

Datenbasierte Erhebung von Kosteneinflussfaktoren in der Instandhaltung

Ökonomisch effiziente Anlagenoptimierung

L. Greimel, F. Kamhuber, L. Chalupa, F. Ansari

ZUSAMMENFASSUNG Die „Twin Transition“, verstanden als paralleler digitaler und nachhaltiger Wandel, stellt einen strukturellen Transformationsprozess dar. Datengetriebene Technologien etablieren die Instandhaltung als wesentlichen Hebel zur Steigerung der Nachhaltigkeit und Effizienz. Der Beitrag demonstriert simulationsgestützt die Analyse kostenrelevanter Einflussfaktoren sowie im Ausblick die Erweiterung der Entscheidungsbasis um ökologische Dimensionen.

STICHWÖRTER

Instandhaltung, PLM, Nachhaltigkeit

Data-Based Identification of Cost-Influencing Factors in Maintenance – Economically efficient asset optimization

ABSTRACT The “twin transition” as the parallel digital and sustainable transformation, represents a structural change process. Data-driven technologies establish maintenance as a key lever for enhancing sustainability and efficiency. The paper demonstrates, through simulation, the analysis of cost-relevant influencing factors and outlines the extension of the decision-making framework to include ecological dimensions.

1 Einleitung

Die fortschreitende wirtschaftliche und technologische Entwicklung und der zunehmende Fokus auf nachhaltige Wertschöpfung eröffnen produzierenden Unternehmen vielfältige Chancen. Die sogenannte Twin Transition, die integrative Verknüpfung von Digitalisierung und Nachhaltigkeit, gilt dabei als zentraler Treiber der europäischen Wirtschaft [1]. Ihr Ziel ist es, digital gestützte Wertschöpfung zu ermöglichen und gleichzeitig positive ökologische, ökonomische und soziale Vorteile zu generieren. Einen wesentlichen Beitrag dazu leistet die Instandhaltung, die zunehmend als Schlüsselfaktor für nachhaltiges Wirtschaften erkannt wird [2].

2 Instandhaltung als Schlüsselfaktor

Instandhaltung gilt zunehmend als zentraler Hebel für die nachhaltige und wirtschaftlich effiziente Transformation industrieller Produktionssysteme. Gerade im industriellen Umfeld tragen effektive Instandhaltungsstrategien dazu bei, Anlagenstillstände um 30–50 % und die Gesamtkosten der Instandhaltung um 10–15 % zu reduzieren. Sie stellen somit nicht nur einen wesentlichen Faktor zur Steigerung der Anlagenverfügbarkeit dar, sondern auch einen entscheidenden Beitrag zur ökonomischen Nachhaltigkeit [3].

Die rasanten technologischen Fortschritte in der Datenakquisition und -verarbeitung eröffnen vielfältige Möglichkeiten im Bereich der datengetriebenen und digital gestützten Instandhaltung [4]. Die größte Herausforderung besteht allerdings weiterhin darin, ausreichend geeignete (quantitative und qualitative) Daten für eine Instandhaltungsoptimierung zu gewinnen. Zudem

wird die Instandhaltung in Unternehmen weiterhin als Kostenfaktor statt als Wertschöpfungspartner betrachtet [5].

Ergänzend wirken politische und klimapolitische Rahmenbedingungen sowie Engpässe bei materiellen und personellen Ressourcen, die insbesondere europäische Industrieunternehmen vor erhebliche Herausforderungen stellen. Steigende Rohstoff-, Energie- und Arbeitskosten sowie zunehmende Umweltauflagen verlangen nach Instandhaltungsstrategien, die nicht nur technisch zuverlässig, sondern auch ressourcenschonend und kostenoptimal sind [6]. Eine zentrale Strategie liegt darin, den Ressourcenverbrauch von der ökonomischen Wertschöpfung zu entkoppeln. Der Übergang von linearen Produktionsmodellen hin zu zirkulären Wertschöpfungssystemen ist dabei eine zentrale Maßnahme zur Sicherung langfristiger Wettbewerbsfähigkeit und zur Erfüllung der EU-Nachhaltigkeitsziele [7].

