

Ein Prozessmodell für Betrieb, Wartung und Weiterentwicklung von KI in CPPS-Umgebungen

AIM4M: MLOps strukturiert im Produktionsumfeld

L. Rauh, M. Süner, D. Schel

ZUSAMMENFASSUNG Der produktive Einsatz von KI in der Industrie scheitert oft nicht an der Modellentwicklung, sondern am stabilen Betrieb im Produktionsumfeld. AI Asset Management for Manufacturing (AIM4M) ist ein Prozessmodell für den KI-Lebenszyklus in cyber-physischen Produktionssystemen (CPPS) mit Fokus auf die Operationalisierung. Es ergänzt dazu den Ansatz von Machine Learning Operations (MLOps) aus der IT um CPPS-spezifische Feinheiten – als praxisnaher Orientierungsrahmen.

STICHWÖRTER

Industrie 4.0, Künstliche Intelligenz,
Product Lifecycle Management

AIM4M: Structured MLOps for Manufacturing AI

ABSTRACT Implementing AI in manufacturing does not necessarily fail because of model creation but is often due to a lack of reliable operation within production environments. AI Asset Management for Manufacturing (AIM4M) is a process model for the AI lifecycle in cyber-physical production systems (CPPS) with a focus on operationalization. It supplements the Machine Learning Operations (MLOps) approach from IT with CPPS-specific characteristics – as a practical orientation framework.

1 Einleitung

Künstliche Intelligenz (KI) gilt als ein zentraler Baustein für die digitale Transformation in der industriellen Fertigung [1]. Ihre Potenziale in der Anwendung (etwa die frühzeitige Fehlererkennung, adaptive Prozessregelung oder prädiktive Instandhaltung) sind weitreichend und gut erforscht [1, 2]. Dennoch zeigt die Realität in den Produktionshallen, dass viele KI-Projekte nicht über eine erfolgreiche Prototypenphase hinauskommen oder nach kurzer Zeit im Betrieb scheitern [3]. Die Ursachen liegen selten in der Qualität der Algorithmen, sondern vielmehr im fehlenden strukturierten Vorgehen bei der Operationalisierung – also beim Übergang von der Idee zur stabil betriebenen und wartbaren KI-Lösung im realen Produktionsumfeld. Die Herausforderung steigt weiter, wenn diese Lösungen innerhalb von cyber-physischen Produktionssystemen (CPPS) laufen, also in Systemen mit engen Echtzeitanforderungen, hohem Integrationsgrad und anspruchsvollen Sicherheits- und Qualitätsanforderungen [4].

Um diese Herausforderungen zu adressieren, etabliert sich zunehmend das ursprünglich aus der IT kommende Konzept der Machine Learning Operations (MLOps). MLOps verspricht, den Lebenszyklus von KI-Lösungen ganzheitlich zu betrachten, von der Datenbereitstellung über Modelltraining bis hin zu Betrieb, Überwachung und kontinuierlicher Verbesserung [5]. Gerade im industriellen Kontext wird der jedoch Begriff oft uneinheitlich verwendet oder auf Teilbereiche reduziert. Häufig fehlt das ganzheitliche Verständnis, wie ein vollständiger KI-Lebenszyklus im Zusammenspiel mit technischen Systemen, Qualitätssicherung,

regulatorischen Anforderungen und operativer Verantwortung aussehen sollte.

Hier setzt das Prozessmodell AIM4M (AI Asset Management for Manufacturing) an, als ein strukturierter Orientierungsrahmen für den Einsatz von MLOps im Kontext von CPPS [6]. Es adressiert explizit die Anforderungen, die beim praktischen Betrieb, der Weiterentwicklung (Update-Phase im Betrieb) und dem Rückbau von KI-Lösungen entstehen, also jenen Phasen, die im klassischen KI-Projekt oft nicht systematisch mitgedacht werden.

2 Stand der Technik und Herausforderungen beim KI-Betrieb

Um ein tragfähiges Prozessmodell für den Lebenszyklus von KI-Anwendungen in der industriellen Produktion zu entwickeln, müssen zunächst die zentralen Rahmenbedingungen und bestehenden Herausforderungen verstanden werden. In den folgenden Abschnitten werden dazu drei zentrale Themenbereiche betrachtet:

1. Die Rolle von CPPS für die Industrie-4.0-Initiative (Kapitel 2.1),
2. die Struktur typischer KI-Lebenszyklen mit MLOps (Kapitel 2.2) und
3. die regulatorischen Anforderungen an den KI-Einsatz im Kontext der Produktion (Kapitel 2.3).

Die daraus abgeleiteten Anforderungen werden in Kapitel 2.4 zusammengefasst und bilden die Grundlage für die anschließende Analyse bestehender Prozessmodelle und die Entwicklung des AIM4M-Modells.

2.1 Cyber-physische Systeme in der Fertigung

CPPS stellen die industrielle Ausprägung cyber-physischer Systeme (CPS) dar, bei denen physische Prozesse eng mit digitalen, vernetzten IT-Komponenten gekoppelt sind [7]. In der Fertigung ermöglichen sie den Echtzeitaustausch großer Datenmengen zwischen Maschinen, Robotern, Sensoren und IT-Systemen wie Datenbanken oder Softwarelösungen [8]. Diese Integration eröffnet fortschrittliche Analyse- und Steuerungsfunktionen zur Steigerung von Effizienz, Flexibilität und Reaktionsgeschwindigkeit in Produktionsumgebungen.

CPPS gelten damit als zentrale technologische Grundlage für die Realisierung von Industrie-4.0-Visionen. Durch die fortlaufende Entwicklung hin zu hochgradig vernetzten, datengetriebenen Systemen spielen sie eine Schlüsselrolle bei der Gestaltung nachhaltiger und anpassungsfähiger Produktionsprozesse. Die Integration von KI beziehungsweise von Verfahren des maschinellen Lernens (ML) verstärken diesen Trend, da diese Technologien eine schnelle Analyse großer Datenmengen erlauben und so prädiktive Fähigkeiten sowie autonome Entscheidungsfindung in der Produktion ermöglichen [4].

Aufgrund dieser CPPS-Spezifika müssen Lebenszyklusmodelle für KI im MLOps-Ansatz neben softwareseitigen Komponenten (etwa Datenpipelines und Versionierung) auch den operativen Betrieb im produktionsnahen Hardwarekontext berücksichtigen. Doch während aktuelle Ansätze zunehmend Aspekte wie Monitoring und Deployment adressieren [9], bleibt die methodische Einbindung solcher physischen Produktionsumgebungen, vor allem unter Echtzeitanforderungen, bislang in etablierten Lebenszyklusmodellen weitgehend unbeachtet [10].

