

Der Prozess der Datenharmonisierung war im Praxisfall sehr umfangreich und erforderte einen großen Aufwand. Dennoch war er unausweichlich, um anschließend zielgerichtete Rückschlüsse auf die Fehlerquellen für Qualitätsabweichungen treffen zu können.

Schließlich war es möglich die Datenbanken der beiden Werke zusammenzulegen und so Fehler rückverfolgen zu können. Im Endergebnis entstand daraus eine Lösung, die die manuelle Datenanalyse werksübergreifend ermöglicht. Es folgt ein kurzer Einblick in die Funktionsweise.

LÖSUNG ZUR WERKSÜBERGREIFENDEN DATENANALYSE

Die bereits erwähnten vorhandenen Datenbanken der beiden Werke sind vom gleichen Typ und haben auch die gleiche Benutzeroberfläche. Die Domänenexpert:innen selektieren zunächst eine Stichprobe von Stahlbändern für die weitere Analyse. Dazu werden Parameter wie Stahlsorte, Abmessungen, Kunden oder Aufträge gefiltert. Nach der Auswahl der Anlage, bei der die Untersuchung gestartet wird, werden noch die Qualitätsgröße sowie einige Prozessgrößen für die Visualisierung ausgewählt. Diese Selektion erfolgt durch die Domänenexpert:innen der Anlage, die für Gewöhnlich bereits einen Verdacht bezüglich der Ursachen für die Qualitätsabweichungen hat. *Abbildung 4* zeigt ein beispielhaftes Ergebnis einer

prozessstufenübergreifenden Analyse von schweren Fehlern aus Sicht der Stranggussanlage. Fehler, die am Warmbandwerk in Duisburg detektiert worden sind, sind in der unteren 2D-Darstellung (relativ über Bandbreite und Bandlänge) rot, während Fehler von der Beize in Andernach blau dargestellt sind. Für die Domänenexpert:innen-Strangguss ergibt sich eine transparente Fehlerdarstellung aus Sicht der Stranggussanlage in der schwere Fehler nahezu deckungsgleich dargestellt werden (Häufungen links und Mitte rechts). Er kann nun synchronisiert relevante Prozessgrößen darstellen, um die Fehlerursache ermitteln zu können. *Abbildung 4* zeigt hierzu exemplarisch die minimalen (grün) und maximalen Gießgeschwindigkeiten (rot).

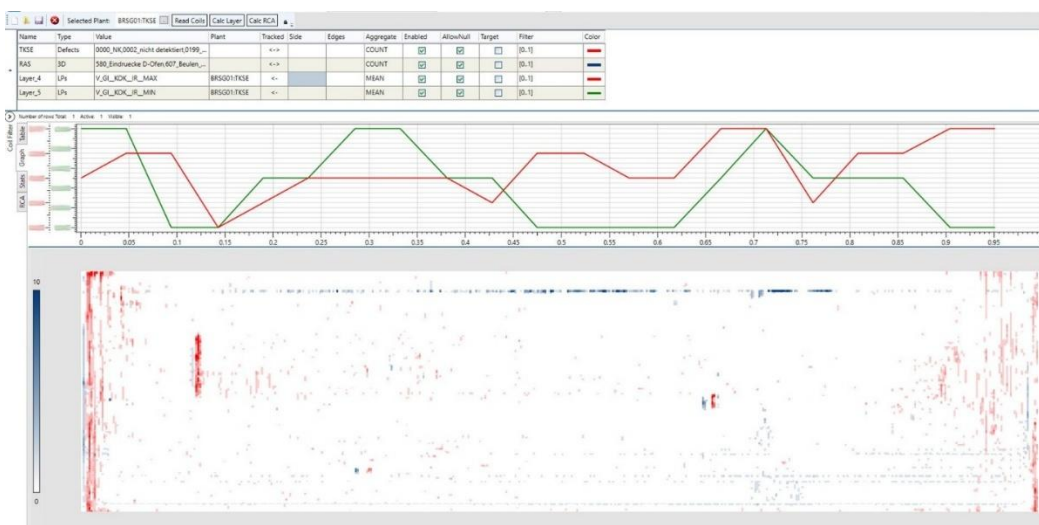


Abbildung 4: Benutzeroberfläche der HUMAINE-Lösung mit 2D-Darstellung der Fehler (unten) und der Prozesssignale der ausgewählten Anlage (oben)

Um den Schulungsaufwand zu verringern wurde die Lösung in die bestehende Oberfläche integriert. Die Anwender können nun in der für sie gewohnten Umgebung durch die Auswahl der Anlagen des jeweils anderen Werkes die Daten lage-richtig auf allen Anlagen der Prozesskette visualisieren. Dies erleichtert die werksübergreifende Zusammenarbeit

der Domänenexpert:innen enorm, da die Parameter, die für eine Darstellung verwendet wurden (z.B. verwendete Filter der Datenstichprobe), leicht geteilt werden können und dadurch alle die gleiche Darstellung erzeugen können. Darauf aufbauend kann dann die Untersuchung zur Ermittlung der Fehlerursachen durchgeführt werden.

