

WHITE PAPER

ML4P – VORGEHENSMODELL MACHINE LEARNING FOR PRODUCTION



ML4P

MACHINE LEARNING FOR PRODUCTION



VORWORT

Maschinelles Lernen wird vermehrt und mit großem Erfolg in der industriellen Produktion eingesetzt. Gängige Beispiele umfassen die Erhöhung der Produktqualität, die Reduktion des Ressourceneinsatzes, die Verringerung ungeplanter Maschinenausfälle durch vorausschauende Wartung und vieles mehr. Maschinelles Lernen in der Produktion ist aber derzeit noch weit davon entfernt als ein Standardwerkzeug einsetzbar zu sein. Ursachen dafür werden im Folgenden kurz umrissen:

- Viele ML-Experten haben derzeit wenig praktische Erfahrungen in der produzierenden Industrie. Dem gegenüber haben die wenigsten Produktions- und Automatisierungsingenieure Erfahrungen mit Machine Learning und dessen mathematischen Grundlagen. Diese Heterogenität in den Disziplinen macht die Schaffung einer gemeinsamen Grundlage für das Verständnis der Domäne und der Technologien für eine Zusammenarbeit unabdingbar.

- Anpassungen von Produktionsanlagen und Produktionsausfälle durch Stillstandszeiten sind mit enormen Kosten verbunden. Es ist eine Herausforderung im Voraus den Einfluss ML-basierter Systeme auf geschäftsrelevante Kennzahlen abzuschätzen. Spätestens für die Freigabe von Mitteln für größere Investitionen sind solche Voraussagen aber zu treffen.

- Es findet noch wenig Wiederverwendung von Bausteinen für ML-basierte Systeme im Produktionsumfeld statt. Die meisten Projekte starten mit wenig mehr als Standard-Bibliotheken für ML. Durch wiederverwendbare Bausteine für häufige Aufgabenstellungen könnte Entwicklungszeit gespart und von den Erfahrungen aus der Vergangenheit profitiert werden.

- Viele ML-Projekte sind davon abhängig, dass eine kleine Gruppe von ML-Experten die Anwendungsdomäne und die technischen Lösungen komplett durchdringt. Bei steigender Komplexität und Größe der Produktionsanlagen ist dies nicht mehr zu leisten. Die Skalierung auf große Projektteams setzt eine andere Organisation und Werkzeuge für strukturiertes Wissensmanagement voraus.

- Nach der Entwicklung und Inbetriebnahme sind ML-basierte Systeme in der Produktion nicht als langfristig stabil anzusehen. Durch die Änderung von Rahmenbedingungen, wie etwa Verschleiß und Wartung, veränderte Eigenschaften von Eingangsmaterialien, sowie strukturelle Umbauten am Prozess verändert sich die Prozessdynamik. Die Modelle müssen im Betrieb an eine veränderte Prozessdynamik angepasst werden.

Diese Herausforderungen sollen durch ein standardisiertes Vorgehensmodell mit zugehörigen Werkzeugen analog zu den Ansätzen des Systems Engineering überwunden werden. Existierende Vorgehensmodelle aus dem klassischen Data Mining, wie zum Beispiel CRISP-DM (Wirth & Hipp, 2000), sind ohne den Hintergrund der industriellen Produktion entwickelt worden und können auf dessen Spezifika nicht eingehen. Im Fraunhofer Leitprojekt **ML4P: Machine Learning for Production** wurde, gemeinschaftlich mit sechs beteiligten Fraunhofer Instituten, ein **toolgestütztes Vorgehensmodell für maschinelles Lernen in der Produktion** entwickelt. Ergebnis des Vorgehensmodells ist eine ML-basierte Anwendung im kontinuierlichen Betrieb in der Produktion. Das Vorgehensmodell kapselt Best Practices und ermöglicht die Skalierung auf große Teams durch entsprechende Planung, die Quantifizierung des Fortschritts und klare Schnittstellen zwischen Verantwortlichkeiten. Entsprechende Werkzeuge sorgen für die direkte Anwendbarkeit der Konzepte und eine hohe Geschwindigkeit in der Ausführung. In diesem Whitepaper wird das Vorgehensmodell in seinen Grundzügen vorgestellt.

Viel Freude und Erkenntnisse beim Lesen wünschen

Jürgen Beyerer (Projektleiter)

Julius Pfrommer (Teamleiter Vorgehensmodell)

Das ganze ML4P Projektkonsortium

ÜBERSICHT DES VORGEHENSMODELLS

Phasen des Vorgehensmodells

Das Vorgehensmodell ist in **sechs Phasen mit klaren definierten Ergebnissen** gegliedert. Für jede Phase ist eine Reihe von Phaseergebnissen definiert. Diese münden in einen Meilenstein, an dem die Phaseergebnisse begutachtet werden und eine Planung der nächsten Schritte vorgenommen wird.

Das Vorgehensmodell befindet sich in einem Spannungsfeld zwischen agilem und linearem Vorgehen. Viele ML-Projekte starten mit einer großen Unsicherheit bezüglich der Datenlage und der Eignung verschiedener Lösungsansätze. Diese Unsicherheit begünstigt ein agiles Vorgehen, bei dem im Projektverlauf laufend nachjustiert wird. Auf der anderen Seite sind Änderungen und Experimente an realen Produktionsanlagen kostenintensiv und setzen eine gute Planung voraus. Um dieses Spannungsfeld aufzulösen, werden agiles und lineares Vorgehen kombiniert:

1. Agiles Vorgehen innerhalb der Phasen
2. Lineares Vorgehen über Phasen hinweg

Ein Zurückspringen auf vergangene Phasen sollte nur in Ausnahmefällen, wie etwa bei einer extern veranlassten Veränderung des Anwendungsbereichs und der -Ziele, vorgenommen werden.

Durchgängige Artefakte

Neben den definierten Phaseergebnissen fußt das Vorgehensmodell auf zwei **durchgängigen Artefakten** – Dokumente und Datenstrukturen, die im Vorgehensmodell initial erstellt und in allen folgenden Phasen angewandt und fortgeführt werden. Sie repräsentieren den aktuellen Entwicklungsstand und sind zentral für das Wissensmanagement:

1. Machine Learning Pipeline Diagramm
2. Virtuelle Prozessakte

Phasen des Vorgehensmodells



Beide durchgängigen Artefakte werden auf den kommenden Seiten im Detail vorgestellt.

Rollenmodell

In den einzelnen Phasen werden unterschiedliche Kompetenzen und Disziplinen benötigt. In einem **Rollenmodell** sind die benötigten Disziplinen für die Phasen ausgeführt. Dabei kann eine Person auch mehrere Rollen ausfüllen. Das Fehlen einer Projektrolle im Team ist ein starker Hinweis für Probleme und Verzögerungen im weiteren Projektverlauf.

Technische Architektur und Werkzeugunterstützung

Das Vorgehensmodell zielt auf eine planbare und wiederholbare Durchführbarkeit von ML-Projekten in der industriellen Produktion ab. Durch die Entwicklung von Best-Practices und wiederkehrender Vorgänge bietet es sich an, Projekte anhand des Vorgehensmodells durch einheitliche technische Werkzeuge zu unterstützen. Dafür wird eine Gesamtarchitektur vorgestellt, an der die Werkzeuge zu einer ganzheitlichen Lösung im Sinne einer Machine Learning Pipeline integriert werden.

MACHINE LEARNING PIPELINE DIAGRAMM

Die Eignung eines maschinellen Lernverfahrens hängt von der Verfügbarkeit qualitativ hochwertiger Datenbestände ab. In klassischen Data Mining Projekten werden bis zu 80% des Aufwands für die Aufbereitung der Datenbestände verwandt. In der industriellen Produktion ist eine nachträgliche Aufbereitung der Daten aber nur mit großem Aufwand machbar. Wenn zum Beispiel eine Zuordnung zwischen Datenströmen nicht möglich ist, kann eine nachträgliche Aufbereitung sogar unmöglich sein! Etwa wenn Messungen von Produktproben in externen Labors durchgeführt werden und deren Ergebnisse erst nach einigen Wochen zurückgeführt werden, ist es notwendig, Bauteilen IDs zu geben und diese mit den Produktionsdaten und Qualitätsdaten zu verbinden. Nur bei einer sorgfältigen Datenhaltung ist noch eine Zuordnung zu den Rahmenbedingungen der ursprünglichen Produktion möglich.

Im Vorgehensmodell wird die Datenverarbeitung ganzheitlich im Sinne einer durchgängigen Verarbeitungskette betrachtet. Dafür wird ein sogenanntes Machine Learning Pipeline Diagramm aufgestellt. Ein solches ML Pipeline Diagramm ist zunächst ein visuelles Hilfsmittel zur Unterstützung menschlicher Kommunikation und der Dokumentation des gemeinsamen Prozessverständnisses. Daneben sind ML Pipeline Diagramme ein gutes Mittel zur Kommunikation mit dem Management.

In kleinen Projekten können die Schritte von der Datenerfassung bis zur Modellbildung noch von Hand ausgeführt werden. Für den automatisierten kontinuierlichen Betrieb und die Verarbeitung großer Datenmengen ist dies jedoch nicht mehr möglich. In solchen Fällen wird die ML Pipeline in strukturierter Weise auf Technologien für den kontinuierlichen automatisierten Betrieb abgebildet und umgesetzt.

Die Phasen des Vorgehensmodells beziehen sich auf die (Weiter-)Entwicklungen und den Betrieb einer Machine Learning Pipeline:

1 In Phase 1 wird die Ist-Situation und die Ziel-Situation für das ML Pipeline Diagramm aufgestellt. Diese Aktivität ist ein wichtiger Schritt, um ein gemeinsa-

mes Verständnis zwischen ML-Experten und Prozessexperten sicher zu stellen. Die Darstellung ist dabei noch rein konzeptionell und unabhängig von konkreten Technologien. Hierbei ist es wichtig den Ist-Zustand von einem idealisierten Zielzustand zu unterscheiden.

2 In Phase 2 wird die ML Pipeline als Proof of Concept (PoC) verfeinert und validiert. Dafür findet eine erste partielle technologische Umsetzung statt. Diese ist aber in der Regel noch nicht für den dauerhaften Betrieb geeignet. Gängige Mittel zur Umsetzung des PoC umfassen die manuelle Ausleitung von Stichproben aus der Produktion und Datenabzüge von freistehenden (nicht vernetzten) Datenbanken der einzelnen Maschinen.

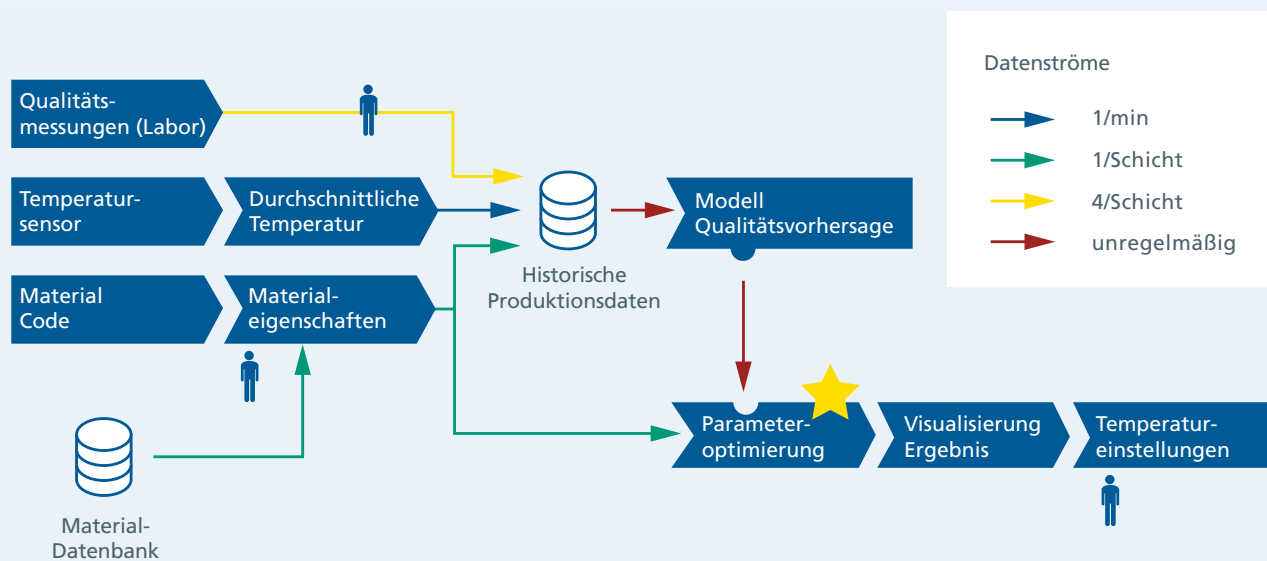
3 In Phase 3 wird die ML Pipeline in einer Systemspezifikation auf Technologien für den Dauerbetrieb abgebildet. Insbesondere Schnittstellen zwischen technischen Komponenten der ML Pipeline und Mensch-Maschine-Schnittstellen für die Interaktion mit dem Anlagenbediener sind im Detail zu betrachten. Die Systemspezifikation ermöglicht die Schätzung von Kosten einer Lösung für den dauerhaften Betrieb.

4 In Phase 4 wird die ML Pipeline als Bestandteil der Produktionsanlage für den kontinuierlichen Betrieb umgesetzt und in Betrieb genommen.

5 In Phase 5 wird die ML Pipeline an das produzierende Unternehmen übergeben.

6 Phase 6 beschreibt den Betrieb, sowie Wartung, Pflege und kontinuierliche Verbesserung der ML Pipeline. Dies ist notwendig, insbesondere wenn sich der physische Produktionsprozess durch Verschleiß, geänderte Rahmenbedingungen oder strukturelle Umbauten im Laufe des Betriebs verändert.

Machine Learning Pipeline Diagramm am Beispiel einer Parameteroptimierung



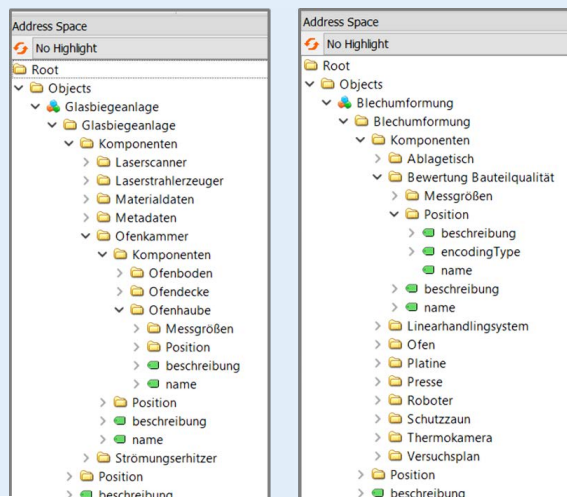
Ein Machine Learning Pipeline Diagramm gibt eine Übersicht über die Datenerhebung und -verarbeitung, Modellbildung und Entscheidungsfindung in einem ML-unterstützten Produktionsprozess. Erste Erfahrungen haben gezeigt, dass sich das ML-Pipeline Diagramm sowohl für die Kommunikation mit nicht-technischen Stakeholdern als auch für die iterative Verfeinerung und Abbildung auf konkrete Technologien eignet.

Im Beispiel wird die optimale Anpassung von Prozessparametern (Ofentemperatur) an schwankenden Eigenschaften in den Eingangsmaterialien betrachtet. Dazu werden auf der linken Seite des Pipeline Diagramms die notwendigen Daten erhoben. Dies sind die Qualitätsmessungen aus dem Labor, die kontinuierlich erhobene Ofentemperatur und die aktuellen Materialeigenschaften, welche aus einer zentralen Datenbank abgerufen werden. Die Datenströme sind farblich entsprechend der Häufigkeit der Übertragung markiert. Die Datenbank wird genutzt, um unabhängig erhobene Daten zusammen zu führen und gemeinsam zu betrachten. Stehen ausreichend historische Daten zur Verfügung, so wird mit ML-Ver-

fahren ein datengetriebenes Vorhersagemodell für die Produktqualität erstellt. Dieses Modell ist die Grundlage für die Optimierung der Ofentemperatur unter Kenntnis der aktuellen Materialeigenschaften. Die Ergebnisse der Optimierung werden visualisiert und vom Prozessbediener am Ofen eingestellt.

Die verfügbaren Operationstypen im ML Pipeline Diagramm sind Quelle, Senke, Stream-Verarbeitung, Persistierung (Datenbank), Modellbildung und Modellanwendung. Dabei können nur passende Schnittstellen verbunden werden (Dreieck: Datenstrom, Halbkreis: Modell-Transfer) und das Diagramm muss abgeschlossen sein – es sollen keine Operationen mit unbenutzten offenen Schnittstellen hinterlassen werden. Dies führt dazu, dass das Diagramm Ende-zu-Ende geführt wird. Von der Datenentstehung über die wertschöpfende Entscheidungsfindung bis zur Anwendung der Entscheidung. Einige Schritte in der Verarbeitungskette können manuell ausgeführt werden. Dies ist durch eine Personen-Ikone gekennzeichnet. Entscheidungen mit Auswirkung auf den Prozess sind durch einen Stern markiert.

VIRTUELLE PROZESSAKTE



Der für die ML-Anwendung relevante Produktionskontext wird in der virtuellen Prozessakte beschrieben. Neben den detaillierten Betriebsdaten zum Prozess sind Kontextinformationen für die Entwicklung und Anwendung der ML-Modelle zentral. Hierzu zählen Informationen zur Struktur, sowie zu Zusammenhängen zwischen Sensorinformationen, funktionale Beziehungen in der Anlage und Ursache-Wirkungs-Beziehungen wie Erfahrungswissen zur Fehlerursachen.

Dabei ist die Begleitung des gesamten Anlagenlebenszyklus wesentlich, in dessen Verlauf sich die Produktionsanlage durch Produktänderungen, Erweiterung, Instandhaltung, Optimierung und Umrüstung stetig wandelt. Daher ist es relevant, dass für historisch erhobene Daten aus der Produktion der **Anlagenkontext** verfügbar ist. Denn nur so ist eine Vergleichbarkeit über einen längeren Zeitraum gegeben.

Die virtuelle Prozessakte ist eine Informationsquelle, welche für das Projektteam relevantes Wissen über die Anlage bereit hält und während der gesamten Projektzeit immer wieder adaptiert und aktualisiert wird. Hierzu zählen beispielsweise Strukturinformationen, Engineeringdaten, CAD-Modelle, Betriebsparameter, Fotos, Messdaten und so weiter. Zudem sollte ein Teil der Prozessakte darin bestehen, Informationen in einer maschinell durchgängig verarbeitbaren Repräsentationsform vorzuhalten, sodass diese beispielsweise direkt für ML-Verfahren verwendet werden können. Prinzipiell ist aber jede Art von Wissen relevant, welches hilft die letztendliche ML-Aufgabe zu lösen. Zu Beginn eines Projektes sollte die virtuelle Prozessakte zumindest die Systemtopologie, sowie die im Prozess schon erzeugten Messdaten inklusive deren Metadaten vorliegen haben.

Bei der Umsetzung von ML-Modellen für Bestandsanlagen (»Brown Field«) muss zunächst die existierende Datenlage zur Anlage und zum Anwendungsumfeld erfasst werden. Als Strukturierungshilfe bietet das Vorgehensmodell das nebenstehende Schalenmodell. Es unterscheidet die folgenden Datenarten:

Systemtopologie

Das Ordnungsprinzip für die virtuelle Prozessakte ist die funktionsbezogene, produktbezogene oder ortsbezogene Systemtopologie der Produktionsanlage (VDMA, 2019). Abhängig von der gewählten Topologie sollten für die relevanten elektrischen und mechanischen Bauteile zumindest die Position, sowie deren Aufgabe erfasst sein. Zusätzlich zur Topologie erfolgt anhand dieser zwei Informationsmodelle die Annotation der Messdaten (z.B. welche Messeinheit und Bauteilzugehörigkeit). Im Beispiel von Abbildung 3 erfolgte die Modellierung in Form von OPC UA Nodesets.


Messdaten

Sensor/Aktorsignale sind normalerweise eine der relevantesten Eingangsgrößen für ML-Verfahren. Daher sollten diese zu Beginn ein Projektes mit zusätzlichen Meta-Informationen in der Prozessakte hinterlegt werden. Hierzu zählt beispielsweise die Messeinheit, der Anlagenzustand bei Aufnahme der Messung, eine Zuordnung des Messwertes zu einem Bauteil oder ein zusätzlicher Zeitstempel bei asynchroner Messung (z.B. bei Qualitätsmessungen in einem Labor). Zudem sollte darauf geachtet werden, dass der Zugriff auf die Messdaten mittels einer standardisierte Schnittstelle erfolgt.

1 Beispiel für die Systemtopologie als Ordnungsprinzip für die Virtuelle Prozessakte. Hier beispielhaft dargestellt für die Prozesse zur Glasbiegung (links) und Blechumformung (rechts).

1. Grundlegende Bestandsdaten: Diese Informationen sind grundsätzlich für Produktionsanlagen erforderlich und können mit geringem Aufwand bereitgestellt werden, z.B. Typenschild und Herstellerdokumentation. Die Bestandsdaten umfassen beispielsweise Typ, Seriennummer und Hersteller der Anlage, Automatisierungsgrad und verfügbare Messwerte der Sensoren.

ML4P-Schalenmodell zur Erhebung der verfügbaren Anlagen- und Prozessdaten



2. Erwartbare Anlagendaten: Diese Kategorie ergibt sich aus der CE-Kennzeichnungspflicht und den gängigen Vorgehensweisen im Anlagenbetrieb fertiger Unternehmen. Dazu zählen Konstruktionsdaten und -pläne, Hard- und Software des Steuerungssystems, Handbuch vom Hersteller, Fehlerinformationen, Gefährdungsanalyse, Anlagenstruktur für den Service und weitere Stücklisten (z.B. Ersatzteilstückliste). Bei modernen Produktionsanlagen zählt auch häufig der Zugriff auf aktuelle Zustandsdaten über die Steuerung in diese Kategorie. Dieser Zugriff ist auf jeden Fall für die ML-Anwendung wichtig.

3. Verfügbare Zusatzdaten: Abhängig vom konkreten Anwendungsfall liegen ggf. spezielle Informationen vor, die für die spezifische Produktion und Maschine relevant sind. Bei den Anwendungsbeispielen trifft dies auf die Biegung von Glas zu, hier liegen Informationen aus Materialsimulationen vor. Diese bieten zusätzliche Hinweise für die ML-Erstellung und -Anwendung, enthalten komplexe Ursache-Wirkungs-Zusammenhänge und können zur Prüfung der Aussagekraft erstellter ML-Modelle herangezogen werden.

4. Zusätzlich erforderliche Daten: Auf Basis des Erfahrungswissens von Anlagenbetreiber und -hersteller liegen Vermutungen zu Ursache-Wirkungs-Beziehungen in der Anlage vor. Daraus ergeben sich die erfahrungsbedingt zusätzlich erforderlichen Informationen, die noch zur Anlage erhoben werden müssen. Dies kann beispielsweise die Nachrüstung von Sensoren für Umgebungstemperatur und -feuchtigkeit sein, die in einem Klebprozess erfahrungsgemäß die Verbindungsqualität beeinflusst.

ROLLEN IM VORGEHENSMODELL

Machine Learning in der Produktion erfordert die Zusammenarbeit heterogener Disziplinen. Zu Beginn jeder Phase werden die notwendigen Projektrollen definiert und auf vorhandenes Personal und verfügbare Kapazitäten abgebildet. Dabei kann eine Person auch mehrere Projektrollen vereinen. Eine Projektrolle ohne verantwortliche Person ist ein starker Indikator für Probleme und Verzögerungen im weiteren Projektverlauf.

Auszug der Rollen im Vorgehensmodell

Projekt-Sponsor Der Projekt-Sponsor gibt das Budget für das Projekt frei und hat den notwendigen Einfluss innerhalb der Organisation.

Prozessexperte Der Prozessexperte kennt den Produktionsprozess und die relevanten Zusammenhänge.

Prozessbediener Die Prozessbediener interagieren täglich mit dem Prozess. Sie haben wichtiges Erfahrungswissen, können dies aber meist nicht quantitativ begründen.

Automatisierungsingenieur Der Automatisierungsingenieur kann Änderungen an der Prozesssteuerung vornehmen. Dies ist notwendig, um zusätzliche Sensorik und Aktorik in den Prozess einzubringen oder um weitere Datenkanäle zu etablieren.

Verantwortlicher für IT-Sicherheit Oftmals müssen Veränderungen in Datennetzwerken und speziell der Kommunikation über die Grenzen des Werksgeländes hinaus mit der zentralen IT-Sicherheit abgestimmt werden.

ML-Experte Der ML-Experte kann datengetriebene Modelle erstellen und bewerten. Er verfügt über ein grundlegendes Prozessverständnis.

PHASE 1: ANALYSE UND ZIELSETZUNG

In der ersten Phase des Vorgehensmodells werden die Wirkzusammenhänge in einem Team aus ML- und Prozessexperten gemeinsam analysiert und auf der Basis definierter Projektziele ein Lösungsansatz abgeleitet. Der Lösungsansatz wird als ML-Pipeline Diagramm visualisiert. Darüber hinaus wird ein Prozessdossier aufgesetzt, um Informationen zum Produktionsprozess und Datensätze strukturiert zu verwalten. Abschließend wird anhand der Übersicht zum Lösungsansatz aus dem ML-Pipeline Diagramm definiert, welche Kompetenzen und Projektrollen in den kommenden Phasen involviert sein müssen.

Aufbau des Prozessverständnisses

Die ML-Experten machen zu Beginn des Projekts häufig zum ersten Mal Begegnung mit dem Produktionsprozess und der Anlage. Eine generelle Vorstellung und vor-Ort-Besichtigung des Prozesses ist in der bisherigen Erfahrung unumgänglich. Wichtig ist dabei, dass die gewonnenen Erkenntnisse strukturiert vorgehalten werden, um zukünftigen Teammitgliedern einen einfachen Einstieg zu ermöglichen.

Definition quantifizierbarer Ziele

Für eine strukturierte Vorgehensweise ist es wichtig zunächst Ziele zu definieren, um anschließend die technischen Ansätze zur Zielerreichung abzuleiten. Die Ziele sollten quantifizierbar sein a), um den Fortschritt der Zielerreichung bewerten zu können und b), um Aufwand und Nutzen für Investitionsentscheidungen und technische Varianten vergleichen zu können.

Durchgängiges Artefakt: ML-Pipeline

Die Entwicklung von Zielen und Maßnahmen ist eng mit der Darstellung als Machine Learning Pipeline Diagramm verbunden. Das Diagramm stellt den Zusammenhang zwischen den technischen Maßnahmen und dem Wirkeingriff in den Produktionsprozess dar. Die ML-Pipeline kann zudem den Unterschied zwischen Ist- und Zielzustand darstellen.

Durchgängiges Artefakt: Prozessdossier

In der ersten Phase lernt das Projektteam den Produktionsprozess kennen. Das aufgebaute Wissen um die Anlage, sowie technische Dokumentation und Zugriffe auf Datenbestände werden in der virtuellen Prozessakte festgehalten. So kann ein weiteres Anwachsen des Projektteams und ein Wechsel von spezialisierten Projektmitgliedern möglich gemacht werden. In der ersten Phase wird die grundlegende Struktur der Prozessakte angelegt. Diese orientiert sich am physikalischen oder logischen Aufbau der Produktionsanlage.

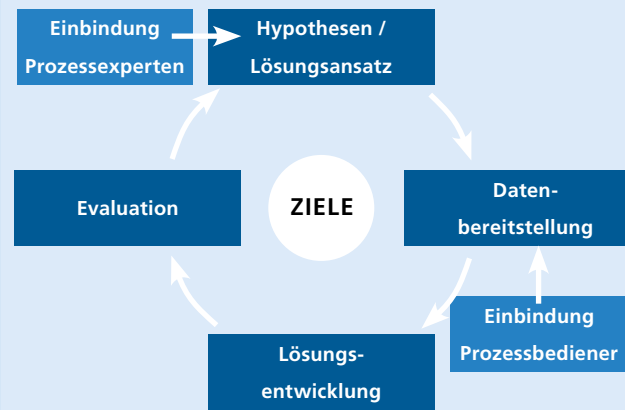
Definition der Projekt-Rollen

An der ML-Pipeline wird ersichtlich, welche Teilsysteme mit welchen Stakeholdern in das Vorgehen involviert sein müssen. In der Vorausschau

Ergebnisse der Phase 1:

- 1. Ein Projektsteckbrief mit der Problemstellung und Basisinformationen**
- 2. Quantifizierte Ziele**
- 3. Initiales ML Pipeline Diagramm**
- 4. Initiale virtuelle Prozessakte**

PHASE 2: PROOF OF CONCEPT



Iterative Vorgehensweise für den Proof of Concept

Der Proof of Concept (PoC) ist eine Nachweisführung, ob und mit welchen Ansätzen die gesteckten Ziele erreicht werden können. Dafür werden exemplarisch Daten aus dem Prozess erhoben und vorverarbeitet, Modelle trainiert und der Einfluss auf Entscheidungen und die Projektziele evaluiert. In einem iterativen Vorgehen werden im PoC der Lösungsansatz und die Hypothesen aus Phase 1 überarbeitet und verfeinert.

Durch den PoC sollen mit einem agilen Vorgehen Lösungsansätze gefunden und mit vertretbarem Aufwand deren Tauglichkeit nachgewiesen werden. So werden teure Investitionen in eventuell nicht notwendige oder nicht wirtschaftliche Umbauten von Maschinen und Anlagen vermieden. Außerdem dient der PoC dazu, Möglichkeiten und Grenzen des Systems zu verstehen und zu einer realistischen Bewertung von Nutzen und Aufwand von ML-basierten Lösungen zu gelangen.

Für den PoC wird ein iteratives Vorgehen angewandt. Dieses ist dadurch motiviert, dass parallel zur Entwicklung der ML-Verfahren immer auch ein Lernprozess bei den ML-Experten sowie den Prozessexperten stattfindet. So ist eine Überarbeitung der initialen Hypothesen und eine Verfeinerung der Ansätze möglich. Die einzelnen Schritte im iterativen Vorgehen für den PoC werden in der Folge kurz skizziert. Der Ablauf wird so lange iteriert, bis eine Lösung gefunden ist, welche die gesteckten Projektziele erfüllt.

Hypothesen / Lösungsansatz Zu Beginn der ersten Iteration wird ein vielversprechender Lösungsansatz ausgewählt und dokumentiert. Zu dem Lösungsansatz wird ein ML Pipeline Diagramm erstellt welches die Datenflüsse beschreibt. Für die Entwicklung des Lösungsansatzes ist die Einbindung der Prozessexperten unabdingbar. In den späteren Iterationen wird der bisherige Lösungsansatz auf Basis der gewonnenen Erkenntnisse verfeinert oder verworfen und durch einen neuen Lösungsansatz ersetzt.

Datenbereitstellung Aus dem ML Pipeline Diagramm sind die notwendigen Datenquellen für den Lösungsansatz ersichtlich. Für den PoC werden mit reduziertem Aufwand Beispieldaten erhoben und für das Training von ML Modellen vorbereitet. Ein wichtiger Aspekt ist die Datenerhebung. Diese

kann für den PoC auch manuell erfolgen. Etwa durch Messkampagnen anhand von Stichproben oder ein manuelles Labeling (Klassifikation). Anschließend werden die Daten bereinigt, strukturiert, extrahiert, angereichert und in ein gewünschtes Format konvertiert. Es wird dringend empfohlen, den Prozessbediener in die Datenbereitstellung einzubeziehen, um die Datenqualität und eventuelle Annotation zu verbessern.

Lösungsentwicklung Nach der Vorbereitung der Daten wird die ML Pipeline soweit umgesetzt, dass mit teilweise manueller Unterstützung ein kompletter Durchlauf berechnet werden kann. Hier können für den PoC auch Technologien zum Einsatz kommen, die nicht für den langfristigen Betrieb vorgesehen sind (zum Beispiel Jupyter- oder Mathematica-Notebooks).

Evaluation Schließlich wird die Performanz der entwickelten ML Pipeline anhand der Projektziele aus Phase 1 evaluiert. Ziel des PoC ist kein absoluter Beweis der Leistungsfähigkeit, sondern Grundlage für eine ganzheitliche Bewertung des Lösungsansatzes. Ist die Performanz nicht ausreichend oder die Umsetzung für den kontinuierlichen Betrieb absehbar nicht praktikabel, so wird der Lösungsansatz angepasst und die Phase 2 geht in eine weitere Iteration.

Ergebnisse der Phase 2:

1. **ML-Pipeline inklusive: Vorverarbeitung, Modellbildung (Ein- und Ausgänge), Parameter und Annahmen und Gültigkeitsbereich der Modelle)**
2. **Quantitative Evaluation der ML-Pipeline**
3. **Vorbereitete Datensätze und Modelle**

PHASE 3: SYSTEMSPEZIFIKATION

In Phase 3 wird ein System für den dauerhaften Einsatz in der Fertigung spezifiziert, denn der PoC wird den Anforderungen im Produktionsalltag noch nicht genügen. Gegebenenfalls sind noch manuelle Schritte in der Datenaufnahme und -verarbeitung zu ersetzen. Die Spezifikation enthält ein detailliertes Betriebskonzept und verweist auf konkrete Technologien und Schnittstellen, insbesondere zum automatisierten Datenaustausch zwischen Maschinen (Maschine-Maschine-Kommunikation) und Interaktionen zwischen Menschen und Maschinen (Mensch-Maschine-Kommunikation). Die Systemspezifikation dient auch einer klaren Abschätzung der direkten technischen und organisatorischen sowie möglicher induzierter Kosten für die Umsetzung und den Betrieb im Verhältnis zum erwarteten Nutzen als Basis für eine ggf. auch gestaffelte Investitionsentscheidung.

Nach Abschluss der Proof-of-Concept-Phase und Aufzeigen der generellen Machbarkeit, ist zu prüfen, welche nächsten Schritte unternommen werden müssen, um die getesteten ML-Verfahren in die Produktionsanlage zu integrieren. Hier werden oftmals mehrere preislich gestaffelte Varianten erarbeitet, so dass der Anwender schlussendlich eine Kosten-Nutzen-basierte Entscheidung treffen kann.

Unter anderem sind technische und organisatorische Aspekte zu prüfen. Ist es beispielsweise notwendig, den Prozess zu verändern oder zusätzliche Sensorik oder Aktorik zu integrieren?

Auch technologische Fragestellungen sind zu untersuchen. Die Art und Weise der Integration der ML-Modelle in eine übergeordnete Anwendungsarchitektur ist ebenso zu klären, wie z.B. Abhängigkeiten mit Komponenten oder Datenquellen, oder welche Anpassungen bei Benutzeroberflächen und Schnittstellen nötig sind, um die ML-Anwendung in die Anlage zu integrieren. Erstrebenswert ist es, auf aktuelle, offene Kommunikationsstandards, wie z.B. OPC UA zu setzen. Weiterhin sollte eine Entscheidung hinsichtlich Edge oder Cloud Computing getroffen werden.

Ebenso ist es wünschenswert, die konzeptionelle ML-Pipeline der Proof-of-Concept-Phase großteils zu erhalten. Jedoch sollte geprüft werden, ob einzelne Komponenten und Datenströme technologisch anders realisiert werden müssen. Im Fokus steht das Ziel, die gesamte Pipeline zu automatisieren. Hierfür sind wieder verschiedene Möglichkeiten zu prüfen und eine jeweilige Kostenabschätzung durchzuführen, die eine Entscheidungshilfe bei der Nachrüstung notwendiger Komponenten liefern sollte.

Während der Systemspezifikation kommt es darauf an, die richtigen Verantwortlichen zusammenzubringen und die möglicherweise noch fehlenden Verantwortlichkeiten und Rollen zu identifizieren und zu verteilen. Vor allem sollte eine enge Kooperation zwischen ML-Experte, Prozessexperte und Automatisierungsingenieur in den Vordergrund treten. Der ML-Experte hat die Datengrundlage im Blick und stellt die notwendigen Modelle und ML-/KI-Komponenten zur Verfügung. Der Prozessexperte bringt das Wissen zu übergeordneten anlagenspezifischen Aspekten ein, die im Sinne von Restriktionen für die ML-Anwendung agieren. Gleichzeitig ist er häufig auch Anwender. Der Automatisierungsingenieur kennt die technischen Restriktionen und Besonderheiten der Anlage und stellt somit ein wichtiges Bindeglied zur im nächsten Schritt geplanten Umsetzung dar. Weitere wichtige Nebenrollen spielen IT-Fachleute und beispielsweise Komponenten-Lieferanten.

Ergebnisse der Phase 3:

- 1. Betriebskonzept und zugehörige Mensch-Maschine-Schnittstellen**
- 2. Abbildung der ML-Pipeline auf Technologien für den Betrieb**
- 3. Varianten / Module für die Umsetzung definiert**
- 4. Angebote für die Umsetzung eingeholt oder intern Kosten geschätzt**

PHASE 4: UMSETZUNG UND INBETRIEBNAHME

In der vierten Phase wird aus der Systemspezifikation ggf. schrittweise ein lauffähiges System für den kontinuierlichen Produktionsbetrieb umgesetzt. Diese Phase muss nicht unbedingt von den ML-Experten aus Phase 1 bis 3 (mit)umgesetzt werden – unter der Voraussetzung, dass die Systemspezifikation ausreichend detailliert für eine Vergabe an weitere Dienstleister oder Entwicklungsgruppen ist, oder auch das Unternehmen selbst die Qualifizierung seiner Belegschaft ausbaut.

In der vierten Phase wird aus der Systemspezifikation ein lauffähiges System für den kontinuierlichen Produktionsbetrieb umgesetzt. Diese Phase muss nicht unbedingt von den ML-Experten aus Phase 1 bis 3 umgesetzt werden – unter der Voraussetzung, dass die Systemspezifikation ausreichend detailliert für eine Vergabe an weitere Dienstleister oder Entwicklungsgruppen ist.

In großen Projekten findet häufig eine gestaffelte Umsetzung und Inbetriebnahme statt. Dies kann sich am physischen Layout der Anlage, der Reihenfolge von Prozessschritten oder auch dem Ablauf in der ML Pipeline (zunächst die Sensorik, dann die Datenkommunikation und -Verarbeitung, zuletzt die Aktorik) orientieren.

In vielen Fällen sind teils händische Arbeitsschritte aus Phase 2 PoC und Phase 3 Systemspezifikation für eine spätere Automatisierung zu überarbeiten. Etwa für den Bereich der Mensch-Maschine-Schnittstellen gibt es häufig erst spät weiteres Feedback vom produzierenden Unternehmen.

Prinzipiell können die Phasen 3 und 4 bei einem agilen Vorgehen zusammen betrachtet werden. Meistens ist die Umsetzung und Inbetriebnahme aber mit Investitionen in Hardware und physischen Umbaumaßnahmen verbunden. Im Produktionskontext ist dabei eine entsprechende vorausschauende Planung notwendig, um unnötige Beschaffungen und Stillstände zu vermeiden.

Für die Inbetriebnahme werden häufig geplante Stillstandszeiten ausgenutzt, wie zum Beispiel Wartungsintervalle und Betriebsferien. Solche festen Termine setzen eine gute zeitliche

Projektplanung voraus. Für die Inbetriebnahme ist die Vor-Ort Präsenz der relevanten Projektrollen Prozessbediener, Automatisierungingenieur und ML-Experte unumgänglich.

Ergebnisse der Phase 4:

- 1. Versionierter Programmcode**
- 2. Systemdokumentation**
- 3. Kriterien zur Prüfung der Gültigkeit von Modellen**
- 4. Definierter Aktualisierungsprozess für Modelle und unterstützende Werkzeuge**

PHASE 5: ÜBERGABE

Nach der erfolgreichen Inbetriebnahme des ML-befähigten Produktionsprozesses erfolgt die Übergabe an den Anlagenbetreiber. Diese Phase soll dem Anlagenbetreiber ermöglichen, den Produktionsprozess autonom betreiben zu können und regelmäßig anfallende Wartungs- und Anpassungsarbeiten weitgehend selbsttätig vorzunehmen. Die Übergabe sollte durch Qualifizierungsmaßnahmen mit Blick auf die neuen ML-Komponenten im Produktionsprozess begleitet werden.

Ziel der Phase 5 ist es, den Anlagen-Betreiber zu befähigen, die mit ML Komponenten modifizierte Anlage selbst, ohne Hilfe vom ML-Experten, zu betreiben und zu warten und in gewissem Grad an geänderte Rahmenbedingungen zu adaptieren.

Das ML Projektteam (Entwicklerteam), das das ML System entworfen und in Betrieb genommen hat, zieht sich zurück. Jetzt kann ein ML Anwenderteam unter Regie des Anlagenbetreibers die Arbeit aufnehmen und sich um die Wartung und ggf. Nachjustierung des ML-Systems kümmern. Je nach Größe des Unternehmens kann das Anwenderteam aus einzelnen geschulten Mitarbeitern oder aus ML Anwendungsexperten bestehen, die mehrere Systeme im Unternehmen betreuen. Dabei sind inhouse Lösungen oder externe Dienstleister möglich. Dem Anlagen-Betreiber wird eine vollständige Dokumentation des ML-Systems übergeben. Diese Dokumentation enthält die virtuelle Prozessakte, die Beschreibung aller Schnittstellen, den Ablauf des Normalbetriebes und die Eskalationsstufen beim Auftreten von Fehlerzuständen. Dem Anlagen-Betreiber wird über entsprechende Schnittstellen die Möglichkeit gegeben, die Dokumentation fortzuführen und an den jeweiligen Stand der Anlage anzupassen. Die Dokumentation ist rollenbasiert aufgebaut (Bedienung, Instandhaltung, Einrichtung). Zusätzlich zur Dokumentation werden rollenbasiert Schulungen angeboten und Schulungsunterlagen für spätere neue Mitarbeiter übergeben.

Um den gesamten Prozess zur ML-Einführung zu Verkürzen, kann die Phase 5 teilweise parallel zur Phase 4 stattfinden.

Die Übergabephase ist ein schrittweiser Prozess, im Laufe dessen alle Hardware- und Softwarekomponenten an den Anlagen-Betreiber übergeben werden. Dabei findet eine Verlagerung der Verantwortung zum Anlagen-Betreiber statt. Alle Zugriffe auf das ML-System erfolgten dann nur durch den Anlagen-Betreiber, ggf. mit Unterstützung in einer Übergangsphase.

Ergebnisse der Phase 5:

1. Inbetriebnahmeprotokoll

2. Dokumentation und Schulungsunterlagen

PHASE 6: BETRIEB

Nach einer initialen Entwicklung und Anwendung von ML-basierter Prozessoptimierung stehen die Unternehmen vor neuen Herausforderungen, diese Lösungen dauerhaft im Betrieb zu etablieren. Grund ist die ständige Fortentwicklung der Fertigungsprozesse, z. B. durch neue Produktvarianten und Edukte, Verschleiß und Wartung sowie strukturelle Änderungen an den Anlagen. Hierfür wird ein Prozess der kontinuierlichen Überwachung der Modellvalidität mit Modellupdates – auch durch Dritte – verfolgt und durch entsprechende Werkzeuge unterstützt.

Überwachung der Modellvalidität

Während des Betriebs sollte das ML-System durch ein ständiges Monitoring überwacht werden. So kann erkannt werden wenn das Modell immer weniger mit dem tatsächlichen Prozess korrespondiert. Die Güte des Modells kann etwa durch einen Vergleich mit zyklischen Testmessungen überwacht werden.

Veränderungen der Modellvalidität sind dem Prozessbediener bzw. Prozessexperten in geeigneter Weise über eine Mensch-Maschine-Schnittstelle oder ein Alarmsystem darzustellen. Weiter müssen Eskalationsstufen und Maßnahmen für den Fall vorgesehen werden, bei dem das Modell nicht weiter ordnungsgemäß arbeiten kann. Das kann beispielsweise bedeuten, dass bei markanten Abweichungen ein Nachtrainieren und Anpassen des Modells erfolgt.

Anpassung der Modelle an Prozessänderungen

Bei einer Anlage, die Verschleiß oder wechselnden Bedingungen unterliegt, ist eine zyklische Anpassung des Modells sinnvoll. Dazu müssen Verfahren etabliert werden, um kontinuierlich neue Daten aufzunehmen und das Nachtrainieren durchzuführen. Das neue adaptierte Modell wird zunächst offline getestet und dann in einem sicheren Prozess (ohne Sprünge oder undefinierte Betriebszustände) in die Anlage integriert.

Finden im Wirkungsbereich des Modells an der Anlage Instandhaltungen, Weiterentwicklungen oder Umbauten statt, ist zu prüfen, ob das Modell in seiner grundsätzlichen Struktur noch den Anforderungen genügt, oder ob es angepasst werden muss. Alle Änderungen müssen geeignet dokumentiert werden, um auch im Nachhinein die Auswirkungen auf das ML-Modell nachvollziehen zu können. Kleinere Änderungen lassen sich einfach durch Nachtrainieren oder Transferlernen in das Modell integrieren. Bei größeren Änderungen kann es nötig sein, ein komplett neues Modell zu entwerfen und dazu Teile früherer Phasen des Vorgehensmodells nochmals zu durchlaufen.

Ergebnisse der Phase 6:

Die 6. Phase hat keinen definierten Abschluss.
Die regelmäßig zu erstellenden und zu prüfenden Dokumente sind im Betriebskonzept festgehalten.
Dazu gehören:

1. Validitätsprüfung der Modelle

2. Dokumentation vorgenommener Veränderungen

TOOLUNTERSTÜTZUNG UND TECHNISCHE ARCHITEKTUR

Für die technische Umsetzung des Vorgehensmodells schlägt ML4P eine auf der Evaluation unterschiedlicher Tools basierende IT-Architektur vor, die darüber hinaus in Form einer prototypischen Software-Implementierung zur Verfügung steht. Besonderes Augenmerk liegt hierbei auf nicht-funktionalen Eigenschaften wie Ausbaufähigkeit, Wartbarkeit, Sicherheit, Performance und Interoperabilität. Ziel ist, einem Nutzer einen Eindruck von dem strukturierenden Rahmen für die Arbeit in ML-Projekten und die Implementierung der zuvor beschriebenen ML-Pipeline zu vermitteln.

Bei der ML-Pipeline handelt es sich um einen gerichteten Graphen, der aus voneinander entkoppelten ML4P-Softwarekomponenten besteht. Die ML4P-Komponenten setzen dabei zumeist auf offener und frei verfügbarer Software auf. Neben den internen ML4P-Komponenten für die Verarbeitung von Datenströmen (z. B. via Apache Kafka), die persistente Speicherung (z. B. in einer Zeitreihendatenbank) oder das Monitoring, können bereits vorhandene Tools über ML4P-Konnektoren an die ML-Pipeline angebunden werden. So kann die Datenerfassung von Maschinen und Anlagen bspw. über einen ML4P-Konnektor zu Industrie 4.0-Verwaltungsschale und OPC Unified Architecture (OPC UA) erfolgen. Auch für die semantische Annotation und das zuvor beschriebene »Tagging«, das Lernen adäquater Modelle und schließlich den Einsatz von ML-Modellen zur Prozessverbesserung und im Engineering, können externe Tools, wie z. B. Jupyter Notebooks, über entsprechende ML4P-Konnektoren angebunden werden.

Die ML4P Architektur komplementiert das Vorgehensmodell. Sie definiert die Struktur und die Regeln, wie eine Anwendung im Kontext von ML4P erstellt werden soll.

Die ML4P IT-Architektur ist in Abbildung 1 dargestellt. Der Benutzer konfiguriert die gewünschte ML-Pipeline, die anschließend von einer Komponente namens »Pipeline Manager« geladen werden kann. Der »Pipeline Manager« überprüft die Korrektheit der ML-Pipeline-Konfiguration und sucht nach den in der Konfiguration vorhandenen ML4P-Komponenten in ihm bekannten Komponentenservern (»Component Server« in Abbildung 1). Die Komponentenserver können an unterschiedlichen Orten ausgeführt werden und beinhalten ML4P-Komponenten mit unterschiedlichen Features. Die sogenannte

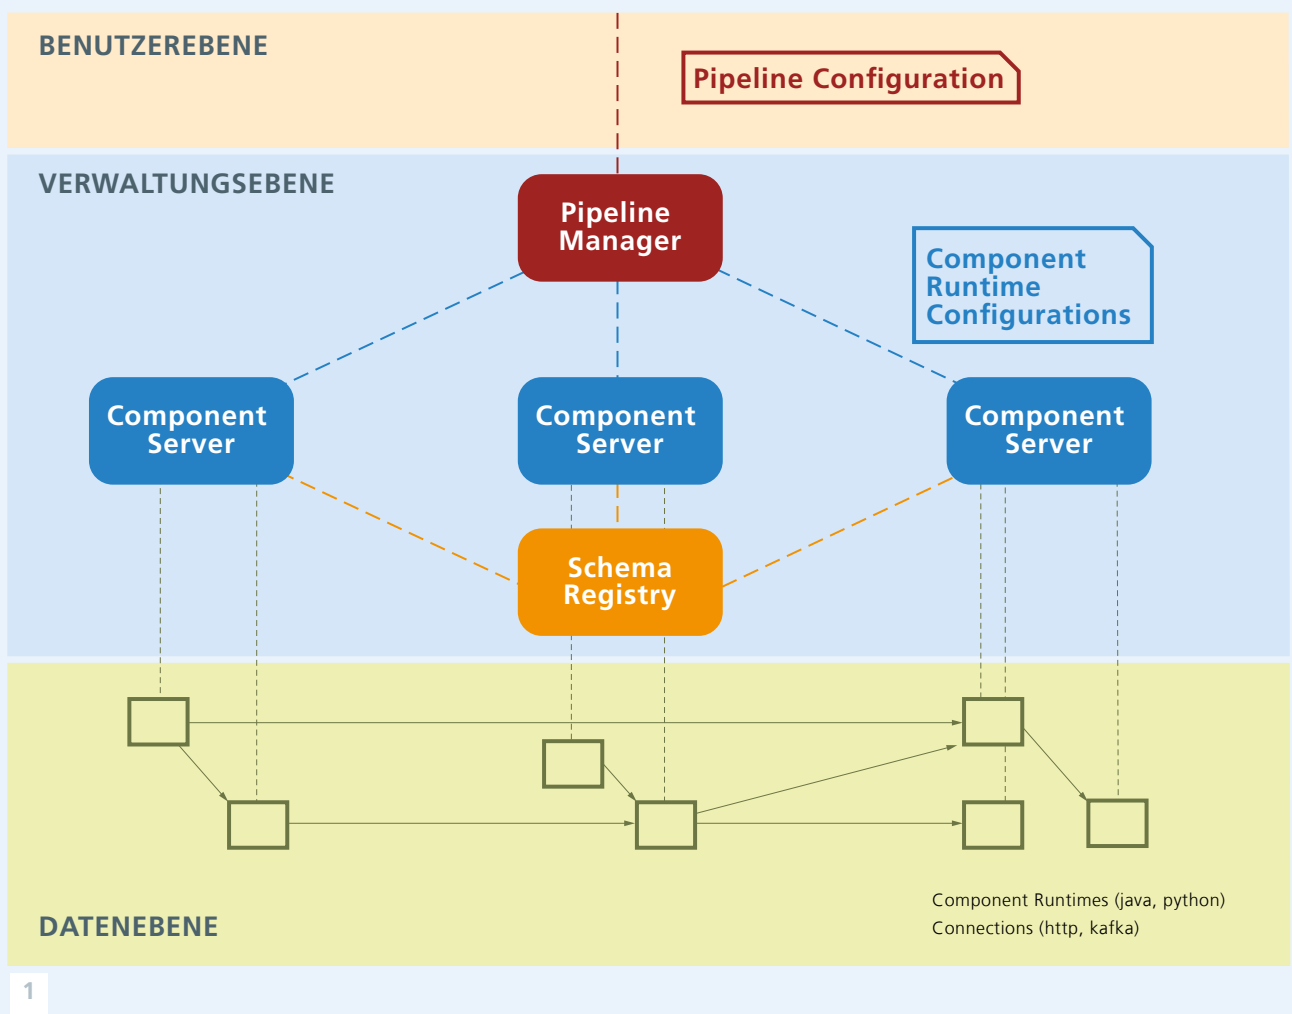
»Registry«, stellt unter anderem Schemata für den Datenaustausch zwischen ML4P-Komponenten zur Verfügung. Über diese wird sichergestellt, dass unterschiedliche ML4P-Komponenten ausgetauschte Daten stets korrekt interpretieren. Auf der untersten »Datenebene« sind die in der ML-Pipeline-Konfiguration enthaltenen und über spezifizierte Schnittstellen miteinander verknüpften ML4P-Komponenten dargestellt. Die Verbindung zwischen ML4P-Komponenten verwendet je nach Konfiguration Apache Kafka oder https/ReST. Es existiert sowohl eine Scala-, als auch eine Python-Implementierung von »Pipeline Manager«, »Component Server“, »Schema Registry« und den weiteren beschriebenen ML4P-Softwarekomponenten.

Grundbausteine sind Komponenten, die jeweils spezifische Funktionalität bereitstellen und die über Ports genannte Schnittstellen miteinander kommunizieren. Die Kommunikation ist asynchron und kann über verschiedene Transportmechanismen wie HTTP oder Kafka erfolgen. Ports sind typisiert, d.h. Daten, die geschrieben oder gelesen werden, müssen den Anforderungen eines spezifizierten Datenschemas genügen.

Eine ML4P Anwendung besteht aus einem Netzwerk solcher Komponenten in einer Pipeline. Pipelines werden durch einen Supervisor gestartet, überwacht und angehalten. Pipelines werden in Form einer Spezifikation definiert.

Diese Struktur erlaubt ein Höchstmaß an Flexibilität. Komponenten können in verschiedenen Programmiersprachen geschrieben werden und auf verschiedenen Plattformen laufen und der Transport von Daten kann über verschiedene Transportkanäle erfolgen. Es muss nur gewährleistet sein, dass

IT-Architektur der ML4P-Pipeline



Daten, die von einer Komponente geschrieben werden und von einer anderen gelesen werden, dasselbe Schema erfüllen.

Die ML4P Architektur wird durch Werkzeuge verschiedenen Typs unterstützt, die als REST Server realisiert sind (siehe Abbildung 1).

- **Komponenten Server** stellen vorbereitete Komponenten zur Verfügung und unterstützen deren Ausführung.
- Der **Pipeline Manager** generiert aus einer Pipeline Spezifikation ein Netzwerk von aktiven Komponenten und überwacht dieses Netzwerk
- Eine **Registratur** verwaltet die genutzten Datenschemata und erlaubt den Zugriff auf Dokumentationen.

ANWENDUNGEN



PKZ 250/1600
K1250/750

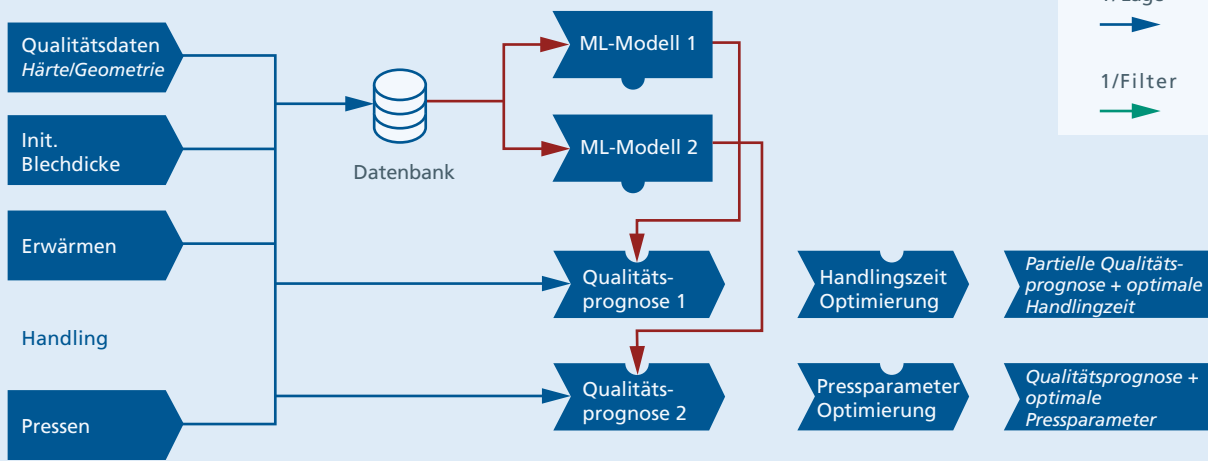
ZEULENRODA

DUNKE

DUNKE

Versuchsstand
Blechwärmumformung

Versuchsstand: Ofen, Presse, Roboter



ANWENDUNG: UMFORMPROZESS

Im Folgenden wird die Umsetzung des vorgeschlagenen Vorgehensmodells am Beispiel des am Fraunhofer IWU etablierten Presshärteprozesses aufgezeigt. Es werden serienfertigungsnah B-Säulenfüße gefertigt. Dafür werden Blechrohlinge auf Temperaturen von ca. 900° C erhitzt und danach in einer Presse gleichzeitig umgeformt und abgekühlt, um sehr hohe Härten in den Bauteilen und somit Zielvorgaben der Automobilindustrie zu erfüllen.

Phase 1 – Analyse

Die Besonderheit dieses Anwendungsbeispiels liegt darin, dass sich der Presshärtevorgang als Prozesskette bestehend aus den drei Prozessschritten Erwärmen, Handling und Pressen darstellt. Als im Prozess beeinflussbare Parameter wurden Ofentemperatur, Handlingzeit, Presskraft und Presszeit identifiziert. Bisher werden einstellbare Prozessparameter durch den Anlagenbediener in Voruntersuchungen erprobt. Ziel ist es jedoch, dynamisch auf Veränderungen im Prozess reagieren zu können. Diese Anpassungen der Prozessparameter können durch die Kombination von maschinellen Lernverfahren und Optimierungsmethoden berechnet werden. Um die Datengrundlage für die maschinellen Lernmodelle zu verbessern, wurde der Versuchsstand durch zusätzliche Sensorik ausgestattet. Vorrangig wurden im Pressenwerkzeug, jedoch auch im Ofen Thermoelemente zur Temperaturerfassung integriert. Weiterhin misst ein Infrarotsensor im Werkzeug die Abkühlraten des Blechs während des Umformens berührungslos. Als Qualitätsparameter wurden an charakteristischen Punkten bzw. Messlinien Kenngrößen für Bauteilhärte, Blechdicken und Geometrie (Formabweichung) identifiziert:

In der Analyse-Phase wurde zur besseren Visualisierung der angestrebten Ziele ein Pipeline-Diagramm erarbeitet. Die vorgesehenen ML-Modelle prognostizieren die finale Bauteilqualität nach dem Erwärmen und nach dem Handling. Das Optimierungsverfahren errechnet aus den prognostizierten Qualitäten optimale Handlingszeiten bzw. optimale Pressenparameter.

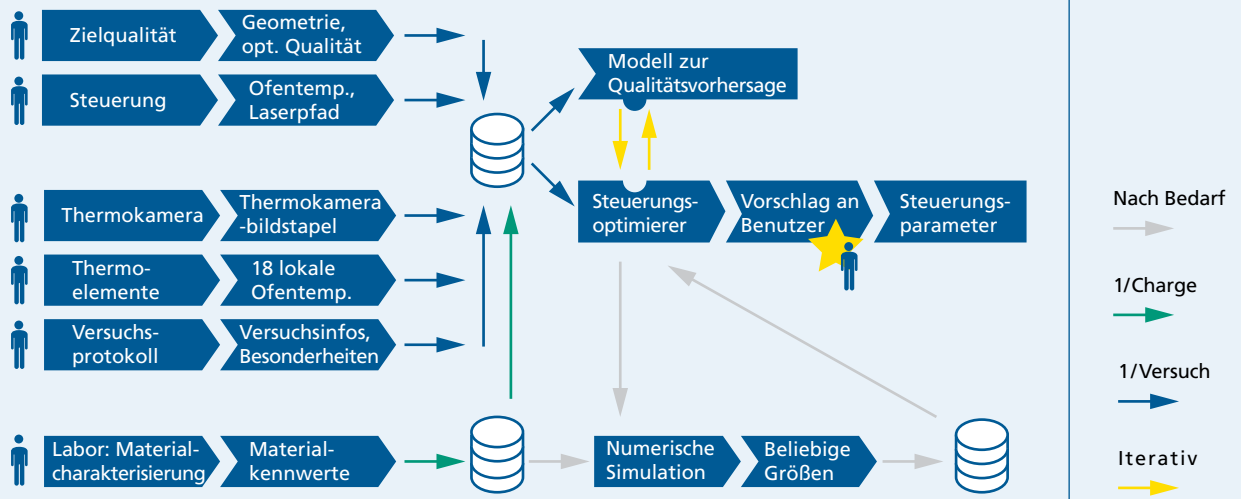
Phase 2 – Proof of Concept

Dem PoC liegen als Eingangsgrößen die vier Prozessparameter Ofentemperatur, Handlingzeit, Presskraft und Presszeit, sowie alle zusätzlich erfassten Sensorwerte zugrunde. Jedem so erfassten Datensatz sind eine Bauteil-ID und die in Phase 1 identifizierten Qualitätsparameter zugeordnet. Es lassen sich einfache lineare oder quadratische Modelle finden, welche die Abhängigkeit der Qualitätsparameter von den Prozessparametern darstellen. Die aktuell zusätzlich erfassten Sensorinformationen haben zu keiner Verbesserung der Modellgenauigkeit geführt. Die ersten ML-Modelle basieren auf 60 Versuchen, für welche die vier Prozessparameter jeweils zwischen drei Werten variiert wurden. Für jedes Parameter-Set gibt es insgesamt Experimente, um eine gewisse statistische Sicherheit zu erreichen. Die Ofentemperatur wurde als signifikanteste Einflussgröße auf die Qualitätsparameter identifiziert. Die Datenerfassung erfolgte weitestgehend unautomatisiert durch die Abspeicherung der Daten in Excel-Tabellen.

Phase 3 – Systemspezifikation

Aktuell befindet sich die Anlage in Phase 3. Die in PoC identifizierten ersten ML-Modelle wurden verwandt, um die qualitativen Vorteile einer Verkürzung der Handlingzeit zu prüfen. Dies hat den positiven Effekt, dass die Ofentemperatur geringer gehalten werden kann. Die Ergebnisse der ML-Modelle suggerierten, dass der Umbau der Anlage zur Verkürzung der Handlingzeit sinnvoll ist. Dafür wurde der Ofen anders positioniert, um das Handling des Blechs in und aus dem Ofen effizienter zu ermöglichen. Parallel dazu musste die Anlage in das Maschinenetz integriert werden. Dafür wurde ein Netzkabel in der Maschinenhalle verlegt und der iPC der Presse über einen USB-Ethernet-Adapter mit einem Internetzugang versorgt.

¹ Zielvorstellung der Anwender der Presshärteanlage als Pipeline-Diagramm



1

ANWENDUNG: INKREMENTELLE FORMGEBUNGSPROZESSE

Für die Anwendungsdomäne inkrementeller Formgebungsprozesse wird das Vorgehensmodell an einem am Fraunhofer IWM entwickelten Glasformgebungsprozess angewandt. Bei diesem handelt es sich um einen Batch-Prozess, mit welchem Glasscheiben gebogen werden. Flachglas wird dabei in einen Ofen eingefahren und erwärmt. Zusätzlich wird in einem bestimmten Bereich um die spätere Biegekante inkrementell mit einem Laser erhitzt. Durch die induzierte Wärme wird das Glas mittels Schwerkraft in eine vordefinierte Form gebogen, siehe Abbildung 2.

Phase 1

Die wichtigsten Parameter des Prozesses sind Ofentemperatur und Laserführung (Pfad, Geschwindigkeit und Dauer des Laservorgangs). Diese werden im bisherigen Prozess manuell bestimmt, basierend auf der Erfahrung der Prozessbediener. Das Ziel ist es, die Prozessparameter mithilfe von maschinellem Lernen zu optimieren und ebenso die Qualitätssicherung zu verbessern durch Datenanalyse am Realprozesses. Eine Aufrüstung der Anlage mit zusätzlichen Sensoren soll dabei in Betracht gezogen werden, sowie der Einsatz von numerischer Simulation.

Der zu untersuchende Anwendungsfall ist die Herstellung einer um 90 Grad gebogenen Glasscheibe. Die für die Optimierung benötigten Zielparameter und Fehlertoleranzen sind im Folgenden aufgelistet:

1. die Biegung der Scheibe soll 90° Grad erreichen mit einer Fehlertoleranz von $\pm 1^\circ$ Grad
2. der Biegeradius r soll konstant über die Biegung zwischen 5 und 20 mm liegen, mit einer Abweichung vom idealen Radius von nicht mehr als ± 0.1 mm an keiner Stelle

Um die Zielvorstellung der Prozessexperten zu verbildlichen und eine Diskussionsgrundlage zu schaffen, wurde ein Pipeline-Diagramm des Glasbiegeprozesses erstellt, siehe Abbildung 1.

Phase 2

Aus Phase 1 geht die Hypothese der Prozessexperten hervor: Mittels Aufrüstung der Anlage und unterstützt durch numerische Simulation ist es möglich, ein datengetriebenes Vorhersagemodell für die Steuerungsparameter (Ofentemperatur und Laserführung) zu erzeugen. Dieses soll die Prozessbediener dabei unterstützen das bisher rein auf Erfahrungen basierte Einstellen der Steuerungsparameter zu verbessern. Um eine aussagekräftigere Datenbasis zu erhalten wird der Glasbiegeprozess um eine Thermokamera und Thermo-elemente in Abstimmung mit dem Prozessingenieur erweitert. Zudem werden die Gültigkeitsbereiche der Steuerungsparameter in Abstimmung mit dem Prozessingenieur und den Prozessbedienern festgelegt, um die Exploration des Prozessfensters in einem sinnvollen Maße zu ermöglichen. In einem ersten Schritt wird der Proof of Concept rein mit einer numerischen Prozesssimulation erbracht, muss danach allerdings gleichermaßen auf Basis von Realdaten erfolgen.

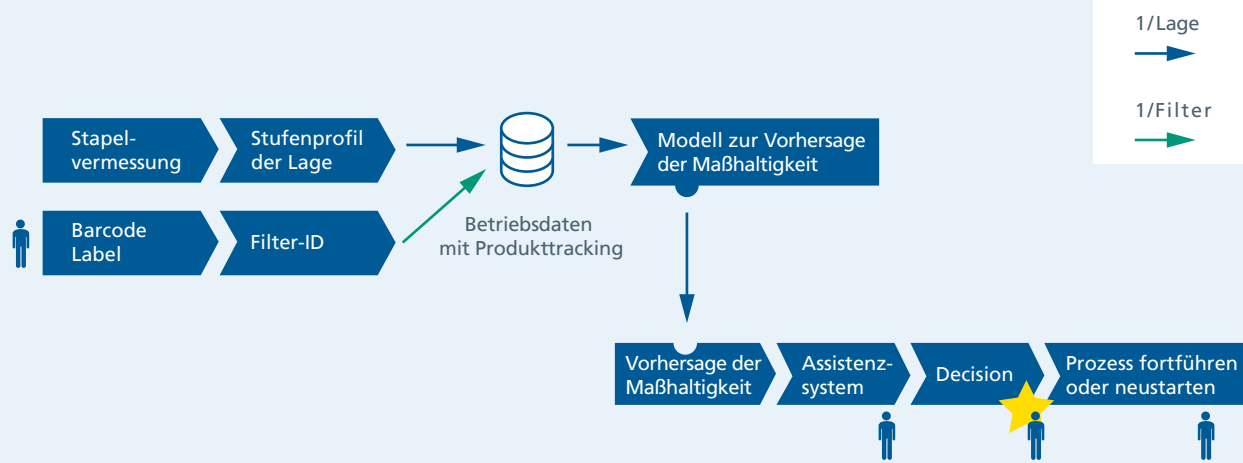


2

1 Zielvorstellung der Prozessexperten des Glasbiegeprozesses als Pipeline-Diagramm

2 Um 90° Grad gebogene Glasscheiben

© Fraunhofer IWM, Foto: Peter Manns



1

ANWENDUNG: FILTER-HERSTELLUNG

Bei diesem Anwendungsbeispiel werden die entwickelten ML-Methoden und Verfahren im Bereich der Verarbeitungsprozesse in der Membranfilterproduktion umgesetzt. Als Demoanlage dient eine am Fraunhofer IFF entwickelte Sondermaschine (Autowinder 2, kurz: AW2), die bei der Lanxess AG am Standort IAB-Bitterfeld GmbH bei der Produktion von Wasserfiltern in Batch-Prozessen im Mehrschichtbetrieb eingesetzt wird. Im Prozess werden Membranen und Zwischenlagen zugeschnitten, gefaltet, gestapelt, verklebt und aufgewickelt. Das Ziel der ML-Anwendung ist die Früherkennung von Stapelfehlern, die Ursache für mangelnde Maßhaltigkeit und somit unzureichende Dichtheit und Qualität der Wasserfilter sind. Darauf aufbauend können von Prozessexperten und ML-Experten Maßnahmen zur Verbesserung der Gesamtanlageneffektivität, insbesondere des Qualitäts- und Leistungsgrades, umgesetzt werden.

Phase 1

Technische Ziele sind das frühzeitige Erkennen von Fehlern in der Stapelbildung, die als Ursachen für mangelnde Maßhaltigkeit identifiziert wurden. Dazu zählen z.B. ein ungleichmäßiges Stufenprofil der Lagen, Verschiebungen und Falten. Ziel ist es, möglichst alle unzulässigen Abweichungen von einem idealen Stapel zu erkennen und zu bewerten, ob infolgedessen die Rundheit oder das Kantenprofil des Filters über die zulässigen Grenzwerte hinaus beeinträchtigt sind. Das Ziel ist eine Vorhersagegüte von mind. 90% durch Abgleich von ML- und Prüfergebnissen hinsichtlich Maßhaltigkeit der Filter, da es dann als wirtschaftlich bewertet wird, den ML-Empfehlungen zu folgen und als fehlerhaft bewertete Filter auszuschleusen. Werden Fehler im Prozess rechtzeitig erkannt, kann der Prozess abgebrochen oder angepasst werden und somit wird Fertigungszeit für Gutteile gewonnen. Es können zudem Maßnahmen eingeleitet werden, um derartige Fehler zukünftig zu vermeiden.

Phase 2

Die in Phase 1 gestellten Ziele und die ursprünglich zur Verfügung stehenden Eingangsdaten wurden von Prozess- und ML-Experten einem Proof of Concept unterzogen. Die grundsätzliche Machbarkeit wurde unter der Bedingung erklärt, dass die Anlage mit weiteren Sensoren zur Stapelvermessung, Rundheitsmessung und Teleskopprüfung (Messung des Kantenprofils) ausgestattet wird. Zudem muss eine eindeutige Zuordnung von Produkt-IDs zu Messwerten möglich sein. In Abstimmung mit Prozessexperten und -bedienern erfolgte die Nachrüstung von Sensoren und Abstimmungen zu Veränderungen in Prozessabläufen (Rückmeldung der Produkt-ID und des vom Prozessbediener ermittelten Bewertungsergebnisses zur Qualität nach dem Wickeln). Nach der Installation und Inbetriebnahme können erste Datensätze zum Training von ML-Modellen zur Verfügung gestellt werden. Darüber hinaus werden Kriterien für Qualitätsvorhersage benannt.



- 1 *Initiales ML-Pipeline-Diagramm zur Vorhersage der erwarteten Produktqualität.*
 - 2 *Homogener Stapelaufbau ermöglicht exakten Kleberauftrag bei parallel angeordneten Lagen*
- © Fraunhofer IFF

Literatur

VDMA. *Interoperabilität durch standardisierte Merkmale – Leitfaden für Industrie 4.0*, 2019.
URL <https://sud.vdma.org/viewer/1v2article/ren-der/39398565>.

Wirth, R. and Hipp, J. *CRISP-DM: Towards a standard process model for data mining*. In *Proceedings of the 4th international conference on the practical applications of knowledge discovery and data mining*, pp. 29–39, 2000.

Titelfoto von Stephen Dawson bei Unsplash

Über »Machine Learning for Production (ML4P)« Im Leitprojekt ML4P forschen sechs Fraunhofer-Institute unter Leitung des Fraunhofer-Instituts für Optronik, Systemtechnik und Bildauswertung IOSB in Karlsruhe an der Entwicklung eines toolgestützten Vorgehensmodells sowie an der Realisierung entsprechender interoperabler Software-Tools, um systematisch das Optimierungspotential in produktionstechnischen Anlagen durch den Einsatz von Methoden des maschinellen Lernens zu erschließen.

ML4P Konsortium

Fraunhofer IOSB (Projektleitung),
Fraunhofer IFF,
Fraunhofer IWU,
Fraunhofer IAIS,
Fraunhofer ITWM,
Fraunhofer IWM

Co-Autoren des Vorgehensmodells

Marlene Eisenträger, Christian Frey,
Andreas Herzog, Ali Moghiseh,
Lukas Morand, Julius Pfrommer,
Henrike Stephani, Anke Stoll,
Lars Wessels

Benötigen Sie weitere Informationen oder haben Sie Interesse an einer Zusammenarbeit? Gerne können Sie uns kontaktieren!

Ansprechpartner

Julius Pfrommer
julius.pfrommer@iosb.fraunhofer.de
Telefon: +49 721 6091-0
www.iosb.fraunhofer.de

Projektleitung

Prof. Dr.-Ing. habil. Jürgen Beyerer
Fraunhofer-Institut für Optronik,
Systemtechnik und Bildauswertung IOSB
Fraunhoferstraße 1, 76131 Karlsruhe