Die Kreislaufwirtschaft (Circular Economy, CE) verfolgt das Ziel, Material- und Energieflüsse in geschlossenen Systemen zu erhalten und die Ressourceneffizienz über den gesamten Lebenszyklus technischer Güter zu maximieren [7, 8]. Die Grundlage hierfür sind die sogenannten zehn R-Strategien (R0-R9), die von der Reduktion und Wiederverwendung über die Reparatur und das Remanufacturing bis hin zum Recycling und der Rückgewinnung reichen. Durch diese Strategien werden Produktlebenszyklen verlängert, Abfallmengen minimiert und die Wiederverwertung wertvoller Materialien gefördert [9]. In diesem Zusammenhang nimmt die Instandhaltung eine Schlüsselfunktion ein. Neben der Betonung von Repair (R4), im Rahmen korrektiver Maßnahmen beeinflussen auch präventive und zustandsbasierte Strategien mehrere R-Strategien, insbesondere während der Nutzungs- und Überholungsphasen eines Produkts [10].

Eine kontinuierliche, systematische Instandhaltung trägt wesentlich dazu bei, die Lebensdauer von Anlagen zu verlängern, Ausfälle zu vermeiden und Rückschlüsse auf den Zustand einzelner Komponenten und Systeme zu ermöglichen. Dadurch verbessert sich nicht nur die Material- und Energieeffizienz, sondern auch die Gesamtleistung des Produktionssystems. Die enge Wechselwirkung zwischen effektiver Instandhaltung und den Zielen der Kreislaufwirtschaft verdeutlicht, dass wirtschaftliche und ökologische Nachhaltigkeit im industriellen Kontext nur durch ein integriertes, lebenszyklusorientiertes Instandhaltungsmanagement realisierbar ist [11].

Basierend auf den genannten technologischen Entwicklungen und Herausforderungen zielt dieser Beitrag darauf ab, die Erhebung von Kosteneinflussfaktoren in der Instandhaltung daten- und modellbasiert zu ermitteln, um dadurch Rückschlüsse auf eine effektive Instandhaltungsstrategie am Beispiel der Fallstudie zu ermitteln. Dazu werden bestehende Instrumente und Bewertungsmodelle mit Optimierungsmethoden verknüpft, an praktischen Daten angewandt und anhand fundierter Kennzahlen bewertet.

3 Bewertungsmethoden der Instandhaltungsstrategie

Eine nachhaltige und ganzheitliche Optimierung von Anlagen erfordert die systematische Integration von Instandhaltungsstrategien in den Lebenszyklus von Maschinen und Prozessen [12]. Bestehende Instandhaltungsstrategien umfassen ein breites Spektrum, das von klassischen reaktiven, präventiven und proaktiven datenbasierten Ansätzen über managementorientierte Konzepte wie Total Productive Maintenance (TPM) und Reliability Centered Maintenance (RCM) bis hin zu wissensbasierten und Sensorik gestützten Strategien reicht. Diese Ansätze zielen vorrangig auf die Sicherstellung von Anlagenverfügbarkeit, Effizienzsteigerung und Kostenoptimierung im Betrieb ab [13]. Allerdings berücksichtigen sie den Lebenszyklus von Anlagen und Komponenten sowie deren Wechselwirkungen mit übergeordneten Wertschöpfungs- und Stoffkreisläufen bislang nur unzureichend [12].

Die Lebenszykluskostenanalyse (Life Cycle Costing, LCC) stellt ein zentrales Instrument zur ökonomischen Bewertung technischer Systeme dar. Sie berücksichtigt sämtliche Kosten, die während des gesamten Lebenszyklus einer Anlage entstehen, von der Anschaffung über Betrieb und Wartung bis hin zu Stilllegung und Entsorgung. [9] Im Kontext der Instandhaltung ermöglicht LCC eine differenzierte Analyse, wie verschiedene Strategien und Maßnahmen die Gesamtkosten eines Systems langfristig beeinflussen [14].