KI-ENTWICKLUNG & -TRAINING

Der Einsatz von KI kann in der industriellen Produktion und insbesondere in der Qualitätssicherung neue Möglichkeiten eröffnen. KI ermöglicht es z.B. Qualitätsabweichungen frühzeitig zu erkennen, automatisierte Entscheidungen zu treffen und dadurch möglicherweise sogar Kosten durch Ausschuss, Nacharbeit oder Stillstände zu senken.

Abgesehen von fertig entwickelten KI-Lösungen, besteht auch die Möglichkeit unternehmensspezifische Lösungen zu entwickeln. Aufgrund der Komplexität des Praxisfalls und den spezifischen Anforderungen an eine KI-Lösung wurde im

Projekt die Entscheidung für eine eigens entwickelte Lösung getroffen. Die Anforderungen und Zielsetzungen der entwickelten Lösung werden im Folgenden skizziert.

ZIELSETZUNGEN DER KI-ANWENDUNG

1) Verursachende Anlage identifizieren

Die für den HUMAINE Pilot 6 vorgesehene KI-Anwendung verfolgt den Ansatz, in der zweidimensionalen Darstellung der Fehler automatisch auffällige Häufungen bzw. Strukturen zu identifizieren. Dies können starke Ansammlungen eines Fehlers am Anfang oder Ende des Stahlbandes sein, Streifen oder Spuren über Teile oder sogar die gesamte Bandlänge oder aber zyklisches Auftreten von

Fehlern. Dieses von einer zufälligen Verteilung abweichendes Auftreten ist für die Domänenexpert:innen ein Hinweis für eine vom Normalzustand abweichende Produktion. Diese Detektion soll die KI-Lösung an ausgewählten Anlagen für ausgewählte Produkt- bzw. Kundengruppen durchführen. Damit kann in einem ersten Schritt die verursachende Anlage identifiziert werden.




Abbildung 5: Die Häufigkeitsverteilung eines Oberflächenfehlers einer Vielzahl überlagerter Stahlbänder zeigt an der messenden Anlage keine Struktur (links). Die identischen Daten sind an der verursachenden Anlage strukturiert (rechts) was Rückschlüsse auf Prozessverlauf ermöglicht.

2) Fehlerursache ermitteln

Ist die Anlage identifiziert soll die KI-Lösung in einem zweiten Schritt versuchen, eine Korrelation des Fehlerbildes mit einer von den Domänenexpert:innen ausgewählte Menge von Prozesssignalen herzustellen. Dazu wird die zweidimensionale Darstellung durch Aggregation auf eine eindimensionale Darstellung

reduziert und mit den ausgewählten Signalen verglichen. Höhere Korrelationskoeffizienten weisen dann in diesem zweiten Schritt auf die potenzielle Ursache für den Fehler hin. Damit können die Domänenexpert:innen eine Untersuchung beginnen um die Ursachen zu ermitteln und abzustellen.

Aus dem Praxisfall wurde deutlich, dass die Vorarbeiten im Sinne der Datenbereitstellung und -qualitätssicherung von wesentlicher Bedeutung dafür sind, dass eine KI-Lösung entwickelt und im Betrieb eingesetzt werden kann. Insbesondere sind an dieser Stelle **folgende Voraussetzungen** zu erwähnen:

- Datenverbindung zwischen Anlagen/Werken herstellen
- Daten harmonisieren und anschließend detailliert prüfen
- Tracking von Produkten über mehrere Anlagen/Werke sicherstellen
- Ausreichende Stichprobengröße für das Modelltraining

Die Erfüllung dieser Voraussetzungen trägt dazu bei, dass die Güte der KI-Ergebnisse steigt und somit der Grundstein für eine verlässliche KI-Lösung gelegt werden kann.

Auch, wenn im Praxisfall keine vollständige Integration der KI-Assistenz in den Produktionsprozess stattgefunden hat, konnten entlang der Entwicklung einige Erkenntnisse gesammelt werden, die auch für andere industrielle Anwendungszwecke hilfreich sein können. Daher wird nun auf das Vorgehen der Entwicklung der KI-Assistenz genauer eingegangen.

ENTWICKLUNG EINER KI-ASSISTENZ

Ausgangssituation

Das Fallbeispiel beinhaltete konkrete Coil-Daten für die prüfende Anlage (Plant with OIS: POIS) und der verursachenden Anlage (Plant with Error-source: PSRC), auf denen sich Oberflächenfehler befinden. Diese Fehler sind in einer Art Bildstruktur kodiert, wobei die Anzahl der Fehler in einem Raster über die Coils gelegt wird und somit den Ort des Auftretens definiert. Obwohl es sich

nicht um Bilder im herkömmlichen Sinne handelt, ermöglicht die Art und Beschaffenheit der Daten Analysen im Kontext des maschinellen Sehens. Insgesamt kann die Problematik als Aufgabe der Anomalieerkennung verstanden werden. Die im Projekt verfolgte Lösungsstrategie wird als „Simple OCC“ bezeichnet, wobei ausschließlich Methoden der Anomaliedetektion angewendet werden.

1) Aufbereitung der Daten

Bevor die verschiedenen Methoden der Anomaliedetektion angewendet werden konnten, mussten die Daten zunächst spezifisch aufbereitet werden, um den letztlich zu simulierenden Fall, nämlich einen schleichenden systematischen Fehler, widerzuspiegeln. Zu diesem Zweck wurden der POIS- und der PSRC-Anteil fließend gemischt. Erste explorative Analysen zeigten, dass die Performance auf Einzelbildern nicht ausreichend war, da sich die Fehler dort nicht ausreichend ausprägten, um mit den zu untersuchenden Methoden zuverlässig detektiert werden zu können. Daher wurde eine Aggregation mehrerer Bilder zu einem Derivat vorgenommen. Mehrere Einzelbilder wurden mittels eines gleitenden und sich überlappenden Fensters aggregiert. Die Länge des Fensters (Parameter WL) und die Anzahl der fehlerhaften Samples im Fenster (Parameter Ne), ab der der aggregierte Wert insgesamt als Fehler/PSRC gewertet

wurde, wurden später untersucht, um festzustellen, welche Kombination die besten Ergebnisse liefert. Die aggregierten Bilder wurden dann auf $[0,1]$ normiert.

Im Laufe des Projektes stellte sich heraus, dass eine Analyse, die nur auf den Bilddaten basiert, mit den gewählten Algorithmen nicht zu einer ausreichend guten Performance führte. Aus diesem Grund wurden Meta-Features aus klar definierten Bereichen der Bilder extrahiert. Dazu wurden die Bilder in Regionen unterteilt, die sich zur Hälfte überlappen, um mögliche Randeffekte an den Rändern zu erfassen. Die Größe der Regionen ist variabel und dient im weiteren Projektverlauf als zu optimierende Hyperparameter. Die Metafunktionen sind Mittelwert, Standardabweichung und Entropie. Weitere Funktionen wie z.B. LBP (Local Binary Pattern) wurden untersucht, boten aber keinen Mehrwert.

2) Simple OCC

Bei diesem Ansatz wurde eine einfache One Class Classification (OCC) verwendet, die nur auf den POIS-Daten (Ground Truth) trainiert wurde. In der Praxis wurde dann geprüft, ob Samples von der Ground Truth abweichen und somit als Fehler klassifiziert werden konnten. Dieser allgemeine Ansatz erlaubte eine einfache Implementierung und in vielen Fällen auch eine einfache Erklärbarkeit der zugrundeliegenden Konzepte. Ein Nachteil war, dass bekannte Fehler hier nicht identifiziert werden konnten und die Fehlerausgabe daher unspezifisch war. Im Praxisfall wurde sich aus betrieblichen Gründen für ein unsupervised Ansatz entschieden.

Den meisten OCC-Ansätzen ist gemeinsam, dass die eigentlichen Vorhersagen nicht auf den Originaldaten, sondern auf einem transformierten Derivat getroffen werden. Eine gängige und hier verwendete Transformation ist die Dimensionsreduktion. Zahlreiche Dimensionsreduktionsverfahren wurden getestet (PCA, NNMF, KPCA, UMAP, Autoencoder) und hinsichtlich ihrer Fähigkeit bewertet, einerseits die Daten zu rekonstruieren und andererseits die beiden bekannten Anteile (POIS und PSRC) im Feature Space bestmöglich voneinander zu trennen. Von den ausgewählten Verfahren schnitten UMAP und der Autoencoder am besten ab. In erster Instanz wurde UMAP für die weiteren Berechnungen verwendet.

Neun unterschiedliche OCC-Modelle wurden dann ausgewählt. Als Grundlage wurde das PyOD toolkit genutzt, welches zahlreiche Verfahren der Anomaliedetektion zusammenfasst. Es wurde eine Mischung aus probabilistischen, linearen, proximity-based und Outlier Ensembles basierten Algorithmen verwendet. Konkret handelte es sich um: OCSVM (One-Class Support Vector Machines), LOF (Local Outlier Factor), IForest (Isolation Forest), ABOD (Angle-Based Outlier Detection), kNN (k Nearest Neighbors), COPOD (Copula-Based Outlier Detection), INNE (Isolation-based Anomaly Detection Using Nearest-Neighbor Ensembles), DIF (Deep Isolation Forest for Anomaly Detection), SOS (Stochastic Outlier Selection).

UMAP wurde dann gemeinsam mit den unterschiedlichen OCC-Modellen, der Entscheidung welche Regionen genutzt werden, sowie einer Auswahl an zusätzlichen Outlierbereinigungsverfahren, welche auf die Trainingsdaten angewendet werden, optimiert. Eine zusätzliche Outlierbereinigung wurde auf die Trainingsdaten angewandt, weil mit der OCC die "typische" Ground Truth gelernt werden sollte. Diese Optimierung wurde für jede Kombination von WL und Ne einzeln vorgenommen. Es wurden verschiedene Zielmetriken für die HPO (Hyperparameteroptimierung) ausgetestet, speziell der macro F1-Score und der F1-Score auf den fehlerhaften Daten (PSRC). Konkret wurde der F1-Score verwendet, weil in den Daten inhärent eine Imbalance zwischen POIS und PSRC besteht. Bei korrektem Betrieb würde es immer mehr gute als schlechte Daten geben. Zum Zwecke zusätzlicher Bewertungen wurden außerdem die Balanced Accuracy, sowie die macro und PSRC spezifischen Precision und Recall bestimmt.

Für die HPO wurde die BHO (Bayes'sche Hyperparameteroptimierung) verwendet. Die insgesamt Trainingsdauer beträgt 108 Stunden. Innerhalb der HPO wurden KFold (hier konkret 5 Folds) verwendet, um die Ergebnisse statistisch belastbarer zu machen. Die Parameter von UMAP wurden separat für die Trainingsdaten und die zusätzlichen Features optimiert und danach in einen gemeinsamen Featurevektor überführt. Die Trennung erlaubte UMAP sich spezifisch an die unterschiedlichen Inputdomänen anzupassen und somit bessere Repräsentationen der Daten zu erzielen. Außerdem wurden damit die distinkten Charakteristika sowohl der Pixel auf der einen als auch der zusätzlichen Features auf der anderen Seite bewahrt.

Im Nachgang wurden dann die Algorithmen hinsichtlich ihres macro F1-Scores geordnet, wobei die Dauer der Optimierung als zusätzliches weiches zweites Bewertungskriterium hinzugezogen wurde, im Falle von identischen Scores. Die so bestimmten optimalen Parameter wurden dann genutzt, um auf einem Testdatensatz eine finale Berechnung von macro F1-Score, F1-Score auf PSRC und Balanced Accuracy vorzunehmen. Für den Testdatensatz wurden zudem Bilder des Feature Spaces erstellt, wobei dort die POIS und PSRC-Samples entsprechend eingefärbt wurden, um eine visuelle Abschätzung der Leistung der verwendeten Methoden zu ermöglichen. Zusätzlich wurden die Übergangsbereiche (Werte die besonders nah an Ne liegen) gesondert eingefärbt, um abschätzen zu können, inwiefern dieser Übergang die insgesamt Leistung des Modells beeinflusst.

Abschließend wurden zwei weitere Typen von Grafiken erstellt. Die erste Art von Grafik vergleicht alle untersuchten

OCC-Modelle und deren Leistungen (macro F1-Score, macro Recall und macro Precision) für alle WL und Ne Kombinationen. Dies erlaubte eine vergleichende visuelle Beurteilung der Performance der verschiedenen Algorithmen für die WL/Ne Kombinationen. Die zweite Art von Grafik stellte den Verlauf der optimalen Werte für eine der spezifischen Metriken (Balanced Accuracy,

macro F1-Score, F1-Score auf PSRC, macro Precision, Precision auf PSRC, macro Recall und Recall auf PSRC) in Abhängigkeit von WL und Ne und unabhängig vom dahinterstehenden OCC-Algorithmus dar. Dies erlaubt übersichtlich global zu vergleichen, wie die einzelnen Kombinationen von WL und Ne im Vergleich zu den anderen performt haben.

3) GUI

Im Rahmen des Praxisfalls wurde auch eine Schnittstelle zwischen der neu entwickelten KI-Assistenz und den Nutzern in Form einer GUI erarbeitet. Der primäre Fokus lag nach Rücksprache mit den Domänenexpert:innen auf einer einfachen Bedienbarkeit der Applikation, welche die relevanten Informationen möglichst übersichtlich darstellen sollte. Diese Überlegungen flossen in das Design des GUI-Prototypen mit ein. Die erarbeitete GUI umfasst zwei primäre Wege der Kommunikation über mögliche auftretende Fehler. Zum einen wird beim Auftreten von Anomalien eine entsprechende, gut lesbare Fehlernachricht in Rot ausgegeben, die das Vorkommen mitteilt. Zum anderen wird gleichzeitig das Bild des entsprechenden Coils, welches den Alarm ausgelöst hat, angezeigt, sodass die Domänenexpert:innen

direkt bewerten kann, ob es sich um einen Fehler handelt oder nicht.

Dieser Ansatz hat mehrere Vorteile: Die Domänenexpert:innen werden nicht mit Informationen überhäuft, sondern ihm werden nur die relevantesten mitgeteilt. Die GUI, bzw. die KI-Assistenz an sich, bietet bewusst nicht die Möglichkeit autonom Entscheidungen zu treffen und Maßnahmen zu ergreifen, diese Verantwortung verbleibt in den Händen der Domänenexpert:innen. Es wird lediglich die Möglichkeit gegeben, mittels eines einfachen Buttons, entsprechende Stellen im Unternehmen durch vorgefertigte Nachrichten im Falle eines Fehlers zu benachrichtigen, sodass die Kommunikation über den Fehler schnell und unkompliziert in die Wege geleitet werden kann.

INTEGRATION IN BETRIEBLICHE PROZESSE

Eine KI-Lösung kann noch so gut entwickelt sein und dennoch an der Integration in betriebliche Prozesse scheitern. Letztlich ist dieser Schritt von besonderer Bedeutung, um eine KI-Lösung im Produktionsbetrieb nutzbar zu machen und deren Mehrwerte ausschöpfen zu können.

Daher ist es von besonderer Bedeutung die betriebsspezifischen Anforderungen an eine KI-Lösung frühzeitig zu eruieren. Im Praxisfall wurde dazu bereits zu einem frühen Zeitpunkt der intensive Austausch mit den Domänenexpert:innen gesucht, um zu ermitteln, wie eine KI-Lösung gestaltet werden müsste, um einen Mehrwert im Betrieb stiften zu können. Dabei geht es sowohl um die Abwägung bestimmter Funktionen als auch in Bezug auf die Gestaltung der Bedienoberfläche.

Je nach Praxisfall können verschiedene Faktoren dazu beitragen, dass die Integration erfolgreich ist. Dazu gehören:

- **Partizipation der Mitarbeitenden:** Eine frühe Einbindung der Mitarbeitenden ermöglicht es die KI-Lösung eng an den Bedürfnissen der Mitarbeitenden auszurichten und eine intuitive Benutzeroberfläche zu gestalten. Beide Aspekte fördern die Akzeptanz einer solchen Lösung.
 - **Anpassung an operative Abläufe:** Bei der Entwicklung einer KI-Lösung ist ein detailliertes Verständnis über operative Abläufe im Betrieb von besonderer Bedeutung. Durch diese Informationen kann ein Verständnis darüber
- aufgebaut werden aus welchen Gründen und zu welchen Zeitpunkten im Produktionsprozess eine KI-Lösung Domänenexpert:innen bestmöglich bei ihrer Arbeit unterstützen kann.
- **Technische Integration:** KI-Lösungen können entweder in bestehende Prozesse integriert werden und somit bestehende Lösungen der Datenverarbeitung/-analyse ergänzen oder eine vollständig neue Lösung darstellen und ggf. sogar bestehende Lösungen ersetzen. Beide Ansätze gehen mit unterschiedlichen Implikationen an die technische Entwicklung einher und sollten im Vorfeld genau abgesteckt werden.
 - **Schulung der Mitarbeitenden:** In Abhängigkeit davon, ob es sich um eine vollständig neue Lösung und eine Ergänzung bestehender Lösungen handelt, ist es notwendig Mitarbeitende im Umgang mit der KI-Lösung zu schulen. Der Schulungsbedarf ist von verschiedenen Faktoren abhängig und kann von einer kurzen Einführung bis hin zu spezifischen Workshops, die auch die Hintergründe von KI behandelt reichen.

Faktoren, die dafür entscheidend sind, sind z.B. die technischen Vorkenntnisse bzw. der Background der Mitarbeitenden, die Komplexität der KI-Lösung und in welchem Umfang die KI-Lösung bestehende betriebliche Abläufe verändert.

- **Transparente Kommunikation:** KI ist in aller Munde und kann daher bei Mitarbeitenden positive wie negative Assoziationen wecken. Entscheidend für eine hohe Akzeptanz der KI-Lösung ist eine frühzeitige Kommunikation darüber, dass eine KI-Lösung im Betrieb eingeführt werden soll und welche Intention mit der Einführung verbunden ist. Der

wahrgenommene Nutzen einer solchen Lösung für Mitarbeitende ist dabei ein entscheidendes Kriterium, ähnliche wie die Veränderungen, die sich in Bezug auf ihre Tätigkeit durch die Einführung ergeben können. Es kann helfen an dieser Stelle zu betonen, dass die KI-Lösung als eine Form der Unterstützung verstanden wird.

Die vorangegangenen Faktoren wurden im Praxisfall im Rahmen eines gemeinsamen Workshops mit den Domänenexpert:innen der beiden Werke thematisiert. Der Fokus lag dabei vor allem auf den Faktoren der Partizipation der Mitarbeitenden und der Anpassung der KI-Lösung an operative Abläufe

INTEGRATION IN BETRIEBLICHE PROZESSE IM PRAXISFALL

Partizipation der Mitarbeitenden

Die Integration der entwickelten Lösung in die betrieblichen Prozesse erfolgte durch Beteiligung der relevanten Mitarbeitenden an beiden Standorten. Dabei ist zunächst festzuhalten, dass die Lösung nur eine geringe Zahl der Beschäftigten direkt betrifft. Nur eine kleine Zahl

von Beschäftigten, die für bestimmte Teile des Produktions- und Qualitätssicherungsprozesses zuständig sind (Domänenexpert:innen) interagieren mit der entwickelten Lösung (Abbildung 6).




Abbildung 6: Domänenexpert:innen der an der Herstellung des Stahlbandes beteiligten Anlagen²

Das geeignete Ausmaß an Beteiligung der Domänenexpert:innen

(Beteiligungsgrad) wurde als moderat eingeschätzt, da die Lösung eher

² Quelle: <https://pixabay.com/de/>

kleinere Tätigkeitsbereiche (Ursachenanalyse von Fehlern) relativ zum gesamten Aufgabenspektrum der Domänenexpert:innen betraf. Ein substanzieller Eingriff der Lösung in die Arbeitsprozesse bestand somit trotz der umfangreichen Potenziale der Lösung nicht. Aus diesem Grund wurde im Praxisfall ein

workshopbasiertes Beteiligungskonzept gewählt, um die Eindrücke der Domänenexpert:innen zu sammeln. Ergänzt wurde dieses Format durch eng am Arbeitsprozess lokalisierte anlassbezogene Austausche, die bereits stattgefunden haben und weiter stattfinden werden.

Anpassung der KI-Lösung an operative Abläufe

Im Rahmen des Workshops wurden auch Anpassungsbedarfe der entwickelten Lösung an die operativen Abläufe im Betrieb thematisiert. Bislang wurden Qualitätsprobleme bei durch die Domänenexpert:innen bearbeitet. Dabei lassen sich zwei Fälle voneinander unterscheiden:

- **Bekanntes Problem** wurden direkt bearbeitet.
- **Unbekannte Probleme** wurden in regelmäßigen Gesprächen unter den Verantwortlichen

diskutiert und potenzielle Ursache in einer anschließenden Recherche ermittelt. Wird die Ursache des Problems im jeweils anderen Werk vermutet, nehmen die Domänenexpert:innen direkten Kontakt mit den bekannten Personen über Telefon oder E-Mail auf. Diese ermitteln die Ursachen, stellen diese ab und geben entsprechendes Feedback. In der folgenden Abbildung 7 ist dieses Vorgehen dargestellt.

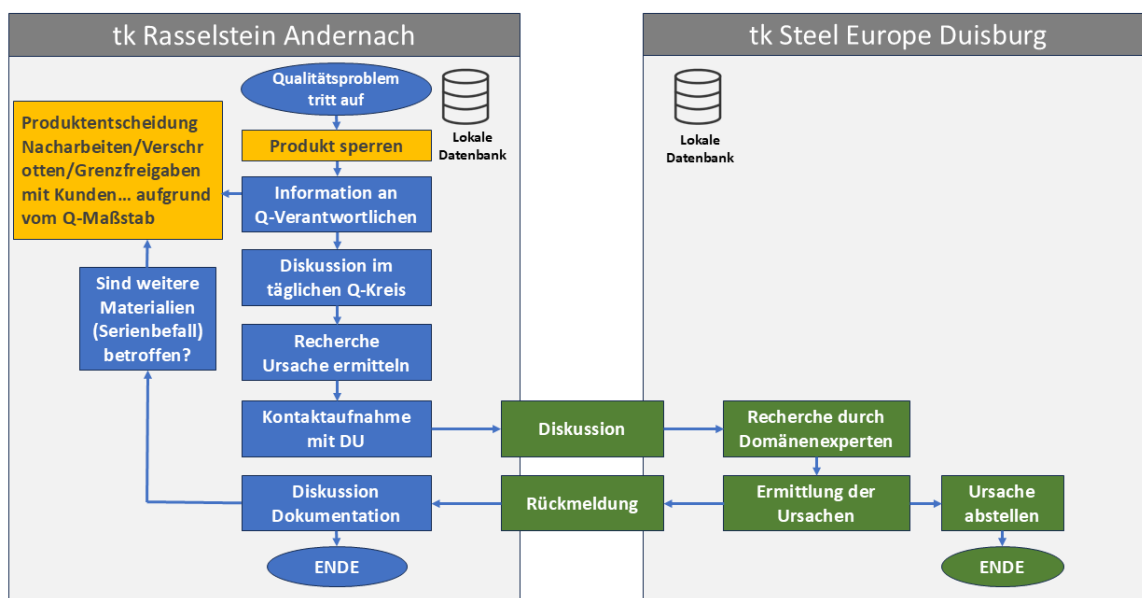


Abbildung 7: Schritte bei der werksübergreifenden Bearbeitung von Qualitätsproblemen durch die Domänenexpert:innen

Die entwickelte Lösung ergänzt den bestehenden Prozess und unterstützt die Mitarbeitenden an verschiedenen Stellen des Vorgangs. Bereits bei der Recherche der Ursachen ermöglicht das neue System einen einheitlichen, transparenten Zugriff auf alle verfügbaren Daten der beteiligten Anlagen in beiden Werken. Gerade die werksübergreifende Verfügbarkeit der Informationen und Ergebnisse, die auf der gleichen Datenbasis erzeugt wurden und für alle Beteiligten nachvollziehbar sind, erleichtert und beschleunigt die Diskussion erheblich.

Hierbei ist die Ermittlung der Zuständigkeit durch die transparente und sachliche Analyse entlang der Prozesskette eine deutliche Verbesserung gegenüber der bisherigen Praxis. Weiterhin können die Vorgänge abgelegt und für einen späteren Vorgang leicht reproduziert werden, sodass die früher durchgeführten Maßnahmen, die zu einer Lösung beigetragen haben, für alle Beteiligten jederzeit eingesehen werden können. Die folgende Abbildung 8 zeigt die Einbindung der Lösung in die operativen Prozesse.

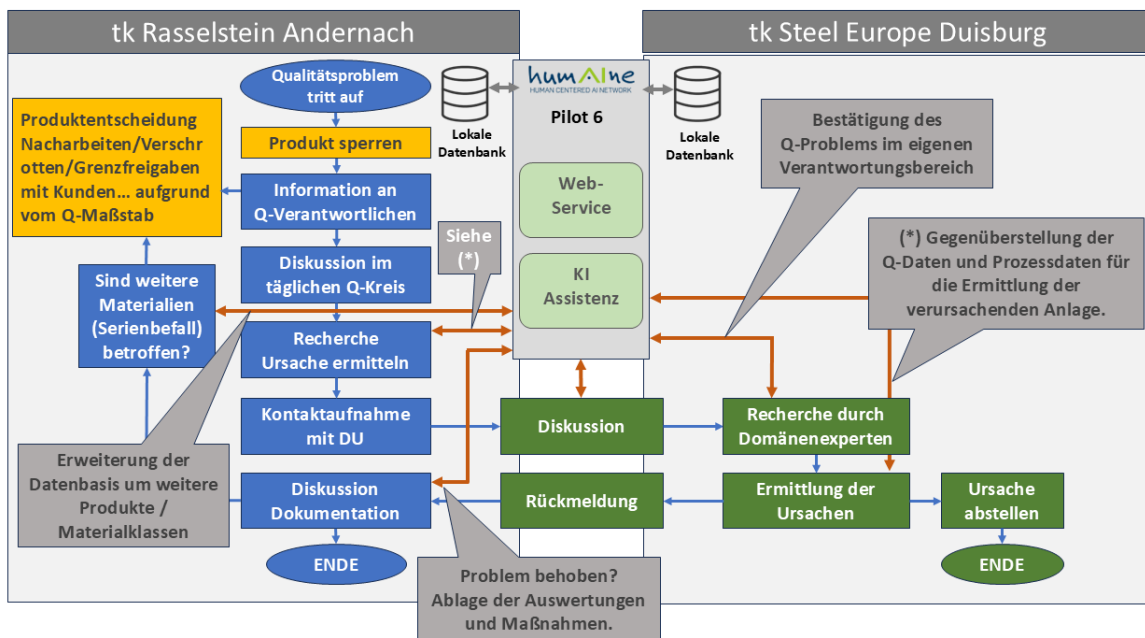


Abbildung 8: Einbindung der HUMAINE-Lösung in die werksübergreifenden operativen Prozesse der Domänenexpert:innen

Akzeptanz der entwickelten Lösung

Aus der Zusammenarbeit mit den Domänenexpert:innen der beiden Werke wurde gleich zu Beginn deutlich, dass keine Akzeptanzvorbehalte vorhanden waren. Die beteiligten Personen sind über jede Unterstützung dankbar, die sie bei der täglichen Arbeit entlastet. Gerade in der derzeitigen Situation von zunehmender Arbeitsverdichtung und gleichzeitiger Informationsflut bei steigenden

Anforderungen z.B. durch den zunehmenden Wettbewerb werden alle Hilfsmittel gerne angenommen. Dieser Fall ist nicht auf alle betrieblichen Kontexte übertragbar, unterstützt allerdings den Punkt, dass eine KI-Lösung, deren Mehrwert für die Mitarbeitenden klar ersichtlich ist, mit weniger Akzeptanzvorbehalten verbunden sein kann.

Schulung der Mitarbeitenden

Da die entwickelte Lösung nahtlos in die bestehende Benutzeroberfläche integriert wurde, ist der Schulungsaufwand im Vergleich zu einer vollständig neuen Lösung geringer. Der wesentliche Schulungsbedarf entstand im Praxisfall vielmehr aus Abweichungen, die sich z.B. bei der Selektion von Anlagen und

Messsignalen über beide Werke ergeben, wobei trotz gleichem physikalischem Inhalt in den Benutzeroberflächen der Werke unterschiedliche werkspezifische Benennungen gewählt wurden. Für die effektive Zusammenarbeit der Domänenexpert:innen ist an dieser Stelle weitere Schulungsaufwand notwendig.

EVALUATION & KONTINUIERLICHE VERBESSERUNG

Die Einführung eines KI-Assistenzsystems ist kein einmaliges Projekt, sondern der Beginn eines kontinuierlichen Entwicklungsprozesses. Erst im produktiven Einsatz zeigt sich, wie gut ein Modell tatsächlich performt, wo es Mehrwerte schafft – und wo es noch Verbesserungspotenzial gibt.

Ein zentraler Aspekt dabei ist die **regelmäßige Überprüfung der Modellleistung anhand realer Produktionsdaten**. Nur durch den Abgleich mit der Praxis lässt sich bewerten, ob die getroffenen Vorhersagen zutreffen, ob Reaktionszeiten optimiert werden konnten oder ob Qualitätsabweichungen nun früher erkannt und vermieden werden.

Darauf aufbauend sollte eine **kontinuierliche Optimierung der Algorithmen** fest im Betrieb verankert sein. Neue Daten, geänderte Prozessbedingungen oder saisonale Effekte können Einfluss auf die Aussagekraft der KI haben –

entsprechend müssen Modelle regelmäßig nachtrainiert, angepasst oder erweitert werden.

Ein besonders wirkungsvoller Hebel ist die **enge Rückkopplung mit den Fachbereichen**: Das Feedback der Mitarbeitenden aus Produktion, Instandhaltung oder Qualitätsmanagement liefert wertvolle Hinweise, wie das System noch besser an die betrieblichen Abläufe angepasst und die Nutzbarkeit erhöht werden kann. Diese Rückmeldungen sollten systematisch erfasst und in zukünftige Weiterentwicklungen einbezogen werden.

Weiterentwicklungen im Praxisfall

Aus den Diskussionen im Rahmen des Workshops wurden einige Anforderungen gesammelt für die Weiterentwicklung der Lösung gesammelt. Die wesentlichen Anforderungen sind:

- Die KI-Lösung muss bei der Handhabung der sehr großen Datenmenge sowie der komplexen Zusammenhänge (z.B. wie bei der Materialverfolgung) unterstützen. Beides

kann nicht mehr manuell gehandhabt werden.

- Durch ein automatisches Monitoring der Daten soll die KI-Lösung automatisch und frühzeitig Qualitätsabweichungen erkennen und durch zielgerichtete Alerts die Bearbeitung anstoßen.
- Die KI soll schnell und transparent kausale

Zusammenhänge aus der sehr großen Datenmenge automatisch ermitteln.

- Die Domänenexpert:innen sollen von wiederholenden Aufgaben entlastet werden. Die gewonnene Zeit muss für andere Aufgaben eingesetzt werden, bei denen deren Kompetenz gefordert ist.

- Über vereinfachte Schnittstellen sollen die Experten gemeinsam an der Ursachenermittlung arbeiten und schnell Lösungen bereitstellen können. Deren schnelle Umsetzung wirkt sich direkt auf die Produktivität aus.

Diese Anforderungen werden durch die im Praxisfall beteiligten Partner in weiteren gemeinsamen Projekten adressiert.

Ein langfristig effektives KI-System lebt von der stetigen Weiterentwicklung – sowohl technisch als auch organisatorisch. Unternehmen, die dies als Teil ihrer

Innovationskultur verstehen, schaffen die Grundlage für langfristigen Erfolg und nachhaltige Wettbewerbsfähigkeit.

SCHLUSSWORT

Die Einführung von KI-gestützten Assistenzsystemen in der industriellen Produktion ist kein rein technisches Projekt – sie ist ein gemeinsamer Lernprozess, der das Zusammenspiel von Mensch, Technologie und Organisation erfordert. Wie unser Beispiel aus dem Stahlwalzprozess zeigt, liegt der Schlüssel zum Erfolg nicht nur in der Entwicklung leistungsfähiger Algorithmen, sondern vor allem darin, das vorhandene Erfahrungswissen sinnvoll zu integrieren und interdisziplinäre Zusammenarbeit zu fördern.

Dieser Leitfaden möchte Unternehmen dazu ermutigen, eigene KI-Initiativen strukturiert anzugehen und dabei auf ein praxiserprobtes Vorgehensmodell

zurückzugreifen. KI kann – richtig eingesetzt – dazu beitragen, Produktionsprozesse robuster, effizienter und nachhaltiger zu gestalten, ohne die Expertise der Mitarbeitenden zu ersetzen, sondern sie gezielt zu unterstützen.

Wenn Sie Fragen haben, den Austausch suchen oder Unterstützung bei der Umsetzung benötigen, kommen Sie gerne auf uns zu. Wir freuen uns auf den Dialog und darauf, gemeinsam die Potenziale von KI in der industriellen Praxis weiter zu erschließen.

ANSPRECHPARTNER

Das Pilotprojekt wurde in enger Zusammenarbeit des Instituts für Neuroinformatik (INI), des Instituts für Arbeitswissenschaft (IAW) der Ruhr-Universität Bochum, dem VDEh-Betriebsforschungsinstitut (BFI) und thyssenkrupp erarbeitet.



Norbert Holz knecht

Abteilungsleiter „Qualitätstechniken und Automatisierung“, VDEh-Betriebsforschungsinstitut (BFI)



Jens Brandenburger

Senior Expert, VDEh-Betriebsforschungsinstitut (BFI)



Dr. Valentin Langhoff

Wissenschaftlicher Mitarbeiter am Institut für Arbeitswissenschaft



Niklas Obermann

Wissenschaftlicher Mitarbeiter am Institut für Arbeitswissenschaft und Projektkoordinator HUMAINE



KONTAKT:

HUMAINE

<https://humaine.info/>

humaine-projekt@rub.de