

bridgefield GmbH • Jerichower Straße 28 – 30 • 39114 Magdeburg

**Deutsches Zentrum für Luft- und Raumfahrt
e.V. (DLR), DLR-Projektträger
Rosa-Luxemburg-Str. 2
10178 Berlin**

Datum: 30.07.2024
Ansprechpartner: Prof. Dr. Frank Ortmeier
Tel.: +49 391 792930-15
E-Mail: frank.ortmeier@bridgefield.de

Sachbericht zum Verwendungsnachweis AI-PAT

Verbundprojekt: KI-basierte nutzerzentrierte Produktions-Assistenz-Toolbox

Teil I - Darstellung des Projektergebnisses

FKZ: 01IS21051A

PT-Bearb.: Dr. Totz

Laufzeit des Vorhabens: 01.09.2021 - 29.02.2024

Berichtszeitraum: 01.09.2021 - 29.02.2024

1. Aufgabenstellung und Stand der Wissenschaft und Technik

Das Ziel des Projektes AI-PAT war die Entwicklung und die Anwendung von KI-Assistenzsystemen für Produktionssysteme zur Steuerung und Optimierung der Prozesskette anhand eines spezifischen Szenarios. Die umfasst das Training entsprechender KI-Systeme als auch die Interaktion zwischen Mensch und KI.

Seitens des **IWF der TU Braunschweig** wurde dafür ein Framework zur automatischen Analyse von Rohdaten und anschließende Verarbeitung in ein KI-Modell entwickelt, das die Schritte möglichst einfach verständlich und anwendbar visualisiert. Mit dem Framework können zum einen Rohdaten in ein für KI-Modelle geeignetes einheitliches Format transformiert, zum anderen kann auf Basis dieser Daten eine Auswahl von Modellen trainiert werden. Diese können dann schließlich in einem Assistenzsystem zur Vorhersage der Bauteilqualität anhand von Prozessparametern genutzt werden können. Der Anwendungsfall für den Aufbau des Frameworks umfasst Produktions- und Qualitätsdaten für die Prozesskette eine Aluminium-Kokillengießerei. Die Daten wurden vom Unternehmen Volkswagen zur Verfügung gestellt und umfassen Zeitreihendaten sowie eine binäre Klassifizierung der Bauteilqualität. Ziel der Vorhersagen war die Identifikation von Wirkzusammenhängen in den Daten und damit in der Prozesskette, um frühzeitig die Bauteilqualität vorherzusagen und gleichzeitig Erkenntnisse für die Steuerung der Prozesse zu gewinnen. Das entwickelte Framework wurde anhand auf reale Prozessdaten aufgebaut, getestet und validiert, um so einen für den Prozess optimierten Assistenten zu konstruieren. Hierfür wurde neben der reinen Modellierung eine Plattform zur Visualisierung des Modellierungsprozesses sowie der Ergebnisse entwickelt. Dieser kann als Assistenzsystem verwendet werden. Darauf aufbauend wurde eine Methodik entwickelt, die eine Übertragung des Frameworks und der Modellierungsroutinen auf zukünftige Szenarien ermöglicht.

Die **bridgefield GmbH** arbeitete unterstützt durch die **METOP GmbH** an der Erfassung, Speicherung und Vorverarbeitung der Daten aus den Anlagen sowie der allgemeinverständlichen Darstellung der KI-Vorhersagen sowie der Interaktion mit den Werkern und anderen Anwendern. Dafür wurde ein Framework zur Datenerfassung und -speicherung erstellt, aber auch prototypische Frontends (Widgets¹) konzipiert und implementiert. Dabei lag der Schwerpunkt auf der einheitlichen KI-nutzbaren Speicherung der erfassten Daten unabhängig vom genauen Produktionsprozess. So ist es je nach Produkt-Typ möglich, dass Stationen durchlaufen werden oder nicht. Dennoch ist das System in der Lage die erfassten Daten über alle Produkte und Anlagen hinweg so zu speichern, dass Daten mit gleicher Bedeutung auch vergleichbar bleiben.

Im Frontend ging es hingegen darum, die Vorhersagen der KI-Modelle für die Anwender nutzbar und leicht erfassbar zu machen. Dafür wurden entsprechende Darstellungs- und Interaktionsmethoden entwickelt, die den Umgang mit der KI für Domänenexperten erleichtern sollen.

2. Ablauf des Vorhabens

Das Vorhaben startete aufgrund von Änderungen im Konsortium zwischen den einzelnen Partnern zeitversetzt. Während das IWF bereits mit der Arbeit am KI-Framework begann, wurden erste Arbeiten zur

¹ Kleine grafische Elemente, die Informationen darstellen und oder Eingaben ermöglichen

Anforderungsanalyse durch bridgefield durchgeführt. Die Arbeiten der METOP GmbH konnten jedoch erst später beginnen, da die METOP erst nachträglich in das Konsortium eingetreten ist. Aufgrund der Abhängigkeiten der Arbeiten von bridgefield und METOP verzögerten sich auch bei bridgefield einige Arbeiten.

Nach der Klärung der neuen Zusammensetzung und Arbeitsaufteilung im Konsortium konnte die Anforderungsanalyse erfolgreich abgeschlossen werden und in die Konzeptionsphase übergehen. Ab dieser Phase gab es regelmäßige virtuelle Jourfix-Meetings und Projekttreffen, die zur Synchronisation der Arbeiten dienten. Die Implementierungsphase teilte sich schließlich in die grundlegende Implementierung der Prototypen sowie dem Test und der Anpassung an der Use-Case Gießerei. Dabei wurden anhand von Tests soweit erforderlich Anpassungen an der ursprünglichen Implementierung vorgenommen.

3. Projektergebnisse

Das System zur Datenerfassung sowie das semantische Datenmodell wurden anhand von Anforderungsanalysen und Kenntnissen aus vorangegangenen Arbeiten und mit Blick auf den Use Case KI erstellt und optimiert. Dabei kam der Vergleichbarkeit der Daten aus unterschiedlichsten Produktionsabläufen eine besondere Bedeutung zu. Dies wurde erreicht, indem die erfassten Daten in kleine Teile (Events) zerlegt wurden, die einzelnen Punkten der Produktionslinie zugeordnet werden können. Die Events selbst sind verkettbar, um so den Produktionsablauf wiederzugeben. Dabei ist es möglich, dass ein oder mehrere Produktionsschritte für bestimmten Produkte übersprungen werden, ohne dass die Vergleichbarkeit dadurch beeinflusst wird. Dies erlaubt den Vergleich unterschiedlichster Produktionsprozesse in einem Werk und erlaubt den KI-Assistenten den Zugriff auf eine größere Menge vereinheitlichter, konsistenter Trainingsdaten.

Das angestrebte KI-Framework wurde vom **IWF** erfolgreich entwickelt und auf Prozessdaten eines beispielhaften Kokillengussprozesses angewandt. Die Entwicklung basiert auf einer umfassenden Recherche des Stands der Technik und Forschung. Das Framework umfasst die methodischen Ansätze anhand der Vorgehensweise CRISP-DM sowie die Beschreibung der notwendigen Schritte inklusive einer Auswahl der möglichen und empfohlenen Ansätze zur Umsetzung. Weiterhin umfasst das Framework die praktische, webbasierte Umsetzung der Ansätze in Form von einer Python-basierten App-Anwendung. Diese Anwendung stellt eine Toolchain bereit, die die Aufbereitung von Daten, sowie eine erste Analyse derer ermöglicht und anschließend eine Vielzahl an Modellen des Machine Learnings zulässt, die auf diese Daten trainiert und verglichen werden können. Die Toolchain wurde in der App-Umgebung grafisch aufbereitet, sodass eine vereinfachte Anwendbarkeit gewährleistet wird. Eine fokussierte Art des Machine Learnings ist das Transfer Learning, welches in das Framework integriert und getestet wurde. Die Validierung des Frameworks erfolgte anhand der bereitgestellten Produktionsdaten.

Die Nutzbarkeit der KI-Vorhersagen hängt entscheidend von der Darstellung und der Interaktion zwischen KI und Anwender ab. Daher wurden durch bridgefield aufbauend auf einer Anforderungsanalyse unter Einbeziehung der Anwender entsprechende Widgets konzipiert und prototypisch umgesetzt. Diese Widgets zielten in erster Linie darauf ab, die Interaktion der Anwender mit der KI so nah wie möglich an bekannte domänenspezifische Interaktionen anzulehnen, um die Hürde zur Interaktion mit der KI so niedrig wie möglich zu halten.

bridgefield GmbH • Jerichower Straße 28 – 30 • 39114 Magdeburg

Deutsches Zentrum für Luft- und Raumfahrt

e.V. (DLR), DLR-Projektträger

Rosa-Luxemburg-Str. 2

Datum: 30.07.2024

Ansprechpartner: Prof. Dr. Frank Ortmeier

Tel.: +49 391 792930-15

E-Mail: frank.ortmeier@bridgefield.de

Sachbericht zum Verwendungsnachweis AI-PAT

Verbundprojekt: KI-basierte nutzerzentrierte Produktions-Assistenz-Toolbox

Teil II – Ausführliche Darstellung der Rahmen des Vorhabens durchgeführten Arbeiten

Das diesem Bericht zugrunde liegende Vorhaben wurde mit Mitteln des Bundesministeriums für Bildung und Forschung unter dem Förderkennzeichen 01IS21051A, 01IS21051D und 01IS21051E gefördert. Die Verantwortung für den Inhalt dieser Veröffentlichung liegt bei der Autorin/beim Autor.

FKZ: 01IS21051A PT-Bearb.: Dr. Totz

Partner: bridgefield GmbH, TU Braunschweig (IWF), METOP GmbH

Laufzeit des Vorhabens: 01.09.2021 - 29.02.2024

Berichtszeitraum: 01.09.2021 - 29.02.2024

1 Durchgeführte Arbeiten im Vergleich zur ursprünglichen Vorhabenbeschreibung

Das Ziel des Projektes AI-PAT war die Entwicklung und die Anwendung von KI-Assistenzsystemen für Produktionssysteme zur Steuerung und Optimierung der Prozesskette anhand eines spezifischen Szenarios. Die umfasst das Training entsprechender KI-Systeme als auch die Interaktion zwischen Mensch und KI. Das Projekt AI-PAT hat als Ziel, mit Hilfe künstlicher Intelligenz Produktionsassistenten zu schaffen, die den Werker in seiner Arbeit unterstützen, ohne ihm die Entscheidungskompetenz abzunehmen. Die dafür notwendige Interaktion kann vielfältig sein und hängt stark von der gewünschten Unterstützung sowie der Tätigkeit des Werkers ab. So kann ein Prüfassistent z. B. auf der Grundlage des gelernten Verhaltens verschiedener Prüfer das Ergebnis einer Sichtprüfung¹ vorhersagen und dem Prüfer als Vorschlag präsentieren. Die Interaktion kann aber auch dahingehend erfolgen, dass die KI abwartet, bis der Prüfer selbst ein Prüfergebnis eingegeben hat, um dieses Ergebnis mit der Vorhersage zu vergleichen und nur im Fall der Abweichung mit dem Prüfer zu interagieren und ihn/sie zu bitten, die Prüfung ggf. nochmal detaillierter durchzuführen.

1.1 Arbeitspakete

Nachfolgend werden die Ergebnisse der einzelnen Arbeitspakete erläutert. Durch die nach dem Projektstart erfolgten Änderung der Zusammensetzung des Konsortiums, wurden verschiedene Inhalte neu zugeordnet. Auf die entsprechenden Abweichungen wird bei der Beschreibung der einzelnen Arbeitspakete eingegangen.

AP 1. Anforderungen für nachvollziehbare, nutzer-zentrierte AI-basierte Assistenz

Im Rahmen des UPA 1.1 (User-Research) wurden Untersuchungen durchgeführt, die folgende Bereiche umfassten:

- Nutzeranforderungen im Produktionskontext
 - Interaktion/Interaktives Dashboard
 - Informationsvisualisierung
- Anforderungen an die Datenerfassung im Produktionskontext
 - Sensordaten
 - Produktionsdaten
- Anforderungen an die Datenhaltung im KI-Kontext

¹ Unter Sichtprüfung wird im Gießereikontext die visuelle Prüfung der Oberfläche eines Produktes durch einen menschlichen Prüfer im Hinblick auf bspw. Risse, Lunken o. Ä. verstanden.

Das **UAP 1.1** befasste sich mit den Nutzeranforderungen. Die hier gewonnenen Erkenntnisse sind sowohl evidenzbasiert als auch aus Befragungen hervorgegangen. Im Ergebnis entstand eine Zusammenfassung der wichtigsten Anforderungen aus Nutzersicht.

Hierzu zählen:

- Augenschonende Lesbarkeit in dunkler Umgebung
- Bedienbarkeit aller Systeme unter Produktionsbedingungen (bspw. mit Sicherheitshandschuhen)
- Domainspezifische Visualisierung von Informationen (bspw. Temperaturdaten dargestellt auf der visualisierten Kokille)
- Einfache, effiziente Erfassbarkeit der visualisierten Informationen
 - Verwendung bekannter Visualisierungs- und Interaktions-Metaphern
 - Klare Aufbereitung der aktuell benötigten Informationen

Aufbauend darauf wurden im **UAP 1.2** Anforderungen an KI-basierte Produktionsassistenten abgeleitet. Die sich daraus ergebenden Anforderungen nebst Lösungsansatz und Bewertung sind in Tabelle 1 beispielhaft aufgelistet.

Anforderung	Lösungsansätze	Priorität	Komplexität
Lesbarkeit in dunkler Umgebung	<ul style="list-style-type: none"> • dunkle Themes mit hohem Kontrast • lesbarer Schriften in passender Schriftgröße • mechanische Eingabemöglichkeiten 	hoch	gering
Bedienbarkeit unter Produktionsbedingungen	<ul style="list-style-type: none"> • Auswahl von Touchscreens, die sich mit Handschuhen bedienen lassen • Verwendung großer Buttons, die sich mit Handschuhen zweifelsfrei treffen lassen • Tabbasierte Navigation statt Scrollen • Beschränkung der notwendigen Eingaben auf ein Minimum 	hoch	mittel
Domainspezifische Visualisierung von Informationen	<ul style="list-style-type: none"> • Darstellung von Informationen basierend auf der Abbildung realer Produkte / Maschinen 	mittel	mittel
Einfache, effiziente	Verwendung bekannter Visualisierungs- und Interaktions-Metaphern	hoch	mittel

Erfassbarkeit der visualisierten Informationen	Klare Aufbereitung der aktuell benötigten Informationen	hoch	hoch
--	---	------	------

Tabelle 1: Beispielhafte Anforderungsübersicht

Während sich die beiden erstgenannten Anforderungen recht gradlinig realisieren lassen, steigt die Komplexität der Umsetzung der weiteren Lösungsansätze durch Spezifika, die sich aus der jeweiligen Domain ergeben deutlich an.

Da eine Anpassung der Visualisierung von Informationen zwar bis zum Eintreten der Gewöhnung an die neue Darstellung einen negativen Einfluss auf die Effizienz haben kann, dann jedoch zum Normalfall wird, wurde hierfür nur eine mittlere Priorität angesetzt. Anders sieht es hingegen bei der Verwendung bekannter und Interaktions-Metaphern aus. Hier kommt das motorische Gedächtnis ins Spiel, das erlernte Bewegungsmuster situationsabhängig instinktiv wiederholt. Dies wiederum kann zu Fehlbedienungen oder Fehleingaben führen.

Die Anforderung mit der höchsten Umsetzungscomplexität stellt die klare Aufbereitung der aktuell benötigten Informationen dar. Hier muss im Kontext der aktuellen Domain, des Arbeitsplatzes (Anlage/Maschine) sowie des aktuellen Arbeitsschrittes entschieden werden, welche Informationen relevant sind und wie diese darzustellen sind. Diese Anforderung erstreckt sich somit über eine örtliche, zeitliche und inhaltliche Dimension. Bspw. benötigt ein Gießer an einer Lineargießanlage teilweise andere Informationen als ein Gießer an einer Druckgießanlage.

Dies setzt ein geeignetes Datenmodell voraus, das die genannten Dimensionen mit den geeigneten Informationen in Relation setzt. Darüber hinaus bietet sich aufgrund der Komplexität der Zusammenhänge der Einsatz KI-basierter Verfahren an, die jedoch auf eine entsprechende Menge Trainingsdaten angewiesen sind.

AP 2. Entwicklung semantisches Datenmodell

Das in **UAP 2.1** entwickelte semantische Datenmodell stellt die Grundlage für das Training sowie den Einsatz der Künstlichen Intelligenz (KI) dar. Das Modell, dessen Struktur in Abbildung 1 dargestellt ist, bildet Graphen strukturell auf relationale Datenbanken ab. Es basiert auf der Erfassung verschiedener Typen von Events aus der Produktion und erlaubt damit die Bearbeitung der Produkte in beliebig langen Produktionsketten detailliert zu erfassen sowie deren Evolution vom Rohmaterial bis zum finalen Produkt aufzuzeichnen. Auf die Bedeutung der verschiedenen Eventtypen wird in der Beschreibung zu AP 3 näher eingegangen.

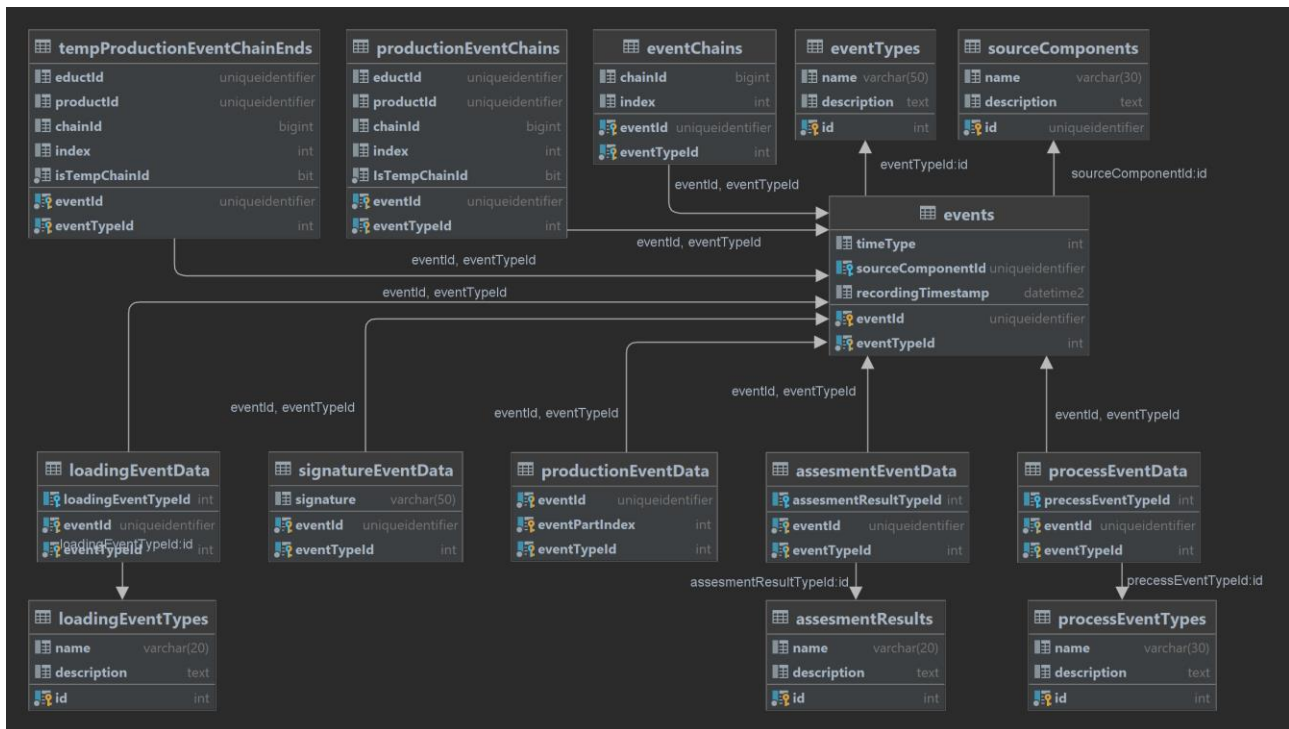


Abbildung 1: Darstellung der Struktur des semantischen Datenmodells

Dem realen Produktionsprozess folgend, durchlaufen die Produkte verschiedene Schritte, in denen sie in unterschiedlichen Detailgraden erfasst werden können. Diese Erfassung kann je nach Produktionsschritt auf Einzelteilebene aber auch aggregiert als Charge aus mehreren hundert Bauteilen erfolgen. Abbildung 2 soll dies beispielhaft veranschaulichen. Hier startet ein Produktionsprozess bspw. mit 2 Gussteilen (Bauteilzwillingen), die im dritten Arbeitsgang jeweils durch Zersägen in einzelne Gussteile aufgetrennt werden. Im sechsten Schritt werden mehrere der bis hierhin bearbeiteten Bauteile gemeinsam als Charge einer Wärmebehandlung unterzogen.

Innerhalb der Wärmebehandlung gelten werden Bauteile im Produktionsprozess technisch wie ein zusammengesetztes Produkt erfasst. Ist die Wärmebehandlung beendet, werden die Bauteile wieder vereinzelt und können in nachfolgenden Schritten wieder als Einzelbauteile verfolgt werden.




Abbildung 2: Prinzipdarstellung der Materialevolution im Produktionsprozess (E als Schritte)

Diese generische Erfassung des Produktionsablaufes hat den Vorteil, dass die Daten beliebig langer Produktionslinien effizient erfasst werden können. Dem gegenüber steht der effiziente Zugriff auf die gespeicherten Daten, bspw. um sie den Produktionsassistenten in Echtzeit zur Verfügung stellen zu können. Hier ist es im Normalfall notwendig, die Daten auf der Einzelteilebene verfügbar zu haben.

Erfolgt bspw. im Schritt $E_{5/1}$ eine Prüfung, sind für den Produktionsassistenten beliebige Kombinationen der Schritte $E_{1/1}$, $E_{2/1}$, $E_{3/1}$ und $E_{4/1}$ relevant. Der Schritt $E_{4/2}$ hingegen bezieht sich auf ein zu diesem Zeitpunkt anderes Bauteil und hat somit keine Relevanz für die aktuelle Prüfung. Da die relationale Abbildung des erwähnten Graphen einen effizienten Zugriff erschwert, wird hier bereits bei der Speicherung eine Erweiterung des Detailgrades auf Einzelteilebene vorgenommen. Diese bewusst mit Redundanz einhergehende Abbildung des Graphen auf einzelne Produktionsketten ist in Abbildung 3 dargestellt. Hier sind die real erfassten Prozesse mit Hilfe durchgezogener Pfeile dargestellt. Die gestrichelten Pfeile zeigen hingegen die während der Speicherung eingeführten virtuellen Schritte.

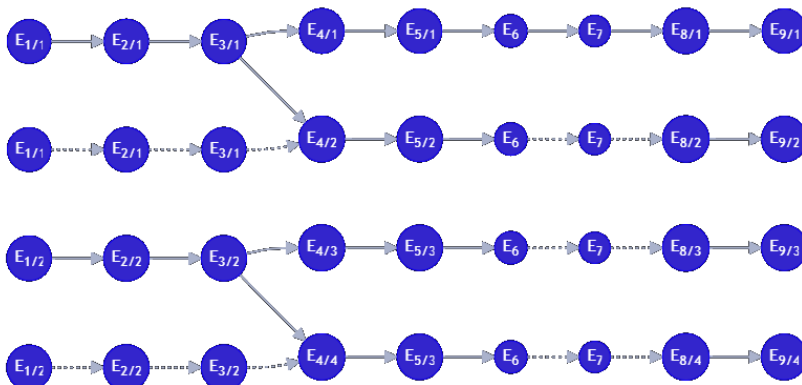


Abbildung 3: Prinzipdarstellung der Aufteilung eines Produktionsgraphen in einzelne Ketten

Die ursprüngliche Darstellung des Graphen wird also auf eine 2D-Matrix abgebildet, deren X-Dimension die Produktionskette des einzelnen Produktes auf dem höchstmöglichen Detailgrad (Produktsicht) abbildet und deren Y-Dimension die einzelnen Arbeitsschritte einer Maschine (Anlagensicht) wiedergibt. Der Vorteil der so erfolgten Speicherung wird insbesondere dann deutlich, wenn im Schritt E_6 mehrere hundert Bauteile zusammengefasst werden.

Würde ein Produktionsassistent im Schritt $E_{9/1}$ auf alle vorhergehenden Produktionsschritte des Produktes 1 zugreifen wollen, genügt in der Matrix-Sicht eine einfache Abfrage unter Verwendung der Chain-ID (entspricht der Produkt-ID) 1 (vgl. Abbildung 4). Ein Produktionsassistent, der hingegen Vergleichsdaten der Bearbeitung verschiedener Produkte an einer Maschine bzw. einem Maschinentyp benötigt, kann dies durch die Verwendung des gleichen Index in der Produktionskette erreichen.

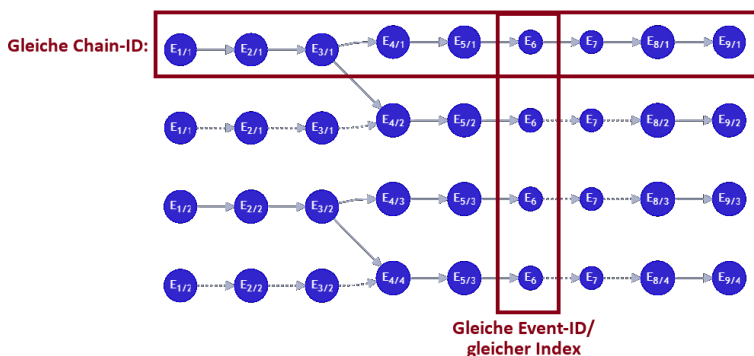


Abbildung 4: Prinzipdarstellung des Zugriffs auf die Produktionsketten in Matrix-Sicht

Da die matrixbasierte Abbildung der Produktionsketten gleiche Produktionsschritte (gleicher Maschinentyp) unterschiedlicher Produktionslinien auf den gleichen Index in der Matrix (X-Dimension) abbildet, werden Produktionsabläufe linienübergreifend vergleichbar. Damit wird mit dem semantischen Datenmodell die Grundlage geschaffen, digitale Produktionsassistenten linienübergreifend zu verwenden, selbst wenn sich die Produktionsabläufe sowie Endprodukte zwischen den einzelnen Linien unterscheiden.

UAP 2.2 Semantisches Framework

Innerhalb des Arbeitspaketes AP 2.2. semantisches Framework, wurden zwei Teilaufgaben bearbeitet:

Erstens die Konzeption eines semantischen Meta-Datenmodells und zweitens eine Umsetzung des Meta-Datenmodells. Innerhalb des Abschlussberichtes fokussieren wir insbesondere die Konzeption und gehen nur kurz auf die im Projekt entstanden prototypische Implementierung ein. Hauptzielsetzung des semantischen Meta-Datenmodells war die strukturierte Erfassung und Abbildung des Wissens und der anlagentechnischen Voraussetzungen in dem Anwendungsbereich

“Abbildung von Prozessketten in Gießereien”. Dabei werden Begriffe und deren Beziehungen zueinander definiert, um eine gemeinsame und wiederverwendbare Wissensbasis zu schaffen. Folgende Schritte zur Konzeption eines semantischen Meta-Datenmodells wurden in Zusammenarbeit mit den Projektpartner bearbeitet:

1. Definition der Zielsetzung und Anwendungsbereich

1.1. Zielsetzung:

Das Ziel des semantischen Modells besteht darin, Daten über sämtliche Maschinen des Maschinenparks systematisch zu erfassen, zu verwalten und zu analysieren. Der Schwerpunkt liegt dabei insbesondere auf der Erfassung von Voraussetzungen für den potenziellen Einsatz von KI-basierten Lösungen zur Steuerung der Prozessketten. Im Rahmen des Projekts wurden zu diesem Zweck umfassende Untersuchungen der Infrastruktur durchgeführt, darunter die technische Anbindung der Maschinen, beispielsweise deren Einbettung in die Netzwerkstruktur, sowie die Analyse von Layout-Informationen zur Verkettung der einzelnen Prozessschritte und Steuerungsparameter des Maschinenparks bzw. einzelner Maschinen.

1.2 Anwendungsbereich:

Der Anwendungsbereich dieser Untersuchung konzentrierte sich auf den Maschinenpark einer Gießerei. Ziel des Arbeitspakets war jedoch die Entwicklung eines Leitfadens zur Bewertung der grundlegenden Voraussetzungen eines Maschinenparks in Bezug auf die Optimierung von Arbeitsschritten durch den Einsatz von KI-basierten Assistenzlösungen. Im Zuge dessen wurde der Anwendungsbereich erweitert, um eine Graph-basierte Erfassung von Produktionsdaten in Maschinenparks zu ermöglichen.

1.3. Zielgruppe:

Zielgruppe des Leitfadens sollen Unternehmen sein, welche in ihrem Maschinenpark produzierte Bauteile durch durchgängige digital erfasste Zwillinge beschreiben wollen. Diese Daten müssen des Weiteren geeignet sein, entsprechende KI-System anzulernen.

2. Bestandsaufnahme der vorhandenen Daten und Metadaten

2.1 Datenquellen identifizieren:

Im Bereich der Datenquellen wurde sich insbesondere auf die Maschinen und die Einbettung in den Produktionsprozess konzentriert. Die Konnektivität der Maschinen und Produktionsdaten standen diesbezüglich im Vordergrund. Welche Daten des Produktionsprozesses können extrahiert werden und welche Meta-Daten können zusätzlich angemischt werden. Dabei muss der Brownfield Ansatz insbesondere berücksichtigt werden. Die bedeutete das z.B. einheitliche Zeitstempel über einen gesamten Produktionsprozess nicht immer verfügbar sind. Grundsätzlich kann jede Maschine als

Datenquelle Produktionsdaten bereitstellen, die Einbettung in ein gesamtheitliches Konzept stellt eine Herausforderung dar.

2.2. Analyse der vorhandenen Metadaten: Innerhalb des Projektes wurde die Betrachtung der Meta-Daten auf den Anwendungsbereich Verknüpfung von Prozessdaten der einzelnen Maschinen eingeschränkt, um den Rahmen der Untersuchungen nicht zu sprengen. Weiterhin sollte eine schnelle Analyse von Produktionsanlagen, bezüglich des Anwendungsfalls Assistenzsysteme auf Basis von KI-Lösungen, möglich sein. Grundsätzlich wurde sich auf folgende Meta-Daten konzentriert:

- Einbindung in die IT-Infrastruktur
- Layoutdaten des Maschinenparks
- Zeitinformationen (Overall Time, Prozess Step Duration)
- Identifikation von Bauteilen (unique ID, unique flow via Layout oder/und time))
- Interne Datenstruktur hinsichtlich der verarbeiteten Bauteile
- Einteilung von Events (siehe AP 3 Framework zur generischen Datenakquise)

3. Konzeptentwicklung

Bei der Konzeptentwicklung wurde auf den Arbeiten von AP 2 Entwicklung semantisches Datenmodell aufgebaut. Dabei wurden folgende Annahmen vorausgesetzt:

Jede Maschine liefert eine Menge von Graphen. Dabei ist ein Graph als Menge von gerichteten Kanten und Knoten repräsentiert. Jeder Knoten ist ein eindeutiger Identifier für den Zustand eines Bauteils im Produktionsprozess. Jede Kante enthält alle Informationen, welche den Zustand eines Bauteils in einen neuen Zustand überführt (digitaler Zwilling eines Produktionsschrittes).

Diese Annahme führt dazu das eine Produktionsanlage aus Mengen von Graphen interpretiert werden kann. Dabei ist zu beachten, dass für die Beschreibung einer Prozesskette die einzelnen Graphen eines Bauteils zu einer Prozesskette zusammengeführt werden müssen. Hierfür würden weitere Annahmen getroffen:

- ID: Jedes einzelne Bauteil ist durch eine eindeutige ID identifizierbar (In der Verarbeitung gescannte Erkennungen von Bauteilen)
- Zeitstempel: Jeder Arbeitsschritt einer Maschine kann mit einem Zeitstempel versehen werden
 - pro Arbeitsschritt (über alle Maschinen)
 - pro Maschine (Infrastruktur)
- Layout: Die Verknüpfung von Maschinen ist durch ein Layoutplan vorgegeben ("Experten"-Wissen über den Aufbau einer Produktionsstraße - örtlich)

Abbildung 1 zeigt eine schematische Architektur des Datenflusses. Im Folgenden soll das Konzept des Matching von Maschinendaten auf Basis von Metadaten detaillierter beschrieben werden.

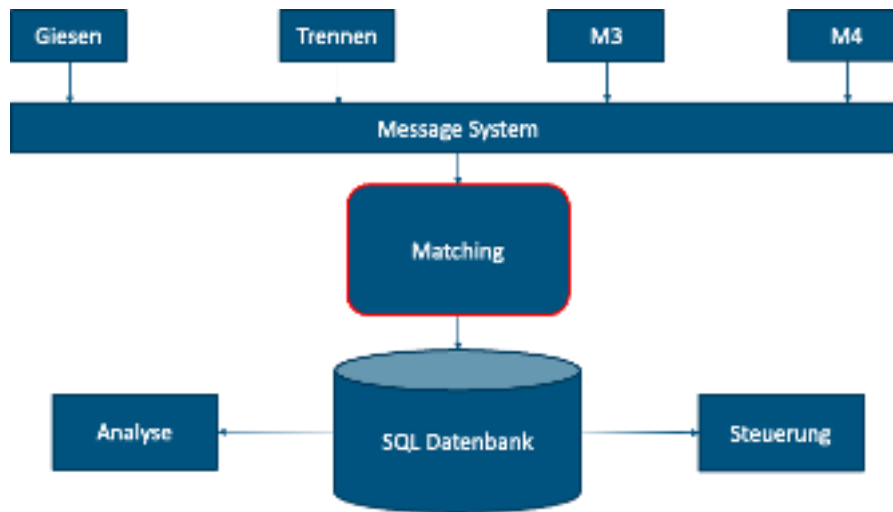


Abbildung 5: schematische Architektur des Datenflusses

Für den Matcher wurde anschließend untersucht, welche Meta-Daten notwendig sind, um ein entsprechendes Matching herzustellen.

Tabelle 1 zeigt entsprechende Matching Variante für das Matching von Bauteilgraphen einer Maschine mit anderen Maschinen.

Merkmale/ Permutationen	2 sequentielle Maschinen	1 Split n sequentielle Maschinen	1 Vereinigung n sequentielle Maschinen
Produkt-ID	-	-	-
Produkt-ID und Layout	+	-	-
Produkt-ID und Zeit	+	+	+
Zeit	-	-	-
Layout	-	-	-
Zeit und Layout	+	+	+
Zeit, Layout und Produkt-ID	+	+	+

Tabelle 1: Matching Varianten bezüglich Meta-Daten (Id, Zeitstempel und Layout)

Ausgehend von diesen Ergebnissen wurde eine prototypenhafte Implementierung des Matching von Produktionsdaten der Maschinen in Prozessketten umgesetzt. Weiterhin wurden die Ergebnisse

in einem Leitfaden zusammengetragen und allgemeine zu analysierende Informationen bestimmt, um einen Einsatz der AI-PAT Assistenz zu ermöglichen.

Für die Integration digitaler Tools, einschließlich KI-Unterstützung, in bestehende Produktionsanlagen, sind folgende Dimensionen zu berücksichtigen. Jede dieser Dimensionen spielt eine entscheidende Rolle bei der erfolgreichen Umsetzung bei Digitalisierungsvorhaben und erfordert spezifische Maßnahmen und Anpassungen.

Datenerzeugung

- Anlagen/Maschinen-Generationen
- Unterschiedliche SPS-Hersteller
- Sensordaten
- Heterogene

Datenformate

Datenverarbeitung

- Sequenzielle Anlieferung
- Graph-basierte Modelle
- Eindeutigkeit und Rückverfolgung
- Datenhaltung (strukturiert, semi- und unstrukturiert)
- Datenmodellierung (relational, Graph basiert)
- Read/Write Modelle

Infrastruktur

- Schnittstellen und Kommunikation
- Anlagen-Layout
- Zeitliche Informationen
- Netzwerkstruktur
- IT-Systemarchitektur

Steuerbarkeit

- Regulatorische Anforderungen
- Referenzen und Erfahrungen
- Regelungstechnik
- Sicherheit
- Echtzeitverarbeitung

4. Implementierung

Die Implementierung eines Funktionsdemonstrators erfolgte in mehreren Schritten, um die Effizienz und Genauigkeit der Prozessdarstellung zu gewährleisten.

Zunächst wurde ein Maschinengraphen-Generator entwickelt. In diesem Schritt erfolgte die Definition des Layouts, wobei unterschiedliche Layout-Typen wie sequentielle Anordnungen, Splits (Verzweigungen) und Aggregationen berücksichtigt wurden. Anschließend wurden Teilgraphen generiert, um die verschiedenen Prozessabschnitte darzustellen. Diese Teilgraphen wurden dann zu vollständigen, gerichteten Graphen zusammengefügt, die die Prozessabläufe und -abfolgen visualisieren.

Der nächste Schritt umfasste die Hüllenberechnung. Hier wurden ID-Listen für die Eingänge und Ausgänge der Graphen erstellt, um die jeweiligen Knotenpunkte eindeutig zu identifizieren. Zudem wurden Zeitstempel entlang der Pfade sowohl in Vorwärts- als auch in Rückwärtsrichtung eingeführt. Diese Zeitstempel ermöglichten es, das Minimum für die Eingangsknoten und das Maximum für die Ausgangsknoten zu bestimmen, was für die zeitliche Koordination der Prozesse entscheidend ist.

Im letzten Schritt wurde das Matching der Hüllen durchgeführt. Dabei wurde entlang aller Eingangs- und Ausgangsknoten der Graphen ein Abgleich vorgenommen, um Übereinstimmungen zu identifizieren. Falls ein Teilgraph innerhalb eines anderen Graphen gefunden wurde, erfolgte eine Aufteilung (Split) der Graphen. Der neu entstehende Teilgraph wurde in das bestehende System eingefügt, während der alte Teilgraph wieder in die Menge der Graphen aufgenommen wurde, die für das Matching verwendet werden. Dieser iterative Prozess stellte sicher, dass alle relevanten Teilprozesse korrekt integriert und synchronisiert wurden.

Durch diese Schritte konnte ein Funktionsdemonstrator entwickelt werden, der die komplexen Prozessabläufe adäquat abbildet und analysiert.

OPC UA Informationsmodell

Basierend im Vorfeld beschriebenen Annahmen wurde OPC UA Informationsmodell entwickelt. Im Nachfolgenden ist der Aufbau kurz skizziert. Dabei wird sich auf das Zusammenspiel der einzelnen Maschinen konzentriert, wobei jede Maschine einen gerichteten Graphen erzeugt. Jeder Knoten im Graphen stellt den Zustand eines Bauteils dar, und jede Kante repräsentiert einen Übergang von einem Zustand zu einem anderen, wobei die Kante die für den Produktionsschritt notwendigen Daten enthält.

Skizze des OPC UA Informationsmodell für Maschinen mit gerichteten Graphen

1. Objekte und Knoten

- **Maschine:** Repräsentiert eine Maschine in der Produktionslinie.
 - Beispiel: Maschine1, Maschine2, etc.
- **Zustandsknoten:** Repräsentiert den Zustand eines Bauteils während der Produktion.
 - Beispiel: Zustand_A, Zustand_B
- **Kanten (Übergänge):** Repräsentieren den Übergang von einem Zustand zum nächsten.
 - Beispiel: Übergang_AB, Übergang_BC

2. Eigenschaften und Attribute

- **Maschine**
 - ID: Eindeutige Kennung der Maschine (z.B. Maschine1).
 - Name: Beschreibung der Maschine (z.B. Montageautomat).
- **Zustandsknoten**
 - StateID: Eindeutige Kennung des Zustands (z.B. Zustand_A).
 - Description: Beschreibung des Zustands (z.B. Bauteil montiert).
- **Kanten (Übergänge)**
 - TransitionID: Eindeutige Kennung des Übergangs (z.B. Übergang_AB).
 - SourceState: Startzustand des Übergangs (z.B. Zustand_A).
 - TargetState: Zielzustand des Übergangs (z.B. Zustand_B).
 - RequiredData: Die für den Übergang erforderlichen Daten (z.B. Temperatur, Druck)

3. Beziehungen und Graph-Struktur

Jede Maschine liefert einen gerichteten Graphen, der die Zustände und Übergänge beschreibt. Die Zustandsknoten sind über gerichtete Kanten miteinander verbunden, die die Übergänge zwischen den Zuständen darstellen.

- **Zusammenspiel der Maschinen:**
 - Die Maschinen sind so konfiguriert, dass die Endzustände einer Maschine zu den Anfangszuständen einer anderen Maschine passen, um einen durchgängigen Produktionsfluss zu ermöglichen.
 - Beispiel: Der Endzustand von Maschine1 (Zustand_C) wird als Startzustand von Maschine2 betrachtet.

4. Methoden und Operationen

- **Erfassen von Übergangsdaten:** Methoden, um die Daten für einen Übergang abzurufen.

- Beispiel: `GetTransitionData(Übergang_AB)`, die Temperatur und Druck für den Übergang zwischen `Zustand_A` und `Zustand_B` abrufen.
- *Navigieren im Graphen*: Methoden, um von einem Zustand zum nächsten zu wechseln.
 - Beispiel: `MoveToNextState(currentState)`, die den nächsten Zustand basierend auf den aktuellen Bedingungen und Übergängen bestimmt.
- *Visualisierung des Graphen*: Methoden, um die Graphenstruktur und die aktuellen Zustände und Übergänge anzuzeigen.
 - Beispiel: `VisualizeMachineGraph()`, die den gesamten gerichteten Graphen der Maschine oder der Verkettung von Maschinen anzeigt.

AP 3. Framework zur generischen Datenakquise

Wie in bereits einführend erläutert, erfolgt die Erfassung der Daten aus heterogenen Datenquellen eventbasiert. Dafür kommen im **UAP 3.1** verschiedene Eventtypen zu Einsatz, wobei zwischen produktions-, umgebungs- und erfassungsrelevanten Eventtypen unterschieden wird.

Zu den produktionsrelevanten Eventtypen gehören:

- **Produktionsevents** zur Erfassung wichtiger Produktionsschritte (Materialevolution – bspw. Übergang vom flüssigen Aluminium zum gegossenen Bauteil),
- **Prozessevents** zur Erfassung wichtiger Zwischenschritte, die Einfluss auf das Produkt haben können (bspw. Start und Ende einzelner Bewegungen eines Gießlöffels) und
- **Assessmentevents** zur Übertragung von Prüfergebnissen

Die erfassungsrelevanten Eventtypen sind:

- **Signaturevents** zur Synchronisation zwischen realem Produktionsprozess und den erfassten Daten und
- **(Un-)Loadingevents** als Beginn und Ende einer Produktionskette

Als umgebungsrelevante Eventtypen gelten:

- **Einstellwertevents** zur Erfassung von Änderungen an Maschineneinstellungen und
- **Rüstevents** zur Erfassung von Werkzeugwechseln (bspw. Tausch des Gießlöffels oder der Kokille)

Die Events werden in der Produktion mittels eines OPC UA-Wrappers aus verschiedenen Quellen erfasst und an den Datenbankservice übermittelt. Zur Reduktion der Netzwerklast sowie des benötigten Speichers wird auf eine stetige Übertragung verzichtet und nur im Bedarfsfall (bei Änderungen) ein neues Event versandt. Dies hat den Vorteil, dass für Anlagen und Produktionslinien, die gerade nicht in Betrieb sind, praktisch „by Design“ kein Datenaufkommen

erzeugt wird. Das Zusammenspiel der produktions- und erfassungsrelevanten Events ist exemplarisch für 5 Anlagen in Abbildung 5 dargestellt

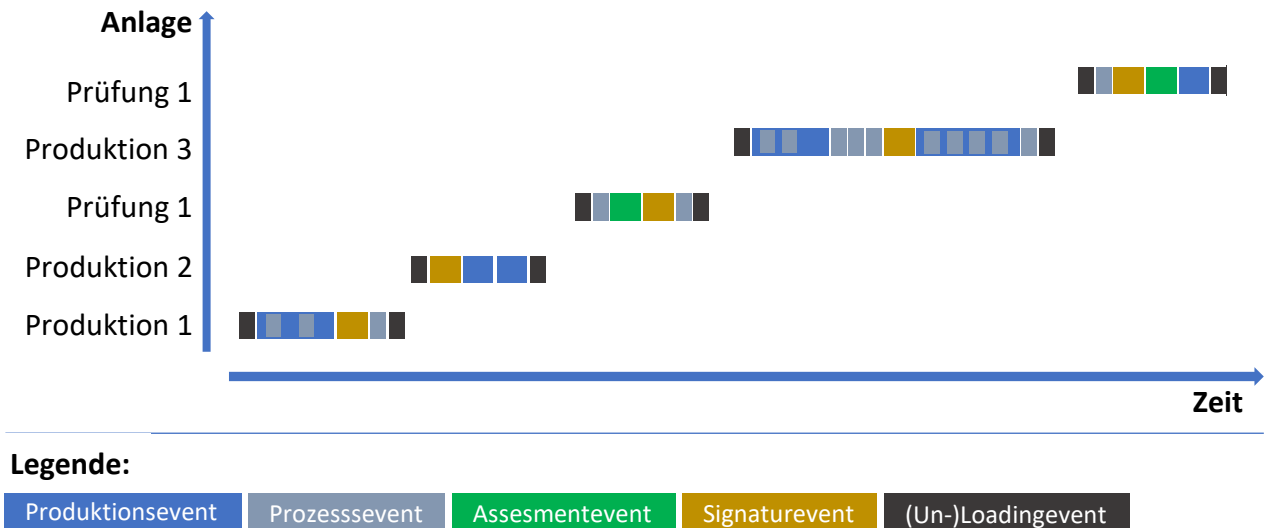


Abbildung 5: Zusammenhang der einzelnen Eventtypen im Produktionsprozess

Diese Darstellung verdeutlicht, dass alle erfassten Teilketten von Loading- und Unloading-Event eingeschlossen werden und mindestens ein Signaturevent enthalten müssen. Dies sichert die Synchronisation zwischen realer Produktion und erfassten Daten. Die so erfassten Teilketten können in der Datenbank anschließend mit Hilfe der Signatur zu kompletten Produktionsketten zusammengefasst werden. Innerhalb von AI-PAT wurde dafür ein Simulator entwickelt, der die eventbasierte Datenbereitstellung unabhängig von der realen Produktion u. A. nach den beschriebenen Regeln simuliert und mit dessen Hilfe die Entwicklung der Datenerfassung simulationsbasiert vorangetrieben werden kann.

Die Ausnahme von der eventbasierten Datenerfassung bilden kontinuierlich als Zeitreihen zu erfassende Sensordaten, die bspw. die Temperatur der Schmelze im Tiegel oder die Energieaufnahme einzelner Anlagen erfassen. Diese Daten werden kontinuierlich übertragen und als *Timestamp-Key-Value-Tripel* in die Datenbank gespeichert. Der Key ist dabei die eindeutige ID des Sensors von dem der Wert (Value) erfasst wurde.

Aus Übersichtsgründen wurden die Tabellen für Zeitreihen sowie Einstellwert- und Rüstevents nicht in Abbildung 5 dargestellt. Die Zeitreihen werden über den Erfassungszeitraum mit den Erfassungszeitpunkten der verschiedenen Events verbunden und stehen so der KI als Input zur Verfügung.

Das Ziel des **UAPs 3.2** war die Erstellung eines Frameworks, welches für KI-Anwendungen in Shopfloors genutzt werden kann. Die Entwicklung des Frameworks wurde nach dem CRISP-DM (Cross Industrial Standard for Data Mining) durchgeführt, welche in sechs Phasen unterteilt ist. In AP 1 wurde die Anforderungsdefinition (Phase „Business Understanding“) durchgeführt. Das Unterarbeitspaket 3.2 entspricht daher dem Schritt „Data Understanding“ des CRISP-DM. Der Fokus dieses Unterarbeitspaketes lag auf der Entwicklung einer generischen nutzer-zentrierten Data Quality-Pipeline unter Einbeziehung von explorativen Analysemethoden und Visual Analytics zur Gewährleistung der Datenkonsistenz. Ziel war die einfache Identifikation der Datenqualität mit Hilfe des Frameworks und der damit verbundenen Anwendung, um geeignete Vorverarbeitungsmethoden identifizieren zu können sowie erste Erkenntnisse über die Daten zu gewinnen. Innerhalb des UAPs 3.2 wurde eine Datenvorverarbeitungskette zur Analyse und Sicherstellung der Datenqualität entwickelt, welche neue Daten in Bezug auf den vorliegenden Datentyp (numerisch, kategorisch, Zeitreihen sowie Zielgrößen) anhand mehrerer Merkmale (wie beispielsweise Fehlstellen, Prozessgrenzen oder auch Datenübertragungsfehler) evaluiert. Umgesetzt wurde dies durch die Implementierung von Methoden wie Heat Maps, Missing Data Maps und ähnlichen Visualisierungstechniken.

Daran anschließend wurde eine Vorgehensweise für eine erste Vorverarbeitung der Daten implementiert, die in Form von der Entwicklung eines Prozesses zur Identifikation und Bereinigung von Datensätzen umgesetzt wurde. Die identifizierten und implementierten Methoden zur systematischen Datenbereinigung (Data Clearing), bspw. interaktive Darstellungen von Minima- und Maxima-Werten zur Selektion und Behandlung von Ausreißern, sind prototypisch implementiert. Durch diese interaktive Vorab-Analyse ist es anschließend möglich, sich einen Überblick über die später zu analysierenden Daten zu verschaffen, insbesondere auch, ob sich einzelne Features auf die Vorhersagen überhaupt in einem signifikanten Maße auswirken würden. So kann bereits im Voraus die Zahl der zu betrachtenden Features und damit die spätere Rechenzeit und Komplexität des Modells reduziert werden. Ziel der Anwendung war eine möglichst einfache Bedienbarkeit der Methoden, um dem Anwender die erste Prüfung der Daten zu vereinfachen und einen ersten Erkenntnisgewinn über die Struktur und Aussagekraft der Daten zu geben.

Als Proof of Concept wurden die Methoden sowohl in einer Python-Umgebung als auch in der kommerziellen Software Lösung Tableau umgesetzt. Für die weitere Entwicklung der Modellierungsroutine wurde auf der entwickelten Python-Lösung aufgesetzt, um Software-Brüche zu vermeiden. Die Python-Anwendung wurde auf Basis der Bibliothek Streamlit [<https://streamlit.io>] entwickelt. Die Verwendung von Streamlit erlaubt den schnellen Aufbau von datengetriebenen, interaktiven Web-Services im Sinne eines Rapid Prototypings und bietet somit ein ausgezeichnetes Testumfeld für die generische, nutzerzentrierte KI-Entwicklung im Projekt. Ebenfalls (und auch in späteren Arbeitspaketen) wurden die Python-Bibliotheken NumPy [<https://numpy.org>], SciPy [<https://scipy.org>] und pandas [<https://pandas.pydata.org>] für die prinzipielle Datenverarbeitung und Datenanalyse verwendet. Die Daten können als CSV-Datei

(„comma separated values“) eingelesen werden, wobei eine minimale Vorverarbeitung nötig ist, um eine Kompatibilität mit der Anwendung herzustellen (z.B. sollten Zeitstempel in ein numerisches Format konvertiert werden). Die weiteren Schritte zur Datenverarbeitung des CRISP-DM (siehe dazu Arbeitspaket 4.1) können anschließend ebenfalls mit der Anwendung durchgeführt werden.

AP 4. Generische KI-Entwicklung

Ziel des **UAP AP 4.1** (Feature Engineering) ist eine Routine zur Vorverarbeitung von generischen Daten, sodass diese später für verschiedene Machine Learning-Verfahren verwendet werden können. Im Rahmen des UAP 4.1 (generisches Feature Engineering) wurden auf Basis einer Literaturrecherche mehrere Konzepte (bspw. systematische, statistische Merkmalsextraktion aus Zeitreihen oder Feature Engineering-Ansätze in Bezug auf diskrete Prozessdaten, wie die Merkmalsrepräsentation von zeitlichen Abhängigkeiten in einem Produktionssystem) zur Steigerung des Informationsgehalts von Rohdaten zusammengestellt und verdichtet. Daraus wurde eine Ansammlung verschiedener Methoden zusammengetragen, die dem allgemeinen technischen Stand entsprechen und für generische Daten genutzt werden können. Diese wurde als Basis verwendet, eine Verarbeitungsroutine (Pipeline) zur systematischen Datenvorverarbeitung sowie zum Feature Engineering zu erarbeiten, welche in Abhängigkeit der verfolgten datengetriebenen Methode (hier Schwerpunkt klassische traditionelle Lernverfahren des maschinellen Lernens sowie Deep Transfer Learning-Ansätze) Datenverarbeitungsaufgaben vorschlägt. Die Auswahl der Methoden inklusive Klassifikation ist in Abbildung 6 dargestellt.

Pre-processing tasks		Exemption	Requirements			Methods	
Task	Subtask	Model	Data	Data type	Storage	SLB	TL
Feature selection	Data integration	-	all	all	yes		
	Manual feature selection	-	all	all	yes		
Data cleaning	Missing values treatment	-	e.g., XGB	all	all	no	
	Outlier treatment	-	RobustScaler	all	numeric	no	
	Removing errors	-	-	all	all	no	
Feature engineering	Feature engineering of trend data	hilbert transformation	-	all	trend	yes	
		LPP	-	all	trend	no	
		FPP I	LSTM	all	trend	no	
		FPP II	LSTM	all	trend	no	
		GFPP	LSTM	all	trend	no	
	Feature engineering of discrete data, e.g.,	timestamp transformation	-	all	timestamp	no	
		temporal dependencies	LSTM	all	nominal	no	
		target offset	-	all	numeric	no	
		polynomial features	-	all	numeric	no	
		custom value transformation	-	all	numeric	no	
Feature selection	Statistics filter	discretization	-	all	numeric	no	
		binarization	-	all	numeric	yes	
		clustering	-	all	numeric	yes	
		low variance filter	-	all	all	no	
Feature encoding	Categorical feature treatment	statistical significance filter	-	all	all	no	
		correlation filter	-	all	all	no	
		nominal feature encoding	-	all	nominal	yes	
Subsets	Build subsets for production system properties	encoding without transfer entity	-	all	nominal	yes	
		subsets for transfer learning	-	all	all	no	
Temporal transform	Appending predecessors	append t previous parts data	-	-	-		
Data split	Train/(validation)/test	-	e.g., DT	all	all	no	
		-	-	training	all	yes	
Feature scaling	Standardization	scaling on conjuncted train set	-	training	all	yes	
		-	-	-	-	-	
Balancing data	Sampling	random under-sampling	e.g., XGB	training	all	no	
		random over-sampling	e.g., XGB	training	all	no	
		SMOTE(-NC)	e.g., XGB	training	all	no	

SLB: Supervised learning benchmark
 TL: Transfer learning

Legend:
 Mandatory (dark grey)
 Recommended (medium grey)
 Optional (light grey)
 If available (blue)

Abbildung 6: Auswahl der Methoden inklusive Klassifikation

Die daraus entwickelte Routine umfasst die Bereinigung von Datensätzen, die Vorverarbeitung von kontinuierlichen Zeitreihen mittels statistischer Verfahren, Feature Engineering auf Basis diskreter Bauteildaten, die Datenintegration, Aufteilung in Trainings-, Test- und Evaluationsdaten sowie Standardisierung. Als ersten Schritt in der Modellierungsroutine werden ein eindeutiger Identifikator (z.B. eine Identifikationsnummer oder ein Zeitstempel) und eine Zielvariable (z.B. ein „OK“ oder „Nicht OK“, kurz „NOK“, für Bauteile) selektiert, anhand derer die weitere Datenverarbeitung erfolgt. Datenzeilen mit fehlenden Informationen oder geringer stochastischer Varianz werden entfernt und spezifische Features können manuell entfernt werden (falls sich diese in der Vorabanalyse als nicht relevant erwiesen haben). Darauffolgend sind verschiedene optionale Filter zur statistischen Signifikanz einstellbar, um weitere Feature zu entfernen. Als nächstes wird eine Aufteilung der Daten zwischen Trainingsdaten und Testdaten vorgenommen (ebenfalls mit einstellbarem Anteilswert, z.B. 20% für Testdaten). Dann werden kategorische Features gemäß des sogenannten One-Hot-Encodings aufgeteilt. Die anderen numerischen Features werden so skaliert,

dass deren Mittelwert 0 und deren Standardabweichung ist. Dadurch werden die Daten in ein einheitliches Zahlenformat gebracht, um eine möglichst hohe Performance der späteren Algorithmen zu garantieren. Die skizzierte Systematik wurde ebenfalls in eine Python-basierte Modellierungsroutine und eine anschließende Web-Applikation überführt. Die beispielhafte Oberfläche der Web-Applikation, welche für alle weiteren Arbeitspakete ebenfalls genutzt wurde, ist in Abbildung 7 dargestellt.

Interactive, software-guided preparation and integration of trend and discrete manufacturing data

WEB-BASED DATA ANALYTICS APPLICATION

LOGIC 1: RAW DATA EXPLORATION

LOGIC 2: DATA PREPARATION

- 2.1 | TREND DATA PRE-PROCESSING BY STATISTICS
- 2.2 | TREND DATA PRE-PROCESSING WITH INJECTED EXPERT-KNOWLEDGE
- 2.3 | FINAL DATA PREPARATION

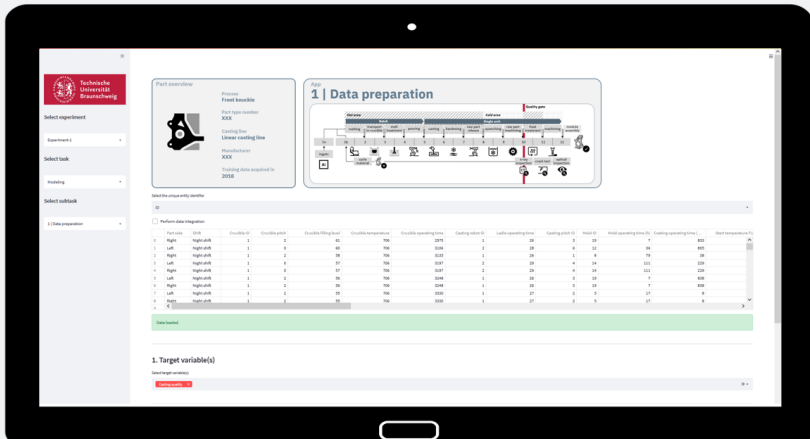
LOGIC 3: MODELLING

INCLUDING HYPERPARAMETER OPTIMISATION

LOGIC 4: MODEL EVALUATION

LOGIC 5: DEPLOYMENT

- 5.1 | FEATURE IMPORTANCE ANALYSIS
- 5.2 | SENSITIVITY ANALYSIS



The screenshot shows a web application interface for data preparation. It includes a sidebar with navigation options, a main content area with a 'Data preparation' section, and a data table with columns for 'Production date', 'Production quantity', 'Production quality', and 'Production cost'. The table contains data for various production dates and quantities.

Abbildung 7: Oberfläche der Webapplikation

Zielsetzung des **UAP 4.2** (Datenbasierte Modellierungsstrategien) war die Erarbeitung einer Empfehlungssystematik für Anwender zur (Vor-) Auswahl von datengetriebenen Methoden (maschinelle Lernverfahren wie Entscheidungsbäume, Random Forest, eXtreme Gradient Boosting (XGBoost) und AdaBoost sowie Deep Transfer Learning), welche in einem anschließenden Modellvergleich gegeneinander evaluiert werden, sodass das beste Modell für den vorliegenden Anwendungsfall ausgewählt werden kann. Es wurden mehrere Kriterien zur Modellauswahl erarbeitet, welche den drei Anforderungskategorien „Produktionssystem“ (bspw. das Produktionssystem ist durch signifikante zeitliche Abhängigkeiten geprägt), „funktional“ und „nicht-funktional“ zugeordnet werden können. Unter Einsatz der Empfehlungssystematik werden Anwender befähigt, entsprechend den Ausprägungen eines vorliegenden Projektes zur Datenanalyse datengetriebene Verfahren auszuschließen oder auszuwählen. Im Rahmen dieses Arbeitspaketes werden verschiedene Modellierungsansätze für generische Datensätze in einer automatisierten Weise anhand des neuesten Forschungsstandes miteinander verglichen, wobei besonderer Fokus auf das Anwendungsgebiet Produktion gelegt wurde. Für die Umsetzung der rechenintensiven Modellierungsroutinen wurde ein leistungsfähiger, stationärer Rechner mit

starker Grafikkarte, welche sich für das Erstellen und Antrainieren von KI-Algorithmen eignet, beschafft.

Ein Beispiel für einen Prozess zur Datenanalyse ist das im Projekt betrachtete Szenario einer präskriptiven Prozessregelung für ein Aluminiumkokillenguss Produktionssystem, in welchem an mehreren parallelen Gießplätzen unterschiedliche Kokillen aus einem Werkzeugbestand eingesetzt werden. Umgesetzt wurden die theoretisch betrachteten datengetriebenen Methoden des Empfehlungssystems für einen Modellbenchmark in Python, welche sowohl für Klassifikations- als auch für Regressionsfragestellungen implementiert sind. In diesem AP wurde ebenfalls Streamlit zur Entwicklung einer Anwendung genutzt, um diese Modellierungsansätze zu implementieren (in Verbindung mit gängigen Python-Bibliotheken für Machine Learning, vor allem Scikit-Learn [<https://scikit-learn.org/>]). In der Anwendung wird zwischen Klassifikationsalgorithmen und Regressionsalgorithmen unterschieden. Erstere ordnen den Daten eine diskrete Anzahl von Zielvariablen (z.B. die Bauteilqualität kodiert als „OK“ und „NOK“) zu, während letztere auf einer kontinuierlichen Zielvariable (z.B. die Ausfallwahrscheinlichkeit eines Bauteils) basieren.

Die grundlegenden Algorithmen für Klassifikation sind:

- Entscheidungsbaum,
- Logistische Regression,
- Support Vector Machine (SVM),
- Random Forest,
- AdaBoost,
- Gradient Boosting,
- XGBoost.

Die Algorithmen für Regression sind:

- Lasso Least Angle Regression,
- Ridge Regression,
- Polynomielle Regression,
- Entscheidungsbaum,
- Random Forest,
- AdaBoost.
- Gradient Boosting
- XGBoost

Sämtliche hier erwähnten Algorithmen wurden aufgrund verschiedener Kriterien (Anwendung in Produktionssystemen, Funktionsumfang und Transparenz) im Rahmen des Projektes ausgewählt.

Abseits der normalen Klassifikation und Regression stehen zusätzlich neuronale Netze, sowie deren Varianten Transfer Learning und Long Short Term Memory (LSTM) als Methoden zur Auswahl. Neuronale Netze bestehen aus einzelnen Zellen („Neuronen“), die gewichtet miteinander verknüpft sind und in mehreren Schichten geordnet sein können (dann auch „Deep Neural Network“ genannt). Das Netzwerk verarbeitet dabei ein Eingangssignal zu einem Ausgangssignal und wird ähnlich wie die zuvor genannten Algorithmen auf möglichst großen Datensätzen trainiert, wodurch die Gewichtungen der Verbindungen variiert werden. Neuronale Netze haben gegenüber den anderen Methoden den Vorteil, auch komplexere und nichtlineare Muster erkennen zu können, welche durch simplere Methoden nicht erfasst werden können. Da die hier zu betrachtenden Prozesse oft eine Vielzahl Parameter besitzen, ist es gerechtfertigt, neuronale Netze als Methode einzubeziehen. Transfer Learning ist eine Methode, neuronale Netze so zu trainieren, dass deren tiefere Ebenen auf ähnliche Anwendungsfälle übertragen werden können. Die oberflächlicheren Ebenen werden hingegen weiterhin spezifisch trainiert. Dadurch lassen sich vergleichbare Anwendungsfälle mit geringerem Ressourcenaufwand trainieren².

Für den spezifischen Anwendungsfall ist Transfer Learning geeignet, da sich verschiedene Maschinen ähnlicher Bauart im Idealfall auch ähnlich verhalten sollten. So kann ein neuronales Netz auf eine Maschine trainiert werden und dann dessen oberste Schichten auf die anderen Maschinen jeweils trainiert werden, statt das neuronale Netz auf alle Daten auf einmal zu trainieren. Kleine Abweichungen unter den Maschinen werden somit besser berücksichtigt, ohne sich auf die Modelle anderer Maschinen auszuwirken. Die Potentiale des Transfer Learnings für den spezifischen Anwendungsfall wurde ebenfalls in folgender Veröffentlichung betrachtet und im Projekt weiter vertieft: S. Gellrich, M.-A. Filz, A.-S. Wilde, T. Beganovic, A. Mattheus, T. Abraham, C. Herrmann, Deep Transfer Learning for Improved Product Quality Prediction: A Case Study of Aluminum Gravity Die Casting, *Procedia CIRP*. Bd. 104 (2021) S. 912–917.

LSTM hingegen modifiziert die Zellen in neuronalen Netzen dahingehend, dass frühere Informationen länger abrufbar bleiben (das „Kurzzeitgedächtnis“ oder „Short Term Memory“ wird sozusagen verlängert, daher die Bezeichnung „LSTM“). Dadurch ist es möglich, potentielle temporale Abhängigkeiten über längere Zeiten korrekt im Modell zu berücksichtigen. LSTM findet insbesondere in Sprachmodellen Anwendung, ist jedoch nicht auf diese beschränkt. Details zur Implementierung können in [2] gefunden werden. Der potenzielle Nutzen von LSTM für den Anwendungsfall Gießerei liegt darin, dass längerfristige zeitliche Abhängigkeiten ebenfalls Auswirkungen auf die Bauteilqualität haben können. Dies gilt stärker, je länger das Bauteil im Prozess verweilt. Vor allem thermische Trägheit spielt hier physikalisch eine potenzielle Rolle wie in Voruntersuchungen festgestellt wurde.

² [Praxiseinstieg Machine Learning mit Scikit-Learn & Tensorflow, Aurélien Géron, 1. Auflage 2018, O'Reilly]

Die Nutzer der Anwendung können eine beliebige Auswahl der genannten Algorithmen anwählen, die mit vordefinierten Hyperparametern (welche über eine bestimmte Einstellungs-Datei geändert werden können) verglichen werden. Nach automatischer Vorverarbeitung der Testdaten gemäß den Methoden in Arbeitspaket 4.1, sowie Data Sampling zum Ausbalancieren der Daten, geschieht dieser Vergleich über ein Kreuzvalidierungsverfahren (spezifisch „k-fold cross validation“). Für jedes Verfahren wird eine Reihe an Qualitätskriterien ausgegeben, sodass der Nutzer einen direkten Vergleich der Verfahren vornehmen kann. Die jeweils genutzten Verfahren können in der Anwendung zusätzlich im Detail untersucht werden. Je nachdem, ob Klassifikation oder Regression genutzt wurde, sind unterschiedliche Qualitätskriterien einsehbar. Für Klassifikationen sind dies u.a. die Gesamtgenauigkeit des Modells, die Einzelgenauigkeiten („Precision“) und Recall-Werte für die diskreten Zielwerte, die ROC-Kurve („Receiver operating characteristic“) und deren Flächeninhalt („AUC“, kurz für „Area under curve“), sowie den F1-Score. Für Regressionsalgorithmen können das Bestimmtheitsmaß (R^2), sowie der mittlere quadratische Fehler („MSE“) eingesehen werden. Ebenfalls für beide Modelltypen ist die Lernkurve einsehbar. Die Anwendbarkeit der Methoden konnte auf Basis des Anwendungsfalls Gießerei gezeigt werden und wurde ebenfalls mit einem weiteren Datensatz validiert.

UAP 4.3 (Transfer Learning) zielt auf eine Potenzialanalyse von Transfer Learning-Ansätzen für Produktionsfragestellungen. Transfer Learning-Ansätze basieren auf Methoden des maschinellen Lernens sowie Deep Learnings um ein datengetriebenes Modell auf Basis von Quelldaten vorzutrainieren und es (schrittweise) auf Daten des Zielsystems anzupassen. Dabei ist der Grundgedanke, ein bereits auf einen Anwendungsfall trainiertes neuronales Netz als Ausgangslage für einen anderen Anwendungsfall zu nutzen, sodass nicht jedes Mal ein völlig neues Netz erstellt werden muss. Das Ziel des Arbeitspaketes ist, den Forschungsstand zu evaluieren und den Ansatz so zu generalisieren, dass zukünftige Anwendungen mit geringerem Aufwand durchgeführt werden können.

Daher wurde zunächst der Stand der Forschung analysiert und verdichtet. Aus der strukturierten Analyse wurde abgeleitet, dass ein strukturiertes Framework zur Entwicklung und Implementierung der Modellierungsansätze in vielen Veröffentlichungen nicht integriert wird. Daher wurde das Frameworks in das im Projekt entwickelte Framework integriert und eine Modellierungsroutine entwickelt.

Mehrere Vorgehensweisen zum Transfer Learning wurden experimentell mittels Python und der Streamlit-Bibliothek als grafische Benutzeroberfläche implementiert und untersucht. Einen produktionsbezogenen Ansatz stellt das kontinuierliche Transfer Learning durch Übertragung von Modellparametern des Ursprungs-Neuronalen Netzes eines Produktionsfaktors auf gleichartige Produktionsfaktoren dar. Als zweiter Ansatz wurde die Verbindung von Transformer Learning mit Transfer Learning untersucht. Transformer Learning Ansätze entstammen der Forschung zur

automatisierten Sprachverarbeitung und weisen hervorragende Merkmalsextraktionsfähigkeiten auf. Der verfolgte Forschungsansatz galt einer Steigerung der Modellgüte durch die starken Merkmalsextraktionsfähigkeiten der Transformer Neuralen Netze. Aktuell wird die Integration von Transfer Learning mit Long Short-Term Memory Neuralen Netzen zur Abbildung der ausgeprägten zeitlichen Abhängigkeiten in Gießproduktionssystemen untersucht (Abhängigkeiten zwischen einer bestimmten Menge an aufeinanderfolgenden Gussbauteilen aufgrund von gestörten Temperaturhaushalten in Kokillen bspw. durch Prozessstörungen bei Vorgänger-Bauteilen), da hierdurch eine signifikante Steigerung der Modellgüte erwartet wird. Darüber hinaus wurde eine Übersicht zu möglichen Anwendungsgebieten (Transfer-Entitäten) innerhalb von Produktionssystemen erstellt (z.B. Produkttypen, Standardfabriken, Jahreszeiten).

AP 5. Entwicklung Interaktionsbaukasten

UAP 5.1 Interaktionsmethoden

Die Erstellung eines Interaktionskonzepts für die AI-PAT Assistenzbox war ein vielschichtiger Prozess, der ein tiefes Verständnis der spezifischen Anforderungen und Herausforderungen der Benutzer im Produktionsumfeld der Gießerei erforderte. Im ersten Schritt wurde eine umfassende Analyse der Benutzer und ihrer typischen Arbeitsabläufe durchgeführt. Diese Analyse zielte darauf ab, die spezifischen Bedürfnisse, Arbeitsweisen und Interaktionsmöglichkeiten der Gießereimitarbeiter zu verstehen, um eine maßgeschneiderte Lösung zu entwickeln, die den Arbeitsalltag erleichtert und die Effizienz steigert. Folgende Schritte wurden bearbeitet:

1) Analyse der Benutzer im Produktionsumfeld der Gießerei

Benutzergruppen und Rollen: Die Gießerei umfasst eine Vielzahl von Rollen. Folgende Rollen wurden identifiziert: Maschinenbedienern, Leiter (Schicht, Bereiche der Produktionsanlage), Wartungspersonal und Qualitätssicherungsexperten. Jede dieser Gruppen hatte unterschiedliche Anforderungen und Interaktionsbedarfe, welche systematisch erfasst wurden. Maschinenbediener beispielsweise benötigten schnellen und einfachen Zugriff auf Maschinendaten und Fehlzustände, während Qualitätssicherungspersonal detaillierte Einblicke in den Bereich der Bewertung von Bauteilen des Produktionsprozesses benötigten.

Arbeitsumgebung: Auch im Arbeitsumfeld konnten unterschiedliche Bereiche wie Büro und Werkhalle der Gießerei unterschieden werden. In der Werkhalle kann beispielsweise nicht auf akustische Signale zurückgegriffen werden, da es oft zu laut ist. Visuelle Signale mussten daher in diesem Bereich in den Vordergrund gestellt werden. Die Benutzeroberfläche musste daher robust und intuitiv gestaltet werden, um schnelle Entscheidungen und Handlungen zu ermöglichen.

Technologische Kompetenz: Das Spektrum an technologischem Verständnis und Kompetenz variierte stark in der Gießerei. Daher musste das Interaktionskonzept sowohl für erfahrene Techniknutzer als auch für weniger technikaffine Mitarbeiter zugänglich und verständlich sein.

2) Analyse von Navigation, Workflows und Kommunikationsformen

Nach der initialen Benutzeranalyse wurden spezifische Aspekte der Navigation, Workflows und Kommunikationsformen untersucht, um sicherzustellen, dass die Interaktionen mit der AI-PAT Assistenzbox effizient und zielgerichtet sind.

Navigation: Die Navigation innerhalb der Assistenzbox muss schnell und direkt erfolgen, um Benutzern in stressigen Situationen die benötigten Informationen ohne Verzögerung zugänglich zu machen. Innerhalb der Gruppe der Maschinenbediener konnte aber z.B. festgestellt werden, dass eine Anzeige mit aggregierten Daten in den meisten Anwendungsfällen ausreichend war. Eine spezifische Analyse der Situation wurde meist erst nach Lösung des Problems durchgeführt. Ergebnis der Analyse war das die Benutzeroberfläche über eine kontextabhängige Navigation verfügen sollte, die je nach Aufgabenstellung relevante Optionen bietet, ohne den Benutzer mit unnötigen Informationen zu überfrachten.

Workflows: Die spezifischen Produktionsprozesse und die unterschiedlichen Aufgaben der Benutzergruppen in der Gießerei wurden nur rudimentär untersucht. Beispielsweise sind folgende Schritte meist in sich abgeschlossen: Überwachung von Maschinenzuständen, Durchführung von Wartungs- und Inspektionsaufgaben. Eine schrittweiser Durchlauf durch die Applikation konnte daher ausgeschlossen werden. Der Workflow wurde insbesondere nur durch einzelne Menüpunkte welche entsprechenden Schritte des Produktionsprozesses repräsentieren konzipiert. Schritt-für-Schritt-Anleitungen wurden nicht konzeptioniert oder implementiert.

Kommunikationsformen: Die Kommunikation zwischen den Benutzern und der AI-PAT Assistenzbox wurde mit dem Augenmerk möglichst einfacher Interaktion gestaltet. Da ein Großteil der Benutzer z.B. Handschuhe oder andere Sicherheitskleidung tragen. Auf textbasierte Eingaben wurde daher in der Konzeption weitestgehend verzichtet. Das Konzept der sprachbasierten Interaktion wurde nicht nachverfolgt, da innerhalb der Werkhalle die Umgebungsgeräusche zu laut waren.

3) Stilfindung und Ausgestaltung des UI-Interfaces der KI-Anwendung

Folgende Aufgabenbereiche wurden in Abstimmung mit der Informationsvisualisierung getroffen.
Farbpalette: Grundsätzlich wurde sich für ein dunkles Design der AI-PAT Toolbox entscheiden (siehe Abbildung: Visualisierung des Bauteilflusses).

Typografie: Es wurde sich für eine klare und gut lesbare Sans-Serif Schriftart entscheiden. Unterschiedliche Schriftgrößen und -gewichte sollen verwendet werden, um unterschiedliche Hierarchien und wichtige Informationen hervorzuheben.

Es wurde sich für ein *Responsives Design* entschieden, um die beiden Anwendungsfälle Werkhalle (Tablet) und Büro (Desktop) zu unterstützen.

3. Erstellen von User Stories für Interaktionswidgets

Um die Benutzererfahrung der AI-PAT Toolbox zu optimieren, wurden im Projektverlauf weitere User Stories für Interaktionswidgets erstellt, um die den spezifischen Anforderungen der unterschiedlichen Benutzergruppen abzubilden. Die entworfenen User Stories spiegeln dabei die unterschiedlichen Bedürfnisse und Erwartungen der verschiedenen Benutzergruppen dar. Die Interaktionswidgets können durch dieses Vorgehen bezüglich der Funktionen und Interaktionen, die notwendige Unterstützung bei den speziellen Aufgabenbereichen bieten.

Innerhalb dieses Berichtes wird nur auf die Benutzergruppen Maschinenbediener und Schichtleiter eingegangen.

Im Folgenden ist eine stark verallgemeinerte User Story für einen Maschinenbediener dargestellt. *Als Maschinenbediener möchte ich ein Echtzeit-Überwachungswidget auf meinem Dashboard sehen, das mir die aktuellen Statusinformationen aller Maschinendaten, für welche ich zuständig bin, angezeigt bekommen.* Dieses Widget muss klare visuelle Indikatoren Symbole verwenden, um sofort erkennbar zu machen, ob eine Maschine ordnungsgemäß funktioniert oder ob Probleme vorhanden sind. Probleme müssen durch entsprechende visueller Interaktion dargestellt werden. Außerdem sollte es die Möglichkeit bieten, durch eine haptische Interaktion (tippen) Details zum aktuellen Zustand und vergangene Fehlermeldungen anzuzeigen.

Für einen Schichtleiter könnte eine User Story in verallgemeinerter Form wie folgt formuliert werden: *Als Schichtleiter möchte ich ein Dashboard nutzen, das mir eine umfassende Übersicht über die Produktionskennzahlen meiner Schicht bietet.* Dieses Dashboard kann verschiedene Widgets enthalten, welche unterschiedliche Daten wie Gieß-Temperatur, Fehlerraten von Bauteilen und Maschinenzeiten (Ausfall bzw. andere Einschränkungen) in leicht verständlichen Diagrammen und Grafiken präsentieren. Darüber hinaus sollte es die Möglichkeit geben, die Daten nach Zeiträumen oder Maschinen zu filtern, um gezielte Analysen durchführen zu können.

UAP 5.2 Informationsvisualisierung

Im **UAP 5.2** (Informationsvisualisierung) wurden Konzepte entwickelt, um Informationen (Predictions der KI-Assistenten) konsistent und auf den jeweiligen Anwendungsfall/Anwender

zugeschnitten darzustellen. Aufgrund des Ausscheidens des Projektpartners Cadera, konzentrierten sich die Arbeiten in diesem UAP im Wesentlichen auf den Anwendungsfall Gießerei. Die entstandenen Konzepte sind jedoch auch auf andere Produktionsbereiche übertragbar. Ein Beispiel einer solchen Visualisierung ist in Abbildung 8 dargestellt. Hier wird der Bauteil-/Produktfluss exemplarisch für eine Gießlinie dargestellt. Diese Darstellung kann sowohl dazu genutzt werden, um die Historie der Produktion zu visualisieren als auch die Vorhersage durch den KI-Assistenten abbilden.




Abbildung 8: Visualisierung des Bauteilflusses

So kann für alle Produkte, die sich aktuell in der Linie befinden, die Vorhersage visualisiert werden, wie sich der weitere Verlauf unter aktuellen Produktionsbedingungen entwickeln wird. Diese Ansicht kann wiederum als Absprungpunkt genutzt werden, um bspw. Detailinformationen zum Grund des Ausschusses darzustellen. Aufgrund der fehlenden Verfügbarkeit einer genügend großen Menge an Trainingsdaten konnte das Training einer entsprechenden KI für diese Art der Visualisierung jedoch nicht um die Detaildarstellung erweitert werden. Das Konzept sieht hier vor, die Details zum Grund des Ausschusses textuell bspw. in einem Tooltip darzustellen. Weitere Details zur Darstellung werden in UAP 6.2 erläutert.

AP 6. Evaluation an Referenzfallstudie

Im **UAP 6.1** wurden die Anforderungen aus AP 1 aufgegriffen und an die Rahmenbedingungen der Produktion in einer Gießerei angepasst. Hier ist u. A. die lange Produktionszeit von Bedeutung, die bedingt durch aufwendige, lang dauernde Prozesse wie bspw. die Wärmebehandlung, die chargenbasiert erfolgt und damit die temporäre Zwischenlagerung der Produkte erfordert, eine genaue Rückverfolgbarkeit der Informationen zu einem Produkt erfordert.

Während bei einer kurzen Durchlaufzeit der Produkte durch eine Produktionslinie, die Informationen zu einem Produkt schnell nach ihrer Entstehung weiterverarbeitet werden und so mit hoher Wahrscheinlichkeit noch im Gedächtnis der Beteiligten sind, muss in der Gießerei mehr darauf geachtet werden, dass die notwendigen Informationen zu einem Produkt teilweise erst nach

Tagen oder sogar Wochen wieder benötigt werden. Tabelle 2 stellt die Spezialisierung der Anforderungen für den Gießereibetrieb beispielhaft dar.

Anforderung	Lösungsansätze	Spezialisierung
Lesbarkeit in dunkler Umgebung	<ul style="list-style-type: none"> dunkle Themes mit hohem Kontrast lesbarer Schriften in passender Schriftgröße mechanische Eingabemöglichkeiten 	keine
Bedienbarkeit unter Produktionsbedingungen	<ul style="list-style-type: none"> Auswahl von Touchscreens, die sich mit Handschuhen bedienen lassen Verwendung großer Buttons, die sich mit Handschuhen zweifelsfrei treffen lassen Tabbasierte Navigation statt Scrollen Beschränkung der notwendigen Eingaben auf ein Minimum 	keine
Domainspezifische Visualisierung von Informationen	<ul style="list-style-type: none"> Darstellung von Informationen basierend auf der Abbildung realer Produkte / Maschinen 	Bspw.: <ul style="list-style-type: none"> Visualisierung von Tiegelfüllständen Unterschiedliche Darstellungen von Schwerkraft- und Druckgießanlagen
Einfache, effiziente Erfassbarkeit der visualisierten Informationen	Verwendung bekannter Visualisierungs- und Interaktions-Metaphern	Bspw.: <ul style="list-style-type: none"> Bauteilprüfungen mit Buzzer-Bedienung Unterstützung durch KI-Systeme im Fall der Abweichung von der Vorhersage Visualisierungen von Zustandsparametern der Gießanlage

	Klare Aufbereitung der aktuell benötigten Informationen	Bspw.: <ul style="list-style-type: none"> • Darstellung der Informationen zu einem Produkt während der Prüfung • Sicherstellung des erfolgreichen Durchlaufens aller notwendigen Prüfungen • Visualisierung der vorausgesagten Produktqualität anhand der aktuellen Produktionsparameter
--	---	---

Tabelle 2: Beispielhafte Darstellung der Spezialisierung der Anforderungen für den Gießereibetrieb

Nachfolgend werden 3 Beispielen der Spezialisierung genauer erläutert.

Da der Gießprozess als Urformverfahren durch viele Parameter beeinflusst wird, ist die Produktqualität schwankend und muss engmaschig kontrolliert werden. Dies erfolgt mehrfach im Fertigungsprozess durch teilautomatisierte und manuelle Prüfungen (Röntgenprüfung, Sichtprüfungen). Abhängig vom gewünschten Ziel kann **Unterstützung durch KI-Systeme** hier auf verschiedene Weise integriert werden. So besteht die Möglichkeit dem Prüfer schon während der Prüfung die Vorhersage der KI anzuzeigen. Dies würde voraussichtlich die Effizienz steigern, da der Prüfer bereits die Entscheidung der KI kennt und dieser Entscheidung in der Regel folgen wird. Die KI muss in diesem Fall jedoch aus Sicherheitsgründen für einen hohen Precision-Wert (bezogen auf die IO-Klassifizierung), ggf. auch zum Nachteil des Recall-Wertes trainiert werden. Dies bedeutet, dass sie keine Produkte als IO klassifiziert, die NIO sind, jedoch durchaus Produkte, die IO sind als NIO klassifiziert. Ist das Ziel jedoch die Verringerung von Fehlentscheidungen während der Prüfung, sollte die KI den Prüfer nur **im Fall der Abweichung von der Vorhersage** informieren. So hat der Prüfer die Entscheidung bereits unabhängig getroffen und wird durch die KI nur in einzelnen Fällen dazu animiert, die Prüfung zu intensivieren.

In einer Gießerei, in der Produkte auf verschiedenen Produktionswegen hergestellt werden, ist die **Sicherstellung des vollständigen Durchlaufens aller notwendigen Prüfungen** eine zentrale Herausforderung. Langläufige Prozesse und manuelle Eingriffe können dazu führen, dass Prüfungen versehentlich übersprungen werden. Daher ist es notwendig, sowohl Datenhaltung als die Visualisierung/Nutzerführung an der Endkontrollstation so aufzubereiten, dass nicht vollständig IO-geprüfte Produkte herausgefiltert werden. Die Visualisierung muss hier auch Auskunft darüber geben, welche Prüfungen fehlen, und Entscheidungen ermöglichen, ob es sich lohnt, die fehlenden Prüfungen nachzuholen.

Die KI-basierte **Visualisierung der vorausgesagten Produktqualität anhand der aktuellen Produktionsparameter** ist ein wichtiges Instrument für die Optimierung des Produktionsprozesses.

Damit können einerseits rechtzeitig Maßnahmen ergriffen werden, um die Produktqualität zu erhöhen und damit den Prüfausschuss zu verringern, andererseits aber auch durch frühzeitiges Erkennen und Aussortieren von Produkten, deren Qualität die IO-Schwelle bereits unterschritten hat, Kosten eingespart werden.

Die Anpassung des Interaktionsbaukastens im **UAP 6.2** beschäftigte sich vorrangig mit der Visualisierung der Vorhersage der Produktqualität. Dafür wurde ein weiteres Widget entwickelt, das den vorhergesagten sowie bereits absolvierten Durchlauf der Produkte durch die Gießlinie visualisiert. Die Darstellung eines Screenshots des umgesetzten Widgets ist in Abbildung 9 zu sehen.

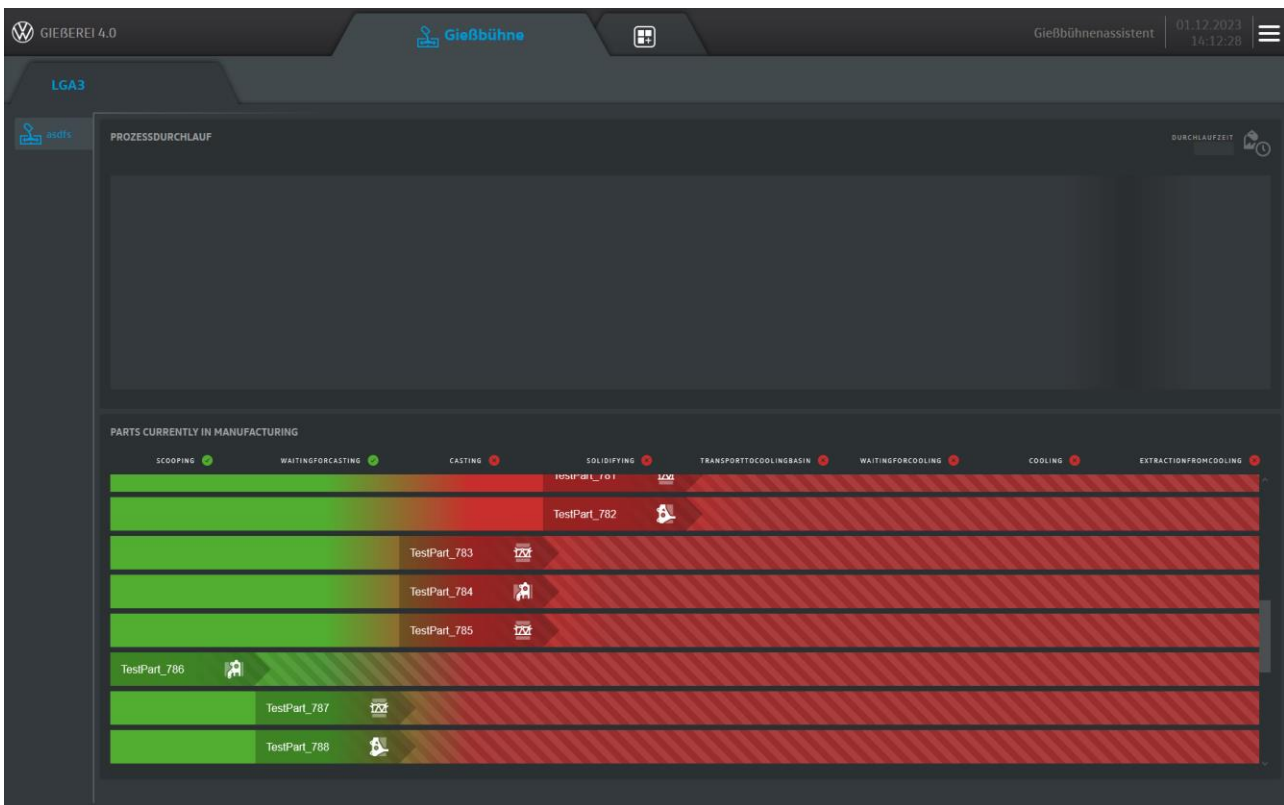


Abbildung 9: Darstellung der KI-Vorhersage der Produktqualität für einzelne Produkte

Das Widget visualisiert den aktuellen Status der in der Produktion befindlichen Produkte sowie die einzelnen Stationen, die die Produkte durchlaufen. Jedes Produkt ist mit einem Icon gekennzeichnet, das Auskunft über den Produkttyp gibt. Die einfarbigen Flächen zeigen den Status des Produktes in den bereits durchlaufenen Stationen. Grün bedeutet hier Ok, rot hingegen nicht Ok. Je nach Datenlage wären hier auch weitere Zustände wie bspw. unbestimmt (orange) denkbar. Im Proof of Concept wurde hier aber bewusst nur eine binäre Darstellung gewählt.

Die schraffierten Bereiche zeigen mit der gleichen Farbcodierung den durch die KI prognostizierten Zustand der Produkte im weiteren Produktionsverlauf an. Dieser Zustand ist theoretisch abhängig

vom jeweiligen Produktionsschritt (Station), vom Produkttyp sowie der Historie (Parameter der vorhergehenden Produktionsschritte) des Produktes. Somit können auch Produkte gleichen Typs an unterschiedlichen Stationen einen Zustandswechsel durchlaufen. Aufgrund der bereits erwähnten schlechten Verfügbarkeit von genügend Trainingsdaten, konnte die zugrundeliegende KI jedoch nicht ausreichend trainiert werden, um diese Darstellung zu erreichen. Über Tooltips können darüber hinaus auch Details zum jeweiligen Produkt und den Parametern, die zur entsprechenden Vorhersage geführt haben, eingeblendet werden.

Die Anpassung des Datenmodells in **UAP 6.3** konnte aufgrund des gewählten Ansatzes der Event sourcing-basierten Speicherung entfallen. Durch die Speicherung der einzelnen Produktionsschritte sowie möglicher Zwischenschritte als Ketten von Events ist es problemlos möglich, die Daten verschiedenster Produktionslinien ohne Anpassung des Datenmodells zu speichern.

Die Herausforderung lag darin, die Daten während der Speicherung so aufzubereiten, dass sie später insbesondere in großen Datenbeständen bedarfsgerecht und effizient ausgelesen werden können. Dies betrifft sowohl die Abfrage aller Daten zu einem Produkt als auch die Daten zu einer oder mehrerer Stationen. Beides konnte durch den Einsatz von „EventId“ und „ChainId“ zusammen mit einer geringfügigen Erhöhung der Redundanz (durch Einführung zusätzlicher Referenzen auf Einzelteilebene) erreicht und in UAP 6.3 erfolgreich mit Hilfe eines dafür entwickelten Simulators getestet werden.

Im **UAP 6.4** (Anpassung Lernverfahren) wurde das zuvor erarbeitete Framework auf einen konkreten Anwendungsfall übertragen. Die in Python entwickelte Modellierungsroutine (Data Quality Checks, systematische Datenvorverarbeitung und Feature Engineering wurde anhand von diskreten Bauteildaten, Modelltraining sowie Modellevaluation) anhand einer 3-monatigen historischen Datenbasis aus dem Jahr 2018 des assoziierten Konsortialmitglieds Volkswagen AG evaluiert. Hierbei ist hervorzuheben, dass diese Daten an verschiedenen Gießplätzen mit unterschiedlichen Kokillen aus einem Werkzeugbestand gewonnen wurden. Um die Eigenschaften jeder Kokille möglichst gut abbilden zu können, wurden die Gesamtdaten für jede Kokille separat behandelt. Verschiedene Ansätze zur Gewinnung möglichst akkurater Modelle wurden im Rahmen des Projektes entworfen und getestet.

Als erstes wurde der triviale Ansatz geprüft, in dem ein neuronales Netz für jede Kokille konstruiert und am Ende je nach Kokille das entsprechende Netz genutzt wird. Dabei ergab sich im Mittel ein AUC-Wert (die Fläche unter der ROC-Kurve) von 66% (Minimum 51%, Maximum 76%). Der nächste Ansatz bestand darin, die Netze ohne deren letzte Schichten zusammenzufügen und drei weitere Schichten hinzuzufügen. Auch hier wurde ein AUC von 62% erreicht, es hat sich somit keine Verbesserung gegenüber dem trivialen Ansatz ergeben. Als letzter Ansatz wurde klassisches

Transfer Learning ausprobiert. Die trainierten Modelle und verwendeten Transformatoren der Datenbasis werden von der Modellierungsroutine gespeichert und stehen somit datengetriebenen Services zur Verfügung. Mit diesen Modellen konnten gute Ergebnisse erzielt werden. Somit ist eine grundlegende Anwendbarkeit der Transfer Learning Modelle gezeigt. Für die Weiterentwicklung der Modelle müsste eine erweiterte Datenbasis vorliegen.

Die Ergebnisse wurden im **UAP 6.5** (Evaluation & Dissemination) qualitativ bewertet, um die Anwendbarkeit des Assistenzsystems zu evaluieren. Aufgrund fehlender Produktionsdaten des assoziierten Partners wurde das System mit anderen Datensätzen validiert und evaluiert. Ein Anwendungsfall bildet ein frei zugänglicher Datensatz zur Produktion von Kaffee, welcher ähnliche Eigenschaften wie der Anwendungsfall aus der Gießereibranche aufweist. Mit Hilfe des Datensatzes konnte die einfache Anwendbarkeit und Visualisierung der Ergebnisse validiert werden. Diese und die Anwendung aus dem Bereich der Gießereibranche zeigte eine prototypische Implementierung des Frameworks als webbasierte datengetriebene Anwendung unter Verwendung der schnellen Prototyping-Python-Bibliothek Streamlit. Der funktionale Prototyp umfasst alle vorgeschlagenen Dienste für die Modellierung und alle Dienste für die Entscheidungsunterstützung der Anwender. Für ein tiefgreifendes Proof of Concept wurde das System auf weitere Anwendungsfälle aus anderen Branchen angewendet. Die Ergebnisse wurden in der Dissertation von Sebastian Gellrich mit dem Titel „Predictive Quality as a Service for Production Systems“ veröffentlicht. Hier wurde die Anwendung in drei verschiedenen Fallstudien demonstriert. Die erste Fallstudie führte Qualitätsvorschriften für den Aluminium-Schwerkraftkokillenguss von Automobil-Chassisteilen durch. Es zeigte sich, dass LSTM-NNs großes Potenzial haben, zeitliche Abhängigkeiten zwischen aufeinanderfolgenden Aluminiumgussteilen zu modellieren. Anschließend wurde das LSTM-NN innerhalb eines genetischen Algorithmus verwendet, um Prozesseinstellungen für die In-situ-Prozesssteuerung für erwartete NOK-Teile zu empfehlen. Die zweite Fallstudie befasste sich mit der Qualitätsdiagnostik in der Rohstoffherstellung von C-Fasern. Sie zeigte die allgemeine Anwendbarkeit des Konzepts für die kontinuierliche Fertigung. In der letzten Fallstudie wurde die Qualitätsprediktion für die (Re-)Fertigung von überformten CFRP durchgeführt. Es zeigte das große Potenzial, Ingenieurdaten in den Betrieb durch FEM-Surrogatmodelle zu übertragen. Somit konnte qualitativ bewertet werden, dass das entwickelte Framework ein großes Potenzial vor allem im Bereich der Zeiteinsparung für die Anwendbarkeit von KI in der Produktion sowie der Reduktion des Modellierungsaufwands aufweist, was die Anwendung ebenfalls für Nicht-Experten ermöglicht. Weiterhin zeigten die Anwendungsfälle, dass die Modellierungsroutine ein großes Potenzial beim Einsatz in Prozessketten zur Reduktion des Ausschusses und Stabilisierung der Prozesse aufweist.

1.2 Demonstrator

Die einzelnen Implementierungen wurden gemeinsam auf einem System (Server) deployed und mit den Anlagen sowie entsprechenden Terminals verbunden. Das Setup des Demonstrators ist in Abbildung 10 dargestellt.

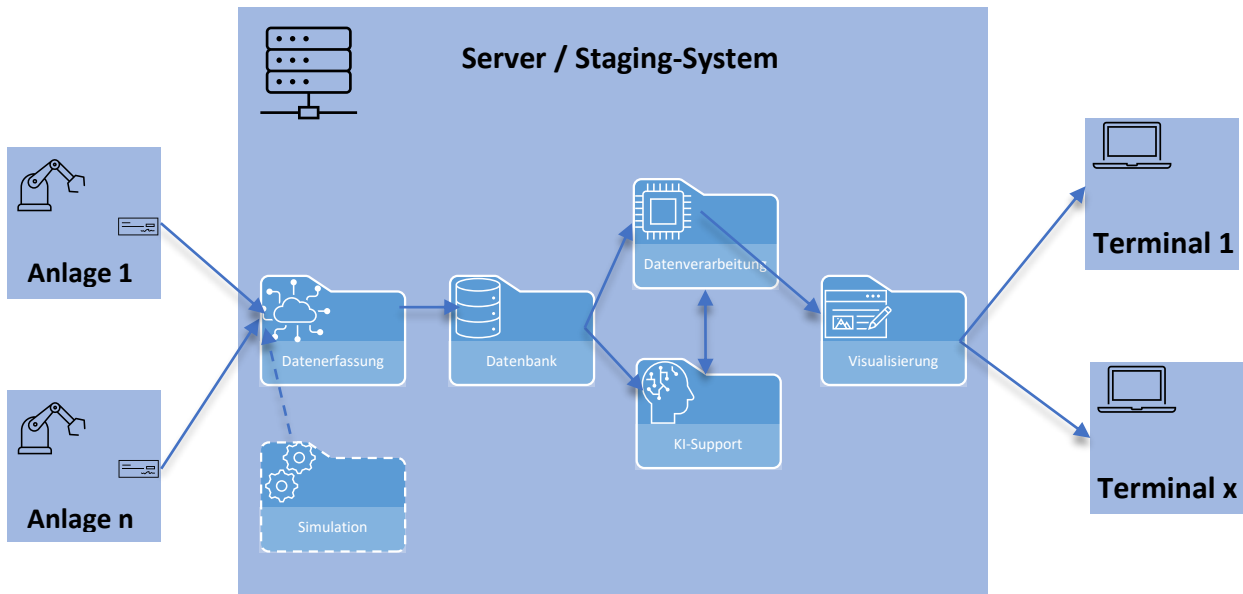


Abbildung 10: Setup des Demonstrators

Die einzelnen Dienste (Datenerfassung, Simulation, Datenbank, Datenverarbeitung, KI-Support, Visualisierung) wurden dabei in einzelnen Podman-Containern auf einem leistungsfähigen Server deployed. Die Dienste haben dabei folgende Inhalte:

- **Datenerfassung:** OPC UA-basierte Erfassung der Daten der einzelnen Anlagen, Entgegennahme der Events sowie Aufbereitung für die effiziente Speicherung
- **Simulation:** Hilfssystem zur Simulation der Datengenerierung durch die Anlagen, nicht zum KI-Training geeignet
- **Datenbank:** Vereinheitlichte, Eventsourcing-basierte Speicherung der erfassten Daten
- **Datenverarbeitung:** Verarbeitungslogik für die erfassten Daten, Nachbearbeitung der KI-Prediction
- **KI-Support:** Plattform für verschiedene KI-Modelle, die als Grundlage für die Assistenzfunktion dienen
- **Visualisierung:** Webbasiertes responsive Frontend-System zur Interaktion mit den Nutzern

Der Demonstrator wurde während der Implementierung auch als Staging-System genutzt, so dass jederzeit ein aktuelles Deployment zur Verfügung stand.

1.3 Meilensteine

- **Meilenstein 1: Konzept**

Beschreibung: Nach dem 12. Projektmonat ist die Konzeption des KI-Interaktionsbaukastens abgeschlossen. Die Arbeiten im Bereich Anforderungen sind beendet. Genauso sind Feature Engineering die generische KI abgeschlossen und eine erste Spezifikation der Softwarearchitektur zur Datenerfassung existiert. Erste Versuche mit der Referenzfallstudie wurden durchgeführt

- **TUBS IWF:** Der Meilenstein 1 konnte erfolgreich abgeschlossen werden. Der Interaktionsbaukasten wurde im ersten Projektjahr in AP 3 und 4 entwickelt. Vollständig eingebunden wurde das Feature Engineering in die generische Modellierungsroutine und in die Web-Applikation auf Basis des Stands der Forschung. Erste Validierungen mit der Referenzfallstudie aus dem Bereich Gießerei konnten ebenfalls erfolgreich im ersten Projektjahr durchgeführt werden.
- **bridgefield:** Seitens bridgefield wurde der Meilenstein 1 mit mehrmonatiger Verzögerung, als Folge der Änderung der Konsortialzusammensetzung, erreicht. Die Arbeiten, die unabhängig von externer Unterstützung durchgeführt werden konnte, wurden jedoch fristgerecht beendet. So konnte anhand des Vorwissens auf vorangegangenen Arbeiten und Anforderungsanalysen die Datenerfassung für die KI-Assistenten nebst grundlegender Datenbankstruktur konzipiert werden. Die Konzeption der Interaktionsmethoden sowie der Darstellung der KI-Informationen verzögerten sich hingegen auch aufgrund der Abhängigkeit von den technischen Rahmenbedingungen (verfügbare Trainingsdaten, möglicher KI-Output).

- **Meilenstein 2: Prototyp**

Beschreibung: Der Interaktionsbaukasten liegt vollständig vor. Die generische KI ist trainiert und die Fähigkeiten des Transfer Learnings wurden evaluiert. Die Softwarearchitektur ist implementiert. Alle Komponenten wurden an der Fallstudie in Betrieb genommen und evaluiert.

- **TUBS IWF:** Der Interaktionsbaukasten konnte vollständig entwickelt und die generischen Ansätze der KI-Modellierungsroutinen trainiert werden. Die Potenziale des Transfer Learnings wurden an Fallstudien evaluiert. Primäre Fallstudie war der Datensatz aus dem Bereich Gießerei. Der Einsatz von Transfer Learning wurde auch auf Basis durchgeführter Vorstudien im Bereich des Kokillenguss erweitert und

bewertet. Anhand der Fallstudie wurden alle Komponenten des Frameworks und der Web-Applikation durchgeführt und evaluiert.

- **bridgefield:** Die Umsetzung der erstellten Konzepte verzögerte sich ebenfalls mehrmonatig, woraus sich die beantragten und bewilligte Projektverlängerung ergab. Die Datenerfassung nebst semantischem Datenmodell konnte schließlich erfolgreich umgesetzt werden. Die prototypische Umsetzung der Interaktionsmethoden und Darstellung der KI-Informationen konnte ebenfalls erfolgreich abgeschlossen werden. Hier mussten aufgrund der fehlenden Zuarbeiten des ausgestiegenen Partners Cadera eine Reduktion im Umfang der Arbeiten in Kauf genommen werden.

2 Positionen des zahlenmäßigen Nachweises

2.1 Gehälter (Personalkosten)

Die Personalkosten stellen den mit Abstand größten Punkt in der Kostenaufstellung des Projektes dar. Aufgrund der Änderungen in der Zusammensetzung des Konsortiums zusammen mit den Einschränkungen durch Corona konnten seitens **bridgefield** dennoch nicht alle Mittel abgerufen werden, da die verfügbaren personellen Ressourcen entsprechend begrenzt waren, sich aber auch Änderungen in den Abhängigkeiten der Arbeiten der verbliebenen/neuen Konsortialpartner ergaben. Dies führte letztlich zur Straffung einiger Arbeiten, insb. im Bereich der KI-Interaktion.

Die Mittel der **TU Braunschweig** konnten wie geplant abgerufen werden, da die Arbeiten trotz Veränderungen im Konsortium wie geplant starten konnten.

Die Personalkosten der **METOP** wurden erfolgreich und vollständig abgerufen. Aufgrund der Auswirkungen der Corona-Pandemie sowie des verzögerten Projektbeginns seitens der METOP war es jedoch notwendig, alle Aufgaben und Meilensteine zeitlich anzupassen. Dank der kostenneutralen Verlängerung des Projekts konnten diese Aufgaben aber zu einem späteren Zeitpunkt erfolgreich umgesetzt werden. Die Umsetzung erfolgte weitestgehend in Übereinstimmung mit der angepassten Planung, die im Rahmen der Verlängerung eingereicht und genehmigt wurde. Somit konnte trotz der Herausforderungen - Corona und verspäteten Einstieg der METOP - eine erfolgreiche Projektdurchführung sichergestellt werden.

2.2 Beschaffung (Sonstige)

TUBS IWF: Für die Umsetzung der rechenintensiven Modellierungsroutinen wurde ein leistungsfähiger, stationärer Rechner mit starker Grafikkarte, welche sich für das Erstellen und Antrainieren von KI-Algorithmen eignet, beschafft. Dies betrifft vor allem die Arbeitspakete 3, 4 und 6. Durch den stationären Rechner waren eine umfangreichere und schnellere Entwicklung, Umsetzung und Validierung der Modellierungsroutinen möglich. Weiterhin konnten umfangreichere Modelle umgesetzt werden. Vor allem für die Visualisierung in der Web-Applikation war dies von entscheidender Bedeutung, um lange Ladezeiten und Fehlermeldungen zu vermeiden.

Bridgefield: Die benötigte Hardware für das Testsystem als auch für den Demonstrator konnten durch interne Ressourcen (Verwendung bereits verfügbarer Hardware) abgebildet werden. Ein Abruf zur Beschaffung zusätzlicher Mittel erwies sich daher als nicht notwendig.

METOP: Die METOP konnte alle technischen Hilfsmittel durch interne Ressourcen abbilden. Anforderungen und die Erprobung von Testszenarien im Bereich der KI konnten erfolgreich mit der TUBS und bridgefield im Team gelöst werden.

2.3 Reisekosten

Coronabedingt fiel ein großer Teil der in AI-PAT geplanten Dienstreisen aus oder wurde durch Remote-Meetings ersetzt. Daher bleibt der Abruf der Mittel für Dienstreisen seitens **bridgefield** hinter der Planung. Hier ergeben sich ebenfalls seitens **TU Braunschweig** Verschiebungen der Mittel aufgrund der Reisebeschränkung während Covid.

3 Notwendigkeit und Angemessenheit der geleisteten Projektarbeiten

Die geleistete Projektarbeit erwies sich als notwendig und angemessen, da sie entschieden zum Wissensaufbau hinsichtlich des Einsatzes von KI-Assistenten im Produktionsumfeld beigetragen hat. Es konnten Anforderungen ermittelt, Lösungen entwickelt und prototypisch realisiert werden. Gleichzeitig wurden aber auch Herausforderungen aufgezeigt, die es zu lösen gilt. Das angestrebte Forschungsvorhaben konnte wie im Antrag beschrieben nur als Kooperationsprojekt unter Beteiligung aller Partner realisiert werden. Im Besonderen wurden Kompetenzen aus den Bereichen Usability Engineering, Datenakquisition (**bridgefield**), Datenanalyse (**METOP**) und der Prozessoptimierung (**IWF**) benötigt. Die Förderung des Vorhabens war insbesondere notwendig, da die Schaffung der technischen Grundlage für den KI-Interaktionsbaukasten mit nicht unerheblichen

wirtschaftlichen Risiken verbunden war, die anderweitig nicht kompensierbar waren und gleichzeitig die Umsetzung der Zusammenarbeit unterschiedlichster Akteure mit unterschiedlichen Geschäftsmodellen erforderte. Im Besonderen fördert aber auch ein Verbundprojekt mit KMU, Industrie, Forschungseinrichtungen sowie öffentlicher Unterstützung zudem die Sichtbarkeit der erzielten Resultate in den anvisierten Marktsegmenten und Branchen.

Aus der Anforderungsanalyse konnte abgeleitet werden, dass KI-Assistenten neben der Anforderung den Menschen in seiner Arbeit ausschließlich zu unterstützen auch vielen nicht-KI-spezifischen Anforderungen im Produktionsumfeld unterliegen. Umfangreiche Arbeiten wurden zur Erfassung und Aufbereitung der Daten durchgeführt. Hier konnte ermittelt werden, wie die Daten möglichst detailliert aus verschiedensten Produktionslinien und für verschiedenste Produkte erfasst und für die effiziente Weiterverarbeitung durch die KI aufbereitet werden können. Eine generische Modellierungsroutine mit Web-Applikation zur einfachen Anwendung konnte vollständig entwickelt werden und dient als Entscheidungsunterstützung für Anwender aus der Produktion. Die Routine umfasst alle relevanten Schritte des CRISP-DM zur Entwicklung und Durchführung von KI. Bei den Arbeiten an den KI-Modellen selbst mussten zwar aufgrund der Verfügbarkeit der Trainingsdaten Einschränkungen im Umfang der Evaluation hingenommen werden, die grundlegende Herangehensweise konnte aber an verschiedenen Beispielen gezeigt werden. Fokus war hier der Erkenntnisgewinn, wie die Modellierungsroutinen als Entscheidungsunterstützung für Anwender dienen können und so den Einsatz von KI in der Produktion beschleunigen und vereinfachen können.

4 Voraussichtlicher Nutzen und Verwertbarkeit des Ergebnisses

Die im Projekt entstandenen Ergebnisse wird **bridgefield** dafür nutzen, seine Kernkompetenz im Bereich System- und Datenintegration insbesondere in komplexen Brownfield-Szenarien weiter auszubauen. Die Datenerfassung und das semantische Datenmodell sind so konzipiert, dass sie auf verschiedenste Produktionsbereiche anwendbar sind. Durch die Resilienz gegenüber mangelnder Anlagensensorik, heterogenen Produktionsprozessen mit verschiedensten Wegen und Zwischenstationen, die ein Produkt im Produktionsprozess durchlaufen kann, sowie einem hohen manuellen Anteil am Produktionsgeschehen stellt das System die ideale Ergänzung des bridgefield-Portfolios dar. Darüber hinaus ist es flexibel genug, um sich an die oft starren Produktionsprozesse im Brownfield anzupassen.

Die Ergänzung durch KI-basierte, nutzer-zentrierte Assistenten wird bridgefield zusätzlich helfen, die bereits erwähnten manuellen Prozess bsw. bei der Qualitätsüberwachung zu unterstützen und zu optimieren. Natürlich müssen die notwendigen KIs explizit für verschiedene Anwendungsfälle

trainiert werden, dennoch wurde auch hier wurde darauf geachtet, dass die entstandenen Implementierungen weitestgehend kompatibel zu verschiedensten Produktionsbereichen sind.

Aus Sicht der Forschung wendet **bridgefield** die entstandenen Ergebnisse aus AI-PAT bereits im Nachfolgeprojekt ReGAIN³ an. Hier werden die Datenerfassungs-/ und Datenhaltungs-Konzepte aus AI-PAT durch bridgefield angewendet und mit Hilfe von Catena X⁴ für den unternehmensübergreifenden Datenaustausch erweitert. Dabei kommen ähnliche Konzepte für die semantische Aufbereitung/Verarbeitung der Daten zum Einsatz, wie sie in AI-PAT angewendet/entwickelt wurden. Darüber hinaus wird das Wissen zur KI-Entwicklung aus AI-PAT durch bridgefield für die Entwicklung weiterer KIs in ReGAIN eingesetzt.

Für die **TU Braunschweig IWF** steht im Fokus der Verwertung der generelle Wissenstransfer in die Wissenschaft, Industrie als auch Lehre. Die Dissemination der Ergebnisse erfolgt u.a. durch Konferenzteilnahmen sowie durch Beiträge in Fachzeitschriften. Während der Projektlaufzeit wurde die CIRP CMS Konferenz 2022 besucht, um neuste Ansätze in der Forschung im Bereich KI und Entscheidungsunterstützung in das Projekt einfließen lassen zu können und weiterhin die Ergebnisse des Projekts mit Vertretern aus Industrie und Forschung zu teilen und diskutieren. Wie aufgeführt entstand neben einer angestrebten Journal-Veröffentlichung ebenfalls eine Dissertation auf Basis der Arbeiten im Projekt, welche 2024 veröffentlicht wird. Diese dient weiterhin zur Dissemination und weitreichenden Veröffentlichung der Ergebnisse. Weiterhin sind anschließende Promotionsvorhaben, die die Arbeiten aus dem Projekt erweitern, geplant. Zusätzlich fließen Projektergebnisse direkt in die Lehre ein, um so die Ausbildung der Studierenden zu stärken. Im Projekt wurden weiterhin verschiedene studentische Hilfskräfte in die Entwicklung der Modellierungsroutine eingebunden und die Grundlagen der Entwicklung und Programmierung gelehrt. Darüber hinaus erlaubt das Projekt eine Formalisierung der systematischen Entwicklung von datengetriebenen Assistenzsystemen für Produktionsprozesse. Nach Projektende wird die Methode als Ausgangsbasis für Forschungstätigkeiten zur qualitätsorientierten, nachhaltigen Prozessplanung und –steuerung mittels datenbasierter Methoden. Verschiedene öffentlich geförderte Projekte wurden auf Basis der Arbeiten beantragt, in denen die Arbeiten weiterentwickelt werden und die Übertragbarkeit auf verschiedene Anwendungsfälle evaluiert wird. Beispiele hierfür sind das Projekt ReGAIN (Resiliente Automotive-Gießereien durch den Einsatz KI-gestützter Assistenten für nachhaltige Prozesse – FKZ 13IK036E) und das Projekt DigiPro2Green (Digitale Methoden für die Produktentwicklung und zirkuläre Produktion nachhaltiger Leichtbaustrukturen – FKZ 03LB3025A).

³ Resiliente Gießereien durch KI-Assistenten für nachhaltigen Automobilbau

⁴ <https://catena-x.net/>

Die **METOP** kann bezüglich der Verwertung drei wesentliche Bereiche hervorheben:

1) Netzwerk

Im Bereich des Netzwerks konnte die METOP die Verbindungen zwischen den Partnern des Projekts, TUBS und bridgefield, nachhaltig stärken. Besonders hervorzuheben ist die intensivierete Zusammenarbeit mit bridgefield, die zu einer Vertiefung der Partnerschaft geführt hat. Diese enge Kooperation hat eine enge Zusammenarbeit innerhalb von zwei gemeinsamen Projekten im Jahr 2024 ermöglicht.

Das erste Projekt fokussiert sich auf den Einsatz von Künstlicher Intelligenz, speziell auf die Integration und Weiterentwicklung von Large Language Models (LLM). Ziel des Projektes ist es, innovative Lösungen und Anwendungen zu entwickeln, die das Potenzial von LLM im Bereich von Healthcare Assistenzsystemen fokussiert.

Das zweite Projekt widmet sich der fortschrittlichen Datenmodellierung, insbesondere im Bereich graphenbasierter Daten. Dabei bündeln METOP und bridgefield ihre Expertise, um neue Methoden zur Erfassung, Analyse und Interpretation von Daten in graphbasierter Form zu entwickeln. Beide Projekte unterstreichen die strategische Bedeutung der Partnerschaft und eröffnen vielversprechende Perspektiven für die Zukunft.

2) Produktportfolio

Die im Projekt gesammelten Erfahrungen im Bereich der Voraussetzungen für den Einsatz von KI-Lösungen wurden in einem umfassenden Leitfaden zusammengefasst. Dieser Leitfaden ermöglicht es, Unternehmen beim Einsatz von KI-Lösungen nach einem Brownfield-Ansatz gezielt zu beraten, wobei der Schwerpunkt insbesondere auf der Daten- und Systemintegration liegt. Dabei wird besonderer Wert auf die Bereitstellung von Daten und den dazugehörigen Metadaten gelegt, um eine nahtlose Integration und effiziente Nutzung der KI-Anwendungen zu gewährleisten.

Darüber hinaus konnte die Expertise im Einsatz von KI-Lösungen speziell für den industriellen Produktionsbereich erheblich erweitert werden. In Zusammenarbeit mit dem Mittelstand-Digital Zentrum Magdeburg wird kurz- und mittelfristig die Akquise von kleinen und mittleren Unternehmen (KMU) im Bereich Künstliche Intelligenz intensiviert. Diese Zusammenarbeit zielt darauf ab, KMU den Zugang zu innovativen KI-Technologien zu erleichtern und deren Wettbewerbsfähigkeit zu stärken.

Zusätzlich wurde der Bereich der Qualitätssicherung und Performance-Optimierung mit Hilfe von KI in das Leistungsportfolio aufgenommen. Diese Erweiterung ermöglicht es, nicht nur die Effizienz und Zuverlässigkeit von Produktionsprozessen zu steigern, sondern auch die kontinuierliche Verbesserung und Anpassung der Systeme an neue Anforderungen sicherzustellen. Damit werden

Unternehmen in die Lage versetzt, ihre Prozesse fortlaufend zu optimieren und sich den Herausforderungen der digitalen Transformation erfolgreich zu stellen.

3) Forschung & Entwicklung

Die im Projekt gesammelten Erfahrungen und Entwicklungen im Bereich Künstliche Intelligenz (KI) fließen in neue KI-Projekte ein. In Zusammenarbeit mit dem Fraunhofer Institut, der Otto-von-Guericke-Universität Magdeburg (OVGU), der Ingenieurplanungs- und Komplexbaugesellschaft mbH, der TragWerk Software, der Ingenics AG und der Schaeffler Gruppe wurde ein umfassender Forschungsvoranschlag im Bereich Generative AI (GenAI4FFD) eingereicht, der in der ersten Begutachtungsrunde positiv bewertet wurde. Dieses Projekt zielt darauf ab, innovative Lösungen im Bereich der generativen KI zu entwickeln und deren Anwendungsmöglichkeiten zu erforschen.

Zudem werden die gewonnenen Erkenntnisse zur Datenakquise und Integration von KI-Lösungen in die Lehre an der Hochschule Harz (HS-Harz) integriert, wobei Prof. Dr. Leich eine führende Rolle übernimmt. Dies ermöglicht es, zukünftige Fachkräfte gezielt auf die Herausforderungen und Anforderungen der praktischen Anwendung von KI vorzubereiten.

Darüber hinaus werden im Bereich des Innovationsmanagements die identifizierten Risiken und Herausforderungen beim Einsatz von KI-Lösungen in praxisnahe Lernmodule überführt. Diese Module sollen dazu beitragen, Studierende und Fachkräfte für mögliche Probleme zu sensibilisieren und ihnen Strategien zur erfolgreichen Implementierung von KI in verschiedenen Unternehmensbereichen zu vermitteln. Auf diese Weise wird das Wissen aus dem Projekt nicht nur zur Weiterentwicklung technologischer Lösungen genutzt, sondern auch zur Förderung eines nachhaltigen und verantwortungsvollen Umgangs mit Künstlicher Intelligenz.

5 Wissenschaftlicher und technischer Fortschritt Dritter auf dem Gebiet des Vorhabens

Im Laufe des Forschungsprojektes AI-PAT wurden insbesondere im Bereich KI allgemein als auch auf dem Gebiet des Datenaustausches Fortschritte durch dritte erzielt.

Während Large Language Modelle (LLM) inzwischen beeindruckende Ergebnisse in der Konversation mit Menschen als auch auf Gebieten, die bisher ausschließlich der menschlichen Domäne zugeordnet wurden, erzielen, brauchen sie jedoch auch enorme Rechenkapazitäten, um ihre Aufgabe performant zu erfüllen. Daher geht der Trend inzwischen weg von großen Convolutional Neuronal Networks (CNNs) hin zu kleinen smarten CNNs, für die jedoch die Qualität und Aufbereitung der Trainingsdaten von noch größerer Bedeutung ist als bei den LLMs. Somit

folgen die in AI-PAT gewählten Ansätze bereits diesem Trend, kleine spezifische KIs ressourcenschonend für einzelnen Anwendungsfälle zu trainieren.

Auch auf dem Gebiet des Datenaustausches im Produktionsumfeld gab es mit Catena X Weiterentwicklungen. Diese erweitern die Datenerfassung im Shopfloor um den unternehmensübergreifenden Datenaustausch mit Hilfe geeigneter Datenmodelle. Sie sind daher als Ergänzung zu den in AI-PAT entwickelten Datenerfassungsmethoden zu sehen.

6 Erfolgte und geplanten Veröffentlichungen des Ergebnisses

Erfolgt:

- Dissertation; Sebastian Gellrich: “Predictive Quality as a Service for Production Systems”; 2024.
- Poster; Christoph Engel, Stephan Dassow: “Eventbasierte Erfassung und Aufbereitung von Produktionsdaten zur KI-Assistenz”; Mittelstandskonferenz Berlin 2023.

Geplant:

- Veröffentlichung im Journal of Manufacturing and Materail Processing; Sebastian Gellrich, Anna-Sophia Wilde et al.: “Concept for predictive quality in carbon fibre manufacturing”; voraussichtlich 2024.
- Vortrag; Christoph Engel: “Semantische Datenerfassung im Produktionsumfeld (nicht nur) für KI-Anwendungen”; INPLAS-Fokusgruppe Berlin 2024