Im Gegensatz zu traditionellen Kostenansätzen berücksichtigt LCC zukünftige Kostenentwicklungen und unterstützt die Auswahl kostenoptimaler Instandhaltungsstrategien. Höhere Anfangsinvestitionen in Zustandsüberwachung oder Predictive Maintenance können sich über den Lebenszyklus durch geringere Stillstands- und Ausfallkosten amortisieren [15]. Studien belegen, dass bis zu 60 % der Lebenszykluskosten technischer Anlagen durch Instandhaltung beeinflusst werden [16].

Aktuelle Ansätze erweitern LCC um probabilistische Verfahren, etwa Monte-Carlo-Simulationen, um Unsicherheiten in Kostenprognosen zu berücksichtigen und fundierte Entscheidungen zu ermöglichen [17, 18]. Damit verbindet LCC technische Zuverlässigkeit mit ökonomischer Effizienz und ökologischer

Verantwortung und etabliert die Instandhaltung als strategischen Hebel für nachhaltige Wettbewerbsfähigkeit [19].

Das Techno-Economic und Life Cycle Cost Analysis Modell von Barahmand und Eikeland [17] kombiniert technische und wirtschaftliche Parameter, um die Wirtschaftlichkeit von Instandhaltungsstrategien über den gesamten Lebenszyklus zu bewerten. Es berücksichtigt nicht nur direkte Kosten (zum Beispiel Wartung, Ersatzteile, Personal), sondern auch indirekte und unsichere Einflussgrößen wie Energiepreise, Ausfallwahrscheinlichkeiten oder Restwerte. Damit liefert das Modell eine quantitative Grundlage zur Optimierung der Wartungsstrategie unter Berücksichtigung technischer Performance, Kostenrisiken und Nachhaltigkeitsaspekte.

Gouveia et al. [18] verknüpfen ökologische und ökonomische Perspektiven in einem integrierten Life Cycle Assessment and Cost Analysis Modell, das Reparaturprozesse im industriellen Umfeld untersucht. Durch die gemeinsame Bewertung von Umweltwirkungen und Lebenszykluskosten lassen sich Instandhaltungsentscheidungen quantifizieren und Optimierungspotenziale transparent darstellen. Das Modell zeigt exemplarisch, wie sich Lebensdauerverlängerung und Kosteneffizienz im Sinne einer ressourcenschonenden Instandhaltung verbinden lassen.

Ergänzend kommen Simulationsframeworks, mathematische Optimierungsmodelle und IoT-basierte Entscheidungsunterstützungssysteme zum Einsatz, die datengetriebene Analysen und Handlungsempfehlungen für ressourceneffizientere und nachhaltigere Geschäftsmodelle ermöglichen [13, 20].

3.1 Unterstützende Simulationsframeworks

Moderne Instandhaltungsansätze beinhalten mathematische beziehungsweise simulationsgestützte Prozessmodelle mit technischen Beschreibungen, essenziellen historischen Daten sowie einer Zielfunktion und entsprechenden Optimierungsmethoden, die auf der Verbesserung des Verhältnisses von eingesetzten Kosten zum erzielten Nutzen abzielen. Dabei werden im Kern die folgenden vier Aspekte behandelt [20]:

- Eine technische Systembeschreibung, die Funktionalität und Wichtigkeit,
- Modellierung der zeitlichen Verschlechterung des Systems und möglicher Folgen,
- Beschreibung verfügbarer Informationen über das System und Maßnahmen,
- Aufsetzen einer Zielfunktion und einer Optimierungsmethode, um die bestmögliche Balance aus eingesetzten Kosten und erzieltem Nutzen zu gewährleisten.

Beim simulationsgestützten Prozessmodell für eine optimierte Instandhaltung werden die gesammelten historischen Daten und Informationen betreffend Ausfälle und Reparaturzeiten und Produktionsmengen sowie technischen Systemzuständen gesammelt, um daraus eine geeignete Instandhaltungsstrategie abzuleiten. Es wird eine Zielfunktion mit den durch das technische System gegebenen Nebenbedingungen bestimmt. Abschließend wird das Simulationsmodell basierend auf diskreter Simulation entwickelt und ausgeführt. In diesem Kontext werden der geeignete Optimierungsalgorithmus ausgewählt, die Simulationszeit festgelegt und diverse Verteilungen sowie Input-Parameter für die Modellbildung bestmöglich eingespielt. Dieses Vorgehen umfasst Parameter für die Zeit bis zum Ausfall beziehungsweise die Reparaturzeit, **Bild 1** [20].