2.2 KI-Lebenszyklus in MLOps und Industrie 4.0

Mit der zunehmenden Relevanz von KI-Systemen in der industriellen Produktion wächst auch der Bedarf, deren gesamten Lebenszyklus systematisch zu gestalten. Die Basis des typischen KI-Lebenszyklus umfasst mehrere iterative Phasen, die durch Feedback-Schleifen miteinander verbunden sind: von der Datenvorbereitung und Modellierung über die Evaluierung und Integration bis hin zum operativen Einsatz und zur Weiterentwicklung [5, 11]. Bekannte Ansätze wie CRISP-ML(Q) gehen dabei über klassische Modelle hinaus, indem sie Qualitätssicherung (in Form von Prüfpunkten zur Qualitätssicherung) und Feedback-Mechanismen explizit integrieren [12]. Sie bieten damit wichtige Impulse für eine praxismgerechte Gestaltung des KI-Lebenszyklus in der Industrie, bilden aber die besonderen Anforderungen von CPPS nicht vollständig ab.

Im industriellen Kontext treten besondere Herausforderungen auf. Anders als bei rein digitalen Produkten muss KI in Produktionssystemen dauerhaft unter variablen Bedingungen performant und sicher sowie nachvollziehbar arbeiten. Daraus ergibt sich die Notwendigkeit eines stabilen Feedback- und Monitoring-Mechanismus, der nicht nur die Performance überwacht, sondern auch Veränderungen in Daten oder Prozessen erkennt und Nutzer-Feedback aus der Anwendung direkt integriert [9].

Ein weiterer zentraler Aspekt ist die Rollenverteilung im Lebenszyklus. Industrieorientierte Ansätze heben hervor, dass der Erfolg von KI-Projekten nicht allein von KI-Experten abhängt, sondern ein Zusammenspiel mit mehreren Rollen aus der Domäne erfordert, wie Datenwissenschaftlern, Stakeholdern und Daten-

und Softwareingenieuren [5, 11]. Dabei werden in [13] weitere Tätigkeiten der MLOps-Domäne beschrieben, die die Notwendigkeit von Hardware- und Infrastrukturrexperten sowie Qualitätsingenieuren implizieren. Eine explizite Erwähnung und Definition dieser notwendigen Rollen im KI-Lebenszyklus fehlt jedoch in gängigen Prozessmodellen.

2.3 Regulatorische Anforderungen an KI-Anwendungen in der Produktion

Der Einsatz von KI in der Produktion bringt nicht nur technische, sondern auch regulatorische Herausforderungen mit sich. Mit dem EU-AI-Act rücken zunehmend Anforderungen in den Fokus, die auf Transparenz, Nachvollziehbarkeit und Dokumentation im KI-Lebenszyklus abzielen [14]. Dies betrifft etwa sicherheitsrelevante Anwendungen, in denen die Entscheidungsfindung der KI erklärbar und kontrollierbar bleiben muss.

Ein Konzept, das zur strukturierten Umsetzung dieser Anforderungen beitragen kann, ist die Verwendung von "AI-Cards", wie in [15] definiert. Diese standardisierten Artefakte erfassen zentrale Informationen zu Datenquellen, Modellverhalten, Anwendungsgrenzen und Risiken und unterstützen dadurch sowohl die interne Qualitätssicherung als auch die externe Kommunikation mit regulatorischen Stellen. Besonders in komplexen Produktionsumgebungen wie CPPS tragen solche Ansätze dazu bei, den verantwortungsvollen KI-Betrieb zu gewährleisten.

2.4 Zusammenfassung der Anforderungen

In den Ausführungen oben wurden zentrale Anforderungen und Perspektiven herausgearbeitet, die ein praxisnahes Prozessmodell für KI-Anwendungen in der Produktion im CPPS-Kontext berücksichtigen muss. Cyber-physische Produktionssysteme stellen hohe technische System-Anforderungen, wie etwa an Echtzeitfähigkeit und Integration in hardwarenahe Infrastrukturen (Kapitel 2.1). Gleichzeitig erfordert der KI-Lebenszyklus in der industriellen Praxis eine strukturierte Iteration mit Monitoring, Feedback und klar definierten Rollen (Kapitel 2.2). Hinzu kommen regulatorische Vorgaben, die Transparenz und dokumentierte Nachvollziehbarkeit über alle Phasen hinweg einfordern (Kapitel 2.3).

Diese technischen, methodischen und regulatorischen Aspekte bilden die Grundlage für die in Kapitel 3.1 folgende Analyse bestehender Prozessmodelle. Ziel ist es, zu prüfen, inwiefern vorhandene Ansätze diesen Anforderungen gerecht werden und wo Lücken bestehen, die eine Weiterentwicklung notwendig machen.

3 Ein strukturierter Prozessrahmen für KI in der Produktion

Um den komplexen Anforderungen an den KI-Lebenszyklus im Kontext von CPPS gerecht zu werden, braucht es ein strukturiertes, anwendungsnahes Vorgehen. Der folgende Abschnitt in Kapitel 3.1 analysiert, inwiefern bestehende Prozessmodelle diesen Anforderungen genügen und bildet damit die Grundlage für die Entwicklung eines eigenen, industrieorientierten Ansatzes (Kapitel 3.2), der auf die Anforderungen und Grundlagen von Kapitel 2 aufbaut. Abschließend wird in Kapitel 3.3 die sich ergebende Praxisbedeutung des eigenen AIM4M-Prozessmodells diskutiert.

Tabelle. Bewertungskriterien, abgeleitet aus zentralen MLOps-Anforderungen für CPPS.

Kategorie	Dimensionen des Kriteriums
Systematisches Lebenszyklus-Engineering	(K1) Verantwortlichkeiten und Akteure: Die relevanten Rollen und Verantwortlichkeiten sind für jeden Prozessschritt aufgeführt.
	(K2) Systematisches Engineering: Die Prozessschritte sind detailliert definiert und beschrieben, anstatt nur ein allgemeines oder generisches Modell darzustellen.
	(K3) Umfassendes Lebenszyklusmanagement (LZM): Der Prozess bildet die gesamte Lebensdauer einer KI-Anwendung ab, von der ersten Idee bis zur Außerbetriebnahme.
Domänen-spezifische Anpassung	(K4) CPS/CPPS und Industrie 4.0 Kontext: Der Prozess integriert Spezifika aus dem CPPS-Kontext, zum Beispiel inkludiert die Integration und Systemtests mit Hardware-Komponenten.(K5) Live-Modellaktualisierungen: Der Prozess ermöglicht eine kontinuierliche Optimierung mit Modelliterationen während der Betriebsphase.
Regulatorische Anforderungen	(K6) Einhaltung gesetzlicher Vorschriften: Anforderungen (Sicherheit, Erklärbarkeit usw.) sind adressiert und werden über den gesamten Lebenszyklus hinweg verortet.
	(K7) Governance und Qualitätsbewertung: Herausforderungen sind adressiert und es werden entsprechenden Anforderungen kontinuierlich aufgenommen und evaluiert.

3.1 Analyse bestehender Prozessmodelle

Zahlreiche Veröffentlichungen der letzten Jahre widmen sich dem Lebenszyklus von KI-Systemen, sowohl im Kontext allgemeiner KI-Prozesse als auch mit Bezug zu MLOps. Ziel ist, zu untersuchen, inwieweit bestehende Prozessmodelle den zuvor beschriebenen Anforderungen an den industriellen KI-Betrieb, vor allem im Umfeld von CPPS, gerecht werden.

Hierfür wurde eine strukturierte Analyse bestehender Modelle aus Forschung und Praxis durchgeführt. Ausgangspunkt bildete eine systematische Literaturanalyse gemäß Prisma-Methode, die im Januar 2025 durchgeführt wurde. Dazu wurden die Datenbanken „Web of Science“ und „Scopus“ durchsucht, basierend auf einem Suchstring, mit drei Komponenten durch ein „AND“ verknüpft. Je Komponente waren dabei mehrere Alternativen durch ein „OR“ verknüpft, um flexibel bei der konkreten Wortwahl zu bleiben. Der Suchstring sollte gewährleisten, dass nur Publikationen gefunden werden, welche sich im weiteren Sinne mit einem Prozessmodell zum Thema MLOps im Kontext von CPPS beschäftigen. Die Suche führte zu insgesamt 243 Paper-Ergebnissen. Diese wurden anschließend mit der Prisma-Methode zu 11 relevanten Ansätzen beziehungsweise Prozessmodellen reduziert [5, 10, 12, 16–24], die ein vollständiges Lebenszyklusmodell adressieren. Diese Modelle wurden auf Basis vorab definierter Bewertungskriterien verglichen, die aus den vorangegangenen Kontextkapiteln (Kapitel 2.1 bis Kapitel 2.3) abgeleitet wurden. Die Kriterien umfassen sieben zentrale Dimensionen von MLOps und Industrie 4.0, die in der **Tabelle** zusammengefasst dargestellt werden.

Anhand dieser Kriterien (K1-K7) wurden die 11 ausgewählten Prozessmodelle in einer Vergleichsmatrix gegenübergestellt (**Bild 1**).

Dabei wurde die Abdeckung der sieben definierten Bewertungskriterien qualitativ mit „Harvey Balls“ auf einer dreistufigen Skala dargestellt: vollständig erfüllt (voller Ball, Wert 100 %), teilweise erfüllt (halber Ball, Wert 50 %) und nicht erfüllt (leerer Ball, Wert 0 %). Der Erfüllungs- beziehungsweise Überdeckungsgrad bezieht sich vor allem auf die qualitative Bewertung des Kriteriums, unter anderem, ob jeweils entsprechende Anforderungen berücksichtigt wurden oder in den Prozessmodellen über Keywords erkenntlich sind. Zusätzlich wurde je Prozessmodell ein

Kriterien (aus Tabelle)	Modell- kandidaten	Jüngling, 2022 [23]	Theusch, 2023 [16]	Fitzner, 2024 [18]	Faubel, 2025 [24]	Kreuzberger, 2023 [5]	Studer, 2020 [12]	Ranawana, 2021 [22]	John, 2021 [19]	Tamburri, 2020 [20]	Faubel, 2025 [17]	Alsagheer, 2023 [21]
(K1) Rollen		●	●	●	●	●	●	●	●	●	●	●
(K2) System. Engineering		●	●	●	●	●	●	●	●	●	●	●
(K3) Umfassendes LZM		●	●	●	●	●	●	●	●	●	●	●
(K4) CPS/CPPS Kontext		●	●	●	●	●	●	●	●	●	●	●
(K5) Updates im Betrieb		●	●	●	●	●	●	●	●	●	●	●
(K6) Regulatorik		●	●	●	●	●	●	●	●	●	●	●
(K7) Governance / QA		●	●	●	●	●	●	●	●	●	●	●
Total (%)		57	50	43	29	64	57	43	21	29	36	57

Bild 1 Bewertung der analysierten Prozessmodelle für Machine Learning Operations (MLOps), anhand der Evaluationskriterien (aus der Tabelle).
Grafik: Fraunhofer IPA

Durchschnittswert berechnet, der den prozentualen Erfüllungsgrad über alle Kriterien hinweg angibt. Das Ergebnis zeigt, dass im Schnitt nur etwa die Hälfte der Kriterien erfüllt wird, mit Einzelergebnissen zwischen 21 % und 64 %.

Die Auswertung zeigt die Unterschiede der Prozessmodelle in Detailtiefe (zum Beispiel Rollen und systematisches Vorgehen), Struktur und Anwendungsfokus. Während die meisten Prozessmodelle zentrale Evaluationsaspekte, wie das umfassende Lebenszyklusmanagement oder Governance- und Qualitäts-Anforderungen, gut abdecken, fehlt häufig die Anwendung systematischer Konzepte für Rollen und Verantwortlichkeiten sowie detailliertes Engineering. Aspekte wie regulatorische Anforderungen und besonders die CPS/CPPS-Integration werden am seltensten und meist nur am Rande adressiert.

Die Analyse macht deutlich: Es fehlt ein Prozessmodell, das die Stärken bestehender Ansätze, wie rollenbasiertes Vorgehen zum Engineering, kontinuierliche Feedback-Zyklen und standardisierte Qualitätsmethoden mit den besonderen Bedingungen der industriellen Praxis, insbesondere im Umfeld cyber-physischer Systeme, ganzheitlich adressiert. Bestehende Ansätze liefern wichtige Impulse, doch kein Ansatz vereint alle zentralen Anforderungen in einer durchgängigen, praxisnahen Struktur. Diese Erkenntnis

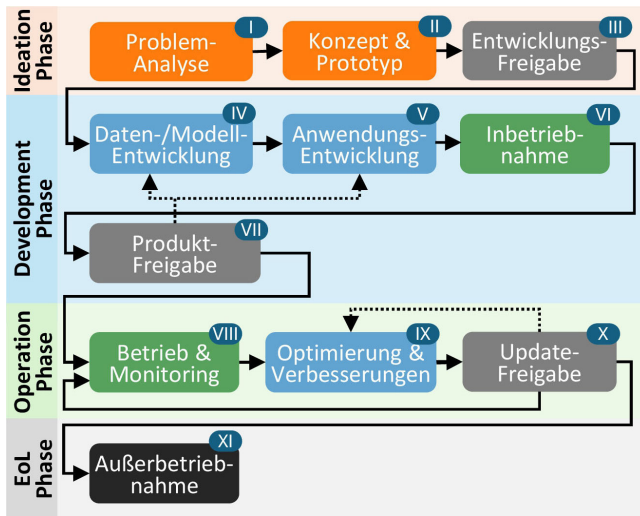


Bild 2 Strukturansicht des AIM4M (AI Asset Management for Manufacturing)-Prozessmodell als Übersicht über die vier Hauptphasen und elf Stufen. Die römischen Ziffern geben die Nummer der Stufe an.
Grafik: Fraunhofer IPA

bildet die Grundlage für die Entwicklung des eigenen Prozessmodells AIM4M, das im Kapitel 3.2 vorgestellt wird.

3.2 Das AIM4M-Prozessmodell

3.2.1 Überblick

Auf Basis der in Kapitel 2 identifizierten Anforderungen und Analyseergebnisse (Kapitel 3.1) wurde mit AIM4M (AI Asset Management for Manufacturing) ein Prozessmodell entwickelt, das den vollständigen Lebenszyklus von KI-Anwendungen in industriellen Produktionssystemen strukturiert abbildet. Die Entwicklung erfolgte iterativ und wurde kontinuierlich durch Erfahrungen aus Industrieprojekten flankiert, um ein betriebsstaugliches und anschlussfähiges Vorgehensmodell abzuleiten. Der Fokus lag auf der praxisnahen Umsetzung im Kontext von CPPS, mit besonderem Augenmerk auf die Betriebsphase, Qualitätssicherung und regulatorische Nachvollziehbarkeit. Details zur Entwicklungsmethodik sind in [6] dargestellt. Die vorliegende Arbeit erweitert diese Fassung insbesondere um eine zweistufige Visualisierung und Evaluierungsergebnisse der Studie (Kapitel 3.3).“

Dazu ist das Prozessmodell in vier Hauptphasen unterteilt, die den gesamten KI-Lebenszyklus umfassen: „Ideation“, „Development“, „Operation“ und „Retirement“, die sich grundsätzlich an den typischen Phasen eines Produktlebenszyklus orientieren. Jede Phase besteht aus mehreren Stufen (römische Nummerierung). Diese Struktur erlaubt es, KI-Projekte systematisch und hierarchisch strukturiert zu steuern: von der Anforderungsanalyse und Ideenfindung bis zur kontrollierten Stilllegung. **Bild 2** bietet eine kompakte Übersicht über das Prozessmodell und zeigt Phasen, Stufen sowie deren Verlauf und mögliche Rückkopplungen (Strukturansicht).

Die Stufen sind farblich an ihre übergeordnete Phase gekoppelt und machen somit Abhängigkeiten sofort erkennbar: orange sind Stufen mit explorativen Tätigkeiten (wie Ideenfindung und konzeptionelles Design), blau sind Stufen mit Entwicklungstätigkeiten (zu Daten, Modell, Anwendung), grün sind Stufen mit Tätigkeiten rund um Betrieb und Monitoring, grau sind Genehmigungsstufen (Qualitätskritische Entscheidungen) und schwarz

ist die finale Stufe der Außerbetriebnahme. Die Abbildung zeigt vor allem die logische Abfolge im Lebenszyklus. Pfeile im Modell geben die Richtung der Bearbeitung an: durchgezogene Linien stehen für sequenzielle Abläufe, während gestrichelte Linien iterative Zyklen und Rückkopplungspunkte verdeutlichen. Umfang und Dauer einzelner Stufen können erheblich variieren. Maßgeblich ist dabei etwa die Erfahrung des Unternehmens in der KI-Entwicklung und die Verfügbarkeit technischer Hilfsmittel. So kann die Stufe „Operation Onboarding“ in einem Großunternehmen lediglich bedeuten, eine neue KI-Anwendung in eine bestehende Plattform einzubinden, während ein Unternehmen ohne etablierte Infrastruktur dafür mehrere Monate für Planung und Bereitstellung einer betriebsfertigen Gesamtlösung einplanen muss. Eine ausführliche Beschreibung der Phasen folgt im nächsten Kapitel.

Die Strukturansicht dient als erster Überblick über die hierarchische Struktur von Phasen und Stufen, um als Orientierungsrahmen die technischen, organisatorischen und regulatorischen Aspekte systematisch miteinander zu verbinden. Somit ist diese Darstellung als Einstiegspunkt in ein umfassendes KI-Lebenszyklusmanagement und zur Kommunikation auf höherer Flugebene gedacht, zum Beispiel mit Entscheidungsträgern.

3.2.2 Die Lebenszyklusphasen

Nachdem Bild 2 den Gesamtzusammenhang des AIM4M-Prozessmodells als Strukturansicht visualisiert hat, richtet sich der Fokus nun auf die einzelnen der vier Hauptphasen und dazugehörigen Stufen dieses Lebenszyklus. Diese Phasen spiegeln typische Projektverläufe bei KI-Anwendungen wider und strukturieren den Lebenszyklus in einer klar nachvollziehbaren Form, von der ersten Idee bis hin zur Außerbetriebnahme. Es folgt je Phase eine kurze Beschreibung:

• Phase I: Ideation Phase

Ziel der Ideation Phase (Stufen I bis III) ist die Initialisierung und Validierung eines Use Cases. Dazu gehört zunächst die Analyse des Problems, das durch die KI gelöst werden soll. Anschließend werden technische und regulatorische Anforderungen abgeleitet. Die Use-Case-Idee wird schrittweise konkretisiert, auf Geschäftsnutzen, Stakeholder-Ziele und (technische) Machbarkeit überprüft und freigegeben. Die Entscheidung zur Weiterverfolgung der Idee und Freigabe entsprechender Ressourcen zur Entwicklung erfolgt am Ende der Phase über einen ersten Qualitätsprüfpunkt (QA-Gate).

• Phase II: Development Phase

Die zweite Phase (Stufen IV bis VII) überführt den KI-Prototypen in eine einsatzfähige Lösung. Dazu gehören sämtliche Entwicklungsaufgaben – von Datenbeschaffung und -aufbereitung über Modelltraining bis hin zu systematischen Experimenten – um für das in der vorangegangenen Phase definierte KI-Problem einen geeigneten Modellkandidaten zu finden. Eine lückenlose Dokumentation und der Einsatz automatisierter Pipelines sind dabei essenziell. Sobald ein Modellkandidat vorliegt, wird er in eine Anwendung integriert: Das Spektrum reicht von einer schlanken Programmierschnittstelle, über die andere Systeme auf das Modell zugreifen, bis zur Entwicklung kompletter Benutzeroberflächen oder sogar einer Smartphone-App. Danach folgt das Onboarding, bei dem die Anwendung in bestehende Delivery- und Monitoring-Plattformen eingebunden und für die Produktfreigabe vorbereitet wird. Diese Ab-

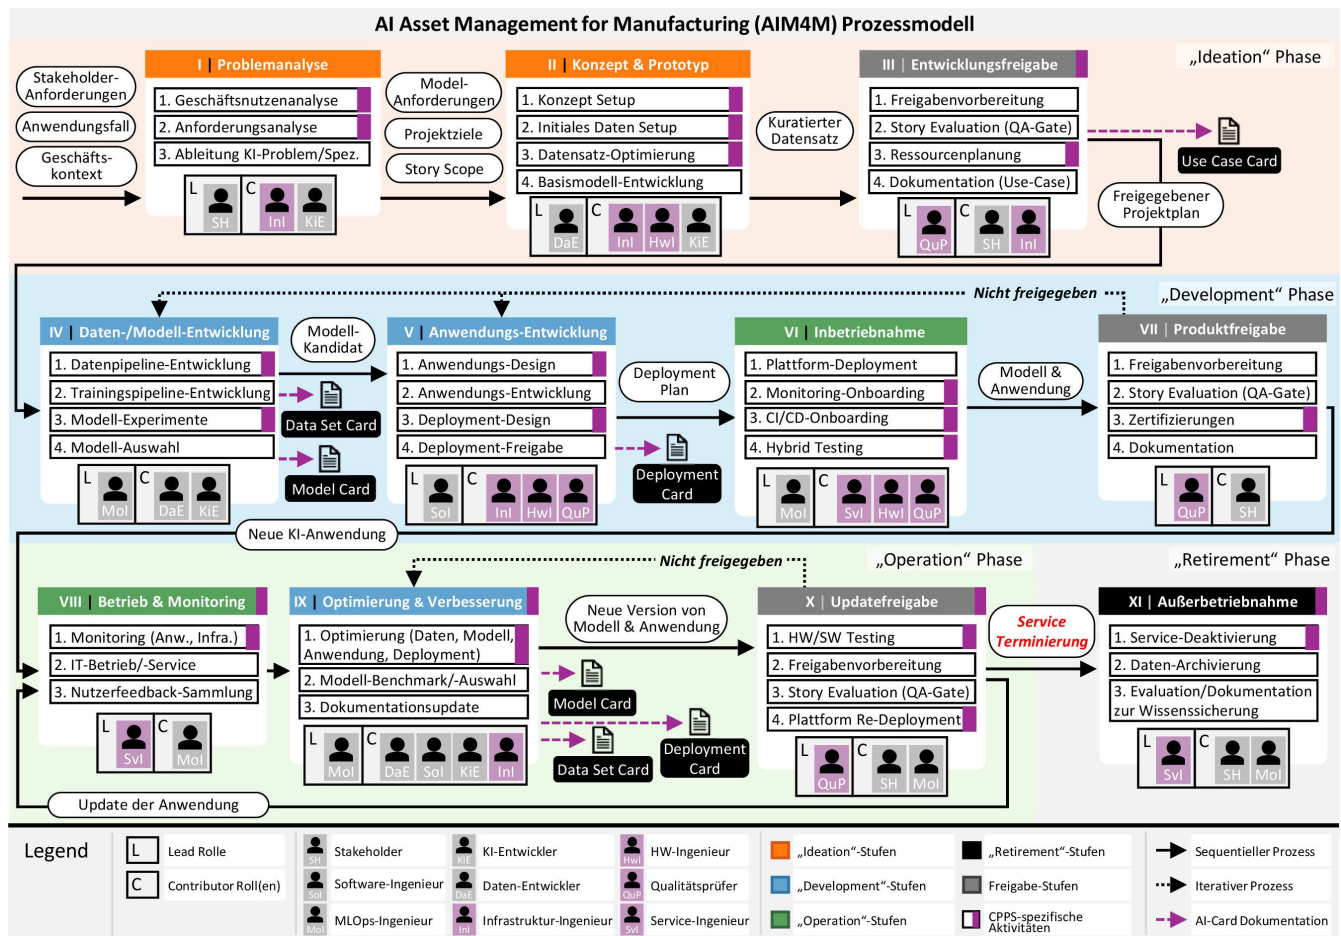


Bild 3 Detaillierte Darstellung des AIM4M-Prozessmodells (Detailansicht), als Verfeinerung der Strukturansicht. Grafik: Fraunhofer IPA

nahme schließt die Entwicklungsphase ab und bestätigt, dass Datenpipelines, Modellversionen und Anwendungen reproduzierbar dokumentiert, automatisiert getestet und freigegeben sind.

• Phase III: Operation Phase

Die Operation Phase (Stufen VIII bis X) umfasst den laufenden Betrieb der KI-Anwendung und stellt deren Stabilität sicher durch kontinuierliche Optimierung, Überwachung und eventuelle Deployment-Zyklen. Im Mittelpunkt stehen ein lückenloses Monitoring von Anwendung und Infrastruktur, die fortlaufende Performance-Bewertung sowie die systematische Einbindung von Nutzerfeedback. Auf dieser Grundlage werden erforderliche Anpassungen an Daten, Modellen oder Infrastruktur gezielt geplant, dokumentiert und kontinuierlich evaluiert. Sämtliche Updates, ob an Modell, Datenpipeline oder Software, durchlaufen einen klar definierten Freigabeschritt, sodass nur geprüfte Änderungen in die Produktionsumgebung gelangen und der reibungslose Betrieb dauerhaft gewährleistet bleibt.

• Phase IV: Retirement Phase

Wird ein KI-System abgelöst oder der zugehörige Use Case eingestellt, zum Beispiel weil definierte Anforderungen über Zeit verletzt und nicht mehr durch Updates behoben werden können, deckt AIM4M auch den strukturierten Rückbau oder die Außerbetriebnahme und damit verbundene Aktivitäten ab (Stufe XI). Dabei wird die KI-Anwendung deaktiviert, Daten

entweder archiviert oder gelöscht (je nach Vorgaben aus der Anforderungsdefinition, entsprechend des Anwendungskontext) und eine abschließende Evaluierung zur Wissenssicherung durchgeführt. Der dokumentierte Abschluss hilft, Erfahrungen für zukünftige Projekte nutzbar zu machen.

Mit dieser Gliederung in vier Hauptphasen spannt AIM4M den Bogen von der ersten Idee bis zur Außerbetriebnahme. Jede Phase verfolgt ein klar definiertes Ziel, endet mit einem geprüften Übergabeschritt und schafft so Transparenz und Wiederholbarkeit, auch im Sinne der Nachvollziehbarkeit und Verantwortlichkeiten, wie sie etwa der EU-AI-Act fordert.

3.2.3 Modellergebnis und -verfeinerungen

Aufbauend auf der Strukturansicht (Bild 2) und der im vorherigen Kapitel vorgestellten Phasengliederung zeigt dieses Kapitel das AIM4M-Prozessmodell in seiner vollständigen Detailansicht, visualisiert in **Bild 3**.

Im Vergleich zu bestehenden Prozessmodellen wurden bei der Entwicklung des AIM4M mehrere zielgerichtete Verfeinerungen und Erweiterungen vorgenommen, auf Basis der dargestellten Anforderungen aus Anwendungskontext und Regulatorik:

1. Hardware-Perspektive für CPPS:

AIM4M berücksichtigt die starke Kopplung von KI-Anwendungen an produktionsnahe Hardware, wie sie für CPPS typisch ist. Besonders bei Test und Integration des KI-Modells,

bei Update-Prozessen und Monitoring werden die technischen Rahmenbedingungen (wie Echtzeitverarbeitung, Steuerungssysteme) miteinbezogen. Relevante Tätigkeiten erstrecken sich aber über den gesamten Lebenszyklus (siehe Magenta-Markierungen an den Schritten im Prozessmodell), zum Beispiel die Berücksichtigung der Hardware-Anforderungen in I, oder Hybrid Testing in VI.

2. Betonte Betriebsphase mit vollständigem Regelkreis:

Während viele Lebenszyklus-Modelle die Entwicklung betonen, stellt AIM4M auch die Betriebsphase detailliert dar. Diese umfasst neben dem Monitoring die kontinuierliche Re-Evaluation, Optimierung sowie geregelte Updateprozesse zur Sicherung der Qualität und Konformität zu anfangs definierten Anforderungen.

3. Regulatorik und Nachvollziehbarkeit als feste Bestandteile:

Der Einsatz der AI-Cards (siehe Anforderungen in Kapitel 2.3) als standardisierter Dokumentationsartefakte ermöglicht einen strukturierten Umgang mit regulatorischen Anforderungen. So wird Nachvollziehbarkeit im Betrieb methodisch verankert.

4. Rollenbasierte Strukturierung:

Das Modell definiert die notwendigen Rollen entlang des Lebenszyklus (zum Beispiel Stakeholder, KI-Entwickler, Software-Ingenieur) und ordnet ihnen konkrete Aufgaben und Schnittstellen zu. Somit entstehen klare Verantwortlichkeiten, auch über Team- oder Abteilungsgrenzen hinweg. Durch die Spezialisierung eines generischen MLOps-Rahmens für den industriellen Einsatz in der Fertigung erweitert AIM4M die in der Literatur bekannten Rollenmodelle für KI-Lebenszyklen (siehe [5, 11]) um vier zusätzliche, in Magenta markierte Rollen (wie in Kapitel 2.2 eingeführt): der Qualitätssicherung, dem Hardware-, Infrastruktur- und Service-Ingenieur.

5. Stufenbasierter Aufbau für Wiederverwendung und Skalierung:

Durch die Aufteilung in Phasen, Stages (Stufen) und Prozessschritte (Steps) können Use Cases in verschiedenen Reifegraden durchlaufen oder modular angepasst werden. Dies erlaubt eine schrittweise Skalierung und Wiederverwendbarkeit. Damit ist das Prozessmodell nicht nur relevant für Unternehmen, die schon mehrere KI-Anwendungen entwickelt und entsprechend des Knowhow aufgebaut haben, sondern besonders auch für Unternehmen, welche erst am Anfang einer solchen Initiative stehen.

Die zielgerichteten Erweiterungen zeigt die Detailansicht (Bild 3) und behält dabei die vertraute Farblogik bei: Orange kennzeichnet die experimentellen Stufen (I–II), blau die Entwicklungsstufen (IV, V, und IX), grün die Betriebsstufen (VI, VIII), grau die formalen Genehmigungsschritte (III, VII, X) und schwarz die Außerbetriebnahme (XI). Jede (römisch nummerierte) Stufe ist als Kasten mit Titel, arabisch nummerierten Schritten und den dafür verantwortlichen Rollen dargestellt (links „L“ = Lead, rechts „C“ = Contributor). Die Rollenkürzel erläutert die Legende am unteren Rand (etwa KiE = KI-Entwickler).

Insgesamt veranschaulicht die Detailansicht (Bild 3), wie das AIM4M-Prozessmodell neben der groben Strukturansicht des KI-Lebenszyklus (Bild 2) auch einen klar abgestimmten Arbeitsplan bietet. Dieser verortet definierte Verantwortlichkeiten, Qualitätsprüfungspunkte mit Dokumentationslogik und nachvollziehbare Artefakte und orientiert sich konsequent an der Farb- und Phasenlogik der Strukturansicht.

3.3 Von der Theorie zur Blaupause: Erste Einblicke aus der Praxis

Das AIM4M-Prozessmodell stellt einen praxisnahen Orientierungsrahmen bereit, der MLOps-Prinzipien auf die besonderen Bedingungen im Kontext von CPPS überträgt. Ein zentrales Ziel bei dessen Entwicklung war nicht nur ein theoretisch fundiertes Prozessmodell, sondern auch eine konkrete Orientierungshilfe für die Praxis zu schaffen. Dafür wurde das Prozessmodell so gestaltet, dass es vielseitig anwendbar (zum Beispiel für Anbieter sowie Anwender von KI-Lösungen), leicht vermittelbar (für unterschiedlichste Reifegrade an KI-Erfahrungen bei Unternehmen) und auf unterschiedliche KI-Use-Cases übertragbar ist (von klassischer KI, über KI-Bildverarbeitung und Sprachmodelle).

Um die Praxistauglichkeit des Prozessmodells schrittweise zu beleuchten, werden momentan zwei Ansätze verfolgt: Zum einen kommt AIM4M bereits in ersten Pilot-Beratungsprojekten bei Kunden zum Einsatz; zum anderen läuft parallel eine qualitative Studie, die auch ohne unmittelbare Anwendung des Prozessmodells zeitnah erste Praxiseindrücke liefert. Bisher wurde das Prozessmodell mit 16 Industrie-Expertinnen und -Experten diskutiert und zeigt so einen ersten Realitätsabgleich sowie Nutzenpotenziale auf. Im Folgenden wird eine Auswahl der bisherigen Ergebnisse vorgestellt.

3.3.1 Studienaufbau

Die Studie liefert eine erste Einschätzung, wie praktikabel und vollständig AIM4M aus Anwendersicht im industriellen Kontext ist. Dafür wurden (im Zeitraum April bis Mai 2025) 16 Expertinnen und Experten aus 16 deutschsprachigen Unternehmen befragt. Die Stichprobe deckt zentrale Rollen des Prozessmodells ab: von strategischer Ebene (Stakeholder) bis in ausführende Rollen (KI-Entwickler, Qualitätsprüfer etc.).

Die Datenerhebung erfolgte durch strukturierte Einzelinterviews (circa 60 Minuten) mit teilweise offenen und teilweise geschlossenen Fragen zur Ist-Situation, dem Prozessmodell und Chancen für eine unterstützende Softwarelösung. Im Interview wurde das AIM4M-Prozessmodell in den zwei Detailebenen (Bild 2 und Bild 3) vorgestellt und diskutiert. Bei geschlossenen Fragen wurde dabei eine Likert-skalierte Skala mit den Antwortmöglichkeiten „trifft nicht zu“, „trifft eher nicht zu“, „neutral“, „trifft eher zu“ und „trifft voll zu“ genutzt.

3.3.2 Einblicke in die Ergebnisse

Einen Einblick in die Ergebnisse und Rückmeldungen aus der Studie mit 16 Teilnehmenden zur Verständlichkeit und Vollständigkeit von AIM4M gibt die Darstellung in **Bild 4**.

Bei den Bewertungen (links) sind neben der Likert-skalierten Skala auch Zwischenschritte von 3,5 beziehungsweise 4,5 angegeben. Diese resultieren daraus, dass einige Teilnehmenden ihre Bewertung als Mittelwert zweier Blickwinkel angaben, zum Beispiel bei Rollenwahrnehmung im eigenen Unternehmen einerseits und des allgemeinen Verständnisses des im Prozessmodell definierten Rollenbilds andererseits.

Die Rückmeldungen zeigen ein eindeutiges Bild: Konzeptionell überzeugt das Modell, insbesondere durch die klare Struktur und Lebenszyklusorientierung. Bereits der Ersteindruck des AIM4M-Prozessmodells wurde durchweg positiv bewertet: Alle Teilneh-




Bild 4 Übersicht zu Bewertungen (Likert-skaliert, mit Punkten nach Zustimmung) und Frage der Rollen-Zuordnung aus der Evaluierung der Interviews.
 Grafik: Fraunhofer IPA

menden stufen die Strukturansicht (Bild 2) zur Übersicht als gut bis sehr gut verständlich ein (siehe „Ersteindruck“, links). Zudem konnten sich fast alle Teilnehmenden unmittelbar im Lebenszyklus verorten, obwohl die konkrete Zuordnung zu Rollen im Überblick noch nicht explizit dargestellt ist. Mit der nachgeschalteten Detailansicht (Bild 3) gelang die Rollenzuordnung vollständig (siehe „Zustimmung“, rechts). Gleichzeitig wurde mehrfach betont, dass in der Praxis eine Person oft mehrere der definierten Rollen gleichzeitig übernimmt. Dieses Spannungsfeld zwischen idealtypischem Rollenmodell und realer Ressourcenlage zieht sich durch viele Rückmeldungen.

Was die Vollständigkeit des Prozessmodells zum Arbeitsumfang der Rollen betrifft, fühlten sich nahezu alle Befragten in ihrem Arbeitsalltag vom Modell gut abgedeckt. Die Einschätzungen reichten überwiegend von „trifft zu“ bis „trifft voll zu“ (siehe „Arbeitsumfang“). Nur in Einzelfällen wurde geringer positiv geurteilt, weil Rollen in der Praxis zusammenfallen und sich damit der Arbeitsumfang verteilt oder einzelne unternehmensspezifische Arbeitsinhalte nicht explizit verortet sind. Insgesamt wird das Modell jedoch als realitätsnah wahrgenommen.

Weniger eindeutig fiel das Urteil zur praktischen Umsetzbarkeit im eigenen Unternehmen aus (siehe „Umsetzbarkeit“). Während einige Teilnehmende die direkte Umsetzung von Vorgaben aus dem Prozessmodell in ihrem Unternehmen mit „gut machbar“ (Bewertung 4–5) einschätzten, weil Rollenklarheit, Budget und Tool-Landschaft bereits weitgehend vorhanden seien, stuften andere die Umsetzung nur als „teilweise machbar“ ein. Sie verwiesen vor allem auf fehlende Fachkräfte, mangelndes strategisches Commitment, unscharfe Rollengrenzen und knappe Ressourcen, die eine Eins-zu-eins-Umsetzung derzeit im Mittelstandsumfeld erschweren. Das Prozessmodell kann aber selbst in solchen Situationen dank seiner klaren Strukturansicht helfen, die Grundprinzipien von systematischem KI-Lebenszyklusmanagement zu erfassen und als Blaupause die Weiterentwicklung anzustoßen. Man kann also sagen: Das Prozessmodell ist praxistauglich, sofern die Organisation die notwendige Reife mitbringt, um es zu tragen.

Besonders hohe Zustimmung erhielt die integrierte Dokumentationslogik in Form der AI-Cards, die als Steckbriefe sämtliche Informationen zu Use Cases, Daten, Modellen und Deployments bündeln und damit Compliance sowie Nachvollziehbarkeit verbessern (siehe „Dokumentation“). Teilnehmende aus Qualitäts-

und Regulatorikrollen hoben dieses Vorgehen als zentralen Mehrwert hervor, auch wenn endgültige rechtliche Vorgaben, wie etwa aus dem EU-AI-Act, derzeit noch nicht feststehen. Daraus folgt, dass die konkreten regulatorischen Anforderungen im Prozessmodell (etwa in den Anforderungslisten im Schritt „Requirements Analysis“) fortlaufend an den aktuellen Stand von Normen und Gesetzen angepasst werden müssen. AIM4M liefert dazu den strukturellen Rahmen.

Auch aus den offen-gestellten Fragen im Interview lässt sich zusammenfassend ableiten, dass ein klar strukturiertes Prozessmodell für KI-Anwendungen, wie AIM4M, erhebliches Potenzial bietet: Ob Digitalisierungsberater oder Experte für Daten, Prozesse und Regulatorik, die Probleme sind deckungsgleich. Ein praxisnahes, rollenbasiertes Prozessmodell für KI im CPPS-Kontext mit integrierter Dokumentation adressiert exakt jene Lücken, die heute Zeit, Geld und Vertrauen kosten. Es schafft Transparenz über Rollen, verankert regulatorische Prüfpunkte mit Quality Gates und verortet Dokumentationspflichten. Damit erleichtert es die Zusammenarbeit in interdisziplinären Teams und verbessert die Compliance. Das wird von allen Befragten als klarer Mehrwert bewertet. Verbesserungswürdig sind vor allem die pragmatische Anpassung an knappe Ressourcen in der Praxis (Rollen in Personalunion) sowie eine Verzahnung mit bestehenden Softwarelösungen, damit sich der Modellablauf im Alltag tatsächlich „leben“ lässt.

4 Fazit und Ausblick

AIM4M ist ein praxisnahes Prozessmodell, das den gesamten Lebenszyklus von KI-Anwendungen im Kontext der industriellen Produktion abbildet, von der ersten Idee über Entwicklung und Betrieb bis zur strukturierten Stilllegung. Im Zentrum steht die Operationalisierung, die häufig als methodische Lücke für KI im Produktionsumfeld identifiziert wird. Um diese Hürde zu überwinden, verknüpft das AIM4M-Prozessmodell MLOps-Prinzipien mit CPPS-spezifischen Rollen, Aktivitäten und Compliance-Artefakten (zum Beispiel AI-Cards) in einer anwendungsorientierten Struktur. Durch die hierarchische Gliederung in Phasen, Stufen und Schritte eignet sich AIM4M nicht nur für Einzelprojekte, sondern auch als organisationsweiter Orientierungsrahmen. Erste Praxiserfahrungen und Expertenrückmeldungen zeigen, dass das

Modell Verständnis schafft, Rollen schärft und die Wiederverwendbarkeit von Lösungen fördert.

Zukünftig kann von AIM4M als Basis für die Harmonisierung von unternehmensinternen Prozessen mit Standardvorgehen des EU-AI-Act Gebrauch gemacht werden, etwa als Vorlage für digitale Dokumentations-Templates oder automatisierte QA-Gates. Anhand in der Studie gewonnenen Erkenntnisse soll zudem der Aspekt einer Tool-Unterstützung gezielt weiterentwickelt werden, damit Unternehmen praxisgerechte Unterstützung erhalten und eine Überführung von AIM4M aus der Prozessebene in den gelebten Alltag ermöglicht wird.

FÖRDERHINWEIS

Diese Arbeit wird unterstützt durch das Projekt „AI Matters“ und ist kofinanziert durch die Europäische Union unter der Finanzhilfvereinbarung Nr. 101100707 sowie durch das Land Baden-Württemberg, gemäß einem Beschluss des Landtags.

LITERATUR

- [1] Usuga Cadavid, J. P.; Lamouri, S.; Grabot, B. et al.: Machine learning applied in production planning and control: a state-of-the-art in the era of industry 4.0. *Journal of Intelligent Manufacturing* 31 (2020), pp. 1531–1558, doi.org/10.1007/s10845-019-01531-7
- [2] Wuest, T.; Weimer, D.; Irgens, C. et al.: Machine learning in manufacturing: advantages, challenges, and applications. *Production & Manufacturing Research* 41 (2016), pp. 23–45, doi.org/10.1080/21693277.2016.1192517
- [3] Peres, R. S.; Jia, X.; Lee, J. et al.: Industrial Artificial Intelligence in Industry 4.0 – Systematic Review, Challenges and Outlook. *IEEE Access* 8 (2020), pp. 220121–220139
- [4] Radanliev, P.; Roure, D. de; van Kleek, M. et al.: Artificial intelligence in cyber physical systems. *AI & society* 36 (2021) 3, pp. 783–796
- [5] Kreuzberger, D.; Kühl, N.; Hirschl, S.: Machine Learning Operations (MLOps): Overview, Definition, and Architecture. *IEEE Access* 11 (2023), pp. 31866–31879
- [6] Rauh, L.; Süner, M.R.; Schel, D.: AI Asset Management for Manufacturing (AIM4M): Development of a Process Model for Operationalization. *ArXiv*, 2025
- [7] Monostori, L.: Cyber-physical Production Systems: Roots, Expectations and R&D Challenges. *Procedia CIRP* 17 (2014), pp. 9–13
- [8] Monostori, L.; Kádár, B.; Bauernhansl, T. et al.: Cyber-physical systems in manufacturing. *CIRP Annals* 65 (2016) 2, pp. 621–641
- [9] Protschky, D.; Lämmermann, L.; Hofmann, P. et al.: What Gets Measured Gets Improved: Monitoring Machine Learning Applications in Their Production Environments. *IEEE Access* 13 (2025), pp. 34518–34538
- [10] Faubel, L.; Schmid, K.; Eichelberger, H.: Is MLOps different in Industry 4.0? General and Specific Challenges. *Proceedings of the 3rd International Conference on Innovative Intelligent Industrial Production and Logistics – IN4PL*, 2025, pp. 161–167, doi.org/10.5220/0011589600003329
- [11] Symeonidis, G.; Nerantzis, E.; Kazakis, A. et al.: MLOps – Definitions, Tools and Challenges. *IEEE 12th Annual Computing and Communication Workshop and Conference (CCWC)*, Las Vegas, USA, 2022, doi.org/10.48550/arXiv.2201.00162
- [12] Studer, S.; Bui, T. B.; Drescher, C. et al.: Towards CRISP-ML(Q): A Machine Learning Process Model with Quality Assurance Methodology, *Machine Learning and Knowledge Extraction* 3 (2021) 2, pp. 392–413, doi.org/10.3390/make3020020
- [13] Del Rey, S.; Medina, A.; Franch, X. et al.: Addressing Quality Challenges in Deep Learning: The Role of MLOps and Domain Knowledge, *2025 IEEE/ACM 4th International Conference on AI Engineering – Software Engineering for AI (CAIN)*, Ottawa, ON, Canada, 2025, pp. 184–189, doi.org/10.1109/CAIN66642.2025.00029
- [14] Kilian, R.; Jäck, L.; Ebel, D.: European AI Standards: Technical Standardization and Implementation Challenges under the EU AI Act. Stand: 2025. Internet: www.aigl.blog/content/files/2025/04/European-AI-Standards-Technical-Standardization-and-Implementation-Challenges-under-the-EU-AI-Act.pdf. Zugriff am 12.08.2025
- [15] Brajovic, D.; Renner, N.; Goebels, V. P. et al.: Model Reporting for Certifiable AI: A Proposal from Merging EU Regulation into AI Development. *ArXiv*, 2023, doi.org/10.48550/arXiv.2307.11525
- [16] Theusch, F.; Seemann, L.; Guldner, A. et al.: Towards Machine Learning-based Digital Twins in Cyber-Physical Systems. *Proceedings of The First Workshop on AI for Digital Twins and Cyber-Physical Applications in conjunction with 32nd International Joint Conference on Artificial Intelligence*, 19 August 2023, Macao, S.A.R
- [17] Faubel, L.; Woudsma, T.; Methnani, L. et al.: A MLOps Architecture for XAI in Industrial Applications. *2024 IEEE 29th International Conference on Emerging Technologies and Factory Automation (ETFA)*, Padova, Italy, 2024, pp. 1–4
- [18] Fitzner, A.; Hülsmann, T.; Ackermann, T. et al.: Machine learning pipeline for application in manufacturing. *Conference paper*, doi.org/10.24405/15309
- [19] John, M. M.; Olsson, H. H.; Bosch, J.: Towards MLOps: A Framework and Maturity Model. *2021 47th Euromicro Conference on Software Engineering and Advanced Applications (SEAA)*, Palermo, Italy, 2021, pp. 1–8
- [20] Tamburri, D. A.: Sustainable MLOps: Trends and Challenges. *2020 22nd International Symposium on Symbolic and Numeric Algorithms for Scientific Computing (SYNASC)*, Timisoara, Romania, 2020, pp. 17–23
- [21] Alsagheer, D.; Xu, L.; Shi, W.: Decentralized Machine Learning Governance: Overview, Opportunities, and Challenges. *IEEE Access* 11 (2023), pp. 96718–96732
- [22] Ranawana, R.; Karunananda, A. S.: An Agile Software Development Life Cycle Model for Machine Learning Application Development. *2021 5th SLAAI International Conference on Artificial Intelligence (SLAAI-ICAI)*, Colombo, Sri Lanka, 2021, pp. 1–6
- [23] Jüngling, S.; Fetai, I.; Rogger, A. et al.: On the Track to Application Architectures in Public Transport Service Companies. *Applied Sciences* 12 (2022) 12, #6073
- [24] Faubel, L.; Woudsma, T.; Kloepper, B. et al.: MLOps for Cyberphysical Production Systems: Challenges and Solutions. *IEEE Software* 42 (2025) 1, pp. 65–73

Lukas Rauh, M.Sc. 
lukas.rauh@ipa.fraunhofer.de

Mel-Rick Süner, B.Sc. 
mel-rick.suener@ipa.fraunhofer.de

Daniel Schel, B.Sc. 
daniel.schel@ipa.fraunhofer.de

Fraunhofer-Institut für Produktionstechnik
und Automatisierung IPA
Nobelstr. 12, 70569 Stuttgart
www.ipa.fraunhofer.de

LIZENZ



Dieser Fachaufsatz steht unter der Lizenz Creative Commons
Namensnennung 4.0 International (CC BY 4.0)