Bild 1 Simulationsgestütztes Prozessmodell für die Auswahl der geeignetsten Instandhaltungsstrategie betreffend die Steigerung der Rentabilität [20].
 Grafik: Fraunhofer Austria Research GmbH

Im Rahmen des überwachten Lernens (engl. Supervised Learning) werden häufig mehrere Methoden in Bezug auf die Wurzel aus der mittleren quadratischen Abweichung (engl. root mean square error, RMSE) verglichen. Für die Prognose der restlichen, verbleibenden Nutzungsdauer von zum Beispiel Turbofan-Triebwerken im ersten Anwendungsfall werden dementsprechend Entscheidungsbäume (engl. Decision Trees), Support-Vektor-Maschinen (engl. Support Vector Machines, SVMs), Random Forest Ausprägungen, k Nearest Neighbors (kNN) Ansätze oder auch Gradient Boosting Machine untereinander in Bezug auf den

Prognosefehler verglichen. Anschließend wird der vielversprechendste methodische Ansatz ausgewählt, in dieser Fallstudie haben Random Forests den geringsten Fehler generiert. Bei einem zweiten Anwendungsfall, Schwingungsüberwachungsdaten, werden ebenfalls Random-Forest-Algorithmen zur Vorhersage von sogenannten Key Condition Indices (KCIs) verwendet, die den Schweregrad des beobachteten Ausfallmodus angeben. Im Vergleich zu einer Standard-Persistenz Technik ist der Fehler von Random Forests, gemessen anhand des RMSE, deutlich geringer [13].

Tabelle 1 KPIs und ihr Nutzen in der Fallstudie.

Features	Split nach binärer Encodierung
Instandhaltungswerk	4 Features (Standort A, Standort B, Standort C, Standort D)
IH-Leistungsart	6 Features (Abbruch, Inspektion, Modifikation, Reinigung, Reparatur, Wartung)
MTBA	4 Features (sehr häufig, häufig, gelegentlich, selten)
Bauteilalter	3 Features (jung, mittel, alt)

3.2 Unterstützende Bewertungsfaktoren in der Instandhaltung

Die Identifikation und Auswahl geeigneter Kennzahlen ist wesentlich, um die Kosten- und Leistungseinflüsse der Instandhaltung im Rahmen lebenszyklusorientierter Bewertungsansätze nachvollziehbar zu erfassen. In der Literatur werden insbesondere die Kennzahlen Mean Time Between Failure (MTBF), Mean Time To Repair (MTTR) und Overall Equipment Effectiveness (OEE) als zentrale Indikatoren zur Bewertung der Instandhaltungsleistung und ihrer Kosteneinflüsse hervorgehoben [21, 22]. Als weitere Größe zur zusätzlichen Berücksichtigung von ökologischen und sozialen Nachhaltigkeitsaspekten ist die Overall Sustainable Equipment Effectiveness (OSEE), deren Anwendung vor allem auf dem strategischen und operativen Bereich liegt [23].

Die MTBF beschreibt die durchschnittliche Zeitspanne zwischen zwei Ausfällen einer Anlage und dient als Maß für deren Zuverlässigkeit. Sie ermöglicht die Beurteilung der Häufigkeit von Ausfällen und stellt damit einen wichtigen Indikator zur Bewertung der Wirksamkeit von Instandhaltungsstrategien dar. Die MTTR gibt die durchschnittliche Zeit an, die erforderlich ist, um eine Anlage nach einem Ausfall wieder betriebsfähig zu machen. Sie dient zur Bewertung der Effizienz und Reaktionsfähigkeit von Instandhaltungsprozessen und erlaubt Rückschlüsse auf die organisatorische Leistungsfähigkeit im Instandhaltungsmanagement [21]. Ergänzend dazu führen Kuhlant *et al.* die Kennzahl Mean Time Between Assistance (MTBA) ein, welche die durchschnittliche Zeit zwischen notwendigen Unterstützungs- oder Hilfestellungen einer Maschine im Produktionsumfeld beschreibt. Im Gegensatz zur MTBF erfasst die MTBA auch externe Interventionen wie Störungen oder Bedienereingriffe und macht dadurch den Betreuungs- und Unterstützungsaufwand im Produktionsprozess transparenter [24].

Die OEE kombiniert die Faktoren Verfügbarkeit, Leistung und Qualität zu einer zusammenfassenden Kennzahl der Gesamtanlageneffektivität. Sie ermöglicht die Beurteilung, in welchem Umfang Anlagen ihr theoretisch verfügbares Produktionspotenzial tatsächlich ausschöpfen, und spiegelt damit die Gesamtwirkung der Instandhaltungsaktivitäten auf die Produktionsleistung wider. Zusammen bilden MTBF, MTTR und OEE ein Kernset objektiver Kennzahlen, das als Grundlage zur Bewertung von Kosteneinflussfaktoren in der Instandhaltung herangezogen wird. Sie ermöglichen die Analyse der Zusammenhänge zwischen Zuverlässigkeit, Effizienz und Anlagenleistung und dienen damit als Grundlage für die quantitative Beurteilung der Instandhaltungsleistung im Rahmen lebenszyklusorientierter Bewertungsmodelle [21, 22].

Anhand einer exemplarischen Anwendung in einer industriellen Fallstudie werden die ökonomischen Faktoren instand-

haltungsbezogener Entscheidungsfindung mittels Simulation mit dem Ziel kostenbeeinflussende Faktoren sowie Zielkonflikte zwischen alternativen Instandhaltungsstrategien zu identifizieren, erhoben.

4 Industrielle Fallstudie aus der Praxis

Zur Erhebung der ökonomischen Faktoren werden die Gesamtkosten herangezogen und durch eine Nutzenperspektive ergänzt, die sich in der Messbarkeit anhand klar definierter Kennzahlen (KPIs) widerspiegelt. Der Fokus einer optimierten Instandhaltungsstrategie liegt dabei auf der Verbesserung dieser KPIs im Rahmen einer Kosten-Nutzen-Analyse, mit dem Ziel, die technische Verfügbarkeit (OEE) und damit die Effektivität der Instandhaltungsmaßnahmen zu maximieren. Eine effektive Instandhaltung konzentriert sich dabei vor allem auf die Optimierung der in **Tabelle 1** dargestellten KPIs. In der Fallstudie werden die Werte der MTBA auf Monatebene verwendet.

Auf Grund der oben angemerkten Genauigkeit bringen wir in Bezug auf den instandhaltungsorientierten Anwendungsfall aus der Branche der Faserindustrie einen maßgeschneiderten Random Forest Algorithmus für die Klassifikation zur Anwendung. Im Fokus der Betrachtung stehen dabei gemäß RCA die verschiedenen Objekttypen und Anlagen je Standort, insbesondere Pumpen, welche zur Instandhaltung maßgeblich beitragen. Weitere im Rahmen der Differenzierung und Modellbildung wichtige Objekt- und Anlagentypen im Zuge dieses Anwendungsfalles aus der Instandhaltung sind das Rührwerk, die Walze oder auch Motoren und Antriebe.

Zur Verfügung stehende Daten sind: Betriebsdauer der einzelnen Aggregate – über das Anlagenalter beziehungsweise Baujahr, diverse auftragsbezogene Anlagenkennzahlen – Anzahl abgeschlossener Aufträge gesamt beziehungsweise pro Jahr, die Daten- und Kostenhistorie inklusive Erfassungsdatum sämtlicher Aktivitäten und Leistungsarten über mehrere Jahre, standortspezifische Daten – betroffenes Werk, Zuordnung Anlage zu einer Linie beziehungsweise einem Bereich, die Korrelation der Größe eines Werks zur Output-Menge Fasern – sowie der jeweilige Wiederbeschaffungswert einer Anlage. Der Datenumfang beträgt für den Datensatz mit einem Standort circa drei Jahre (2022 – 2024) beziehungsweise 6800 Instandhaltungs-Auftragskostenzeilen sowie für den werksübergreifenden Datensatz 9500 Auftragszeilen beziehungsweise circa 20 Jahre (2005 – 2024). Es wird jeweils ein Modell für den jeweiligen Datensatz erstellt.

Die Standortübersicht, **Tabelle 2**, gibt einen guten Überblick über den Werkswiederbeschaffungswert, die jährlichen Instandhaltungskosten sowie dem Produktionsvolumen. Auf Basis dieser Angaben wird im Zuge der Modellierung ein Instandhaltungskostenindex für einen Objekttyp (Pumpen) abgeleitet. Dieser dient als Zielfunktionswert für eine Modellvariante.

Tabelle 2 Standortübersicht (Wiederbeschaffungswert, jährliche Instandhaltungskosten, Jahresdurchsatz).

Standort	Wiederbeschaffungswert	Instandhaltungskosten p.a.	Produktionsvolumen p.a. [t]
A	€ 400.000.000	€ 11.095.000	44.208,00
B	€ 1.100.000.000	€ 19.721.000	208.006,00
C	€ 600.000.000	€ 10.284.000	101.950,00
D	€ 460.750.000	€ 8.276.000	44.783,00

Tabelle 3 Kategorisierung von Features und IH-Auftragskosten.

Features	Split nach binärer Encodierung
Instandhaltungswerk	4 Features (Standort A, Standort B, Standort C, Standort D)
IH-Leistungsart	6 Features (Abbruch, Inspektion, Modifikation, Reinigung, Reparatur, Wartung)
Anlagentyp	6 Features (Pumpe, Rührwerk, Walze, Motor, Antrieb, Ballenpresse)
MTBA	4 Features (sehr häufig, häufig, gelegentlich, selten)
Bauteilalter	3 Features (jung, mittel, alt)

Tabelle 4 Features und Encodierung (Datensatz beziehungsweise Modell 1).

Features	Split nach binärer Encodierung
Anlagentyp	5 Features (Pumpe, Spinnerei, Behälter & Tank, Allgemein, Sonstige)
Schadensbild	9 Features (Kabel defekt, Lager defekt, Luftleitung undicht, Messwert abweichend, Programmierung/PLS fehlerhaft, Rohrleitung geplatzt, Sensor defekt, Sensor verschmutzt, Sonstiges)
Bauteilalter	3 Features (jung, mittel, alt)

In Bezug auf die Leistungsarten werden Inspektion, Wartung, Modifikation, Reinigung und Reparatur sowie Abbruch mit einer hinterlegten Priorität mit Werten zwischen null und vier differenziert. Am jeweiligen Standort sind Pumpen einer Linie beziehungsweise einem Bereich zugeordnet. Außerdem ist eine Fehlerbeschreibung sowie ein Schadensbild zu jeder Leistungsart dazugehörig beschrieben. In der Regel ist der Anlagenhersteller nur teilweise (unvollständig) gepflegt.

Das oberste Auswertungsziel besteht in der Ermittlung der Einflussfaktoren in Bezug auf die Instandhaltungskosten. Also wird die Zielfunktion in Anlehnung an Bild 1 über die (größten) Kostentreiber formuliert. Die realen Instandhaltungskosten sind über den historischen Betrachtungszeitraum (drei beziehungsweise 20 Jahre) im Modell berücksichtigt. In Bezug auf die Methodologie wird ein vorbereitender Datenaufbereitungsschritt, das sogenannte Preprocessing durchgeführt. Ergebnis ist die Einteilung der Kosten in drei Kategorien (gering, mittel, hoch). In gleicher Art und Weise werden die verwendeten Features (MTBA, Anlagentyp, Bauteilalter etc.) im Rahmen der Modellbildung generiert und kategorisiert, **Tabelle 3**. Die jeweiligen Klassen werden in Anlehnung an eine ABC-Analyse derart gebildet, so dass in jeder Kategorie genügend viele Vertreter vorhanden sind.

Anschließend werden weitere Features (Instandhaltungswerk, Auftragstypen, Technische Platzbezeichnung) des Modells erstellt und entsprechend encodiert. Eine Encodierung bedeutet, dass aus einer Spalte mit mehreren Einträgen (zum Beispiel vier Werks-

standorte) jeweils separate binäre Spalten, zum Beispiel für die jeweiligen Werksstandorte, generiert werden.

Datensatz 1 erstellt, unter Verwendung des jeweils zugeschnittenen Random Forests, mit den encodierten Features, **Tabelle 4**, ein Modell für die Vorhersage von Kostentreibern (hoch) mit einer erzielten Genauigkeit von 88,6 % (Tabelle 6). Bereits zwei der 17 Features, defekte Lager als auch Spinnereien, tragen bereits > 50 % zur Modellgenauigkeit bei. Weitere signifikante Beiträge erhält das Modell von einem hohen Anlagentypalter sowie dem Objekttyp Pumpe. Die Top fünf Features steuern also circa 70 % zur Modellgenauigkeit bei.

Datensatz 2 erstellt, unter Verwendung des jeweils zugeschnittenen Random Forests, mit den encodierten Features, **Tabelle 5**, ein Modell mit unterschiedlichen Kostenausprägungen betreffend die Zielfunktion, siehe die Varianten eins bis vier zum zweiten Modell aus **Tabelle 6**.

Betreffend Variante vier aus dem zweiten Modell wurde ein Kostenindex für den Objekttyp Pumpe erstellt. Dieser besteht aus den anteilig für Pumpen je Standort aufgetretenen Instandhaltungskosten und multipliziert den Instandhaltungskostenanteil für Pumpen mit dem relativen IH-Kostenanteil für Pumpen gemessen am Werks-Wiederbeschaffungswert sowie mit den IH-Kosten für Pumpen pro Tonne. Variante vier erzielt die höchste Modellgenauigkeit, wobei fast 50 % der Modellgenauigkeit von drei Features (Objekttyp Pumpe, Standort D, MTBA: selten) beigesteuert werden. In den Top 10 sind außerdem noch die Features MTBA: häufig/sehr häufig sowie ein hohes Bauteilalter vertre-

Tabelle 5 Features und Encodierung (Datensatz beziehungsweise Modell 2).

Features	Split nach binärer Encodierung
Instandhaltungswerk	4 Features (Standort A, Standort B, Standort C, Standort D)
IH-Leistungsart	6 Features (Abbruch, Inspektion, Modifikation, Reinigung, Reparatur, Wartung)
MTBA	4 Features (sehr häufig, häufig, gelegentlich, selten)
Bauteilalter	3 Features (jung, mittel, alt)

Tabelle 6 Ergebnisvergleichstabelle der vier Varianten von Modell 2 gegenüber Modell 1.

Modell	Variante	Zielfunktion	Modellgenauigkeit	Top 3 Features und Modellbeitrag
1	1	Kostentreiber (hoch)	88,6%	Defektes Lager (39,2%) , Spinnerei (11,9%), Sonstige (6,9%)
2	1	Kostentreiber (hoch)	81,2%	Motor (21,7%) , MTBA: selten (17,9%) , Pumpe (8,7%)
2	2	Kostentreiber (mittel)	76,7%	MTBA: selten (14,4%) , Standort D (13,3%) , MTBA: häufig (9,7%)
2	3	Kostentreiber (gering)	70,9%	Motor (20,6%) , MTBA: selten (20%) , Standort D (8,2%)
2	4	Kostenindex (hoch)	97,1%	Pumpe (19,5%) , Standort D (17,4%) , MTBA: selten (11,7%)

ten. Dementsprechend tragen über elf Jahre alte Pumpen am Standort D, die entweder selten oder (zu) häufig instandgehalten werden, zu den intensiven Kostentreibern an diesem Standort bei.

Jene Varianten, welche auf die Klassifikation der Kostentreiber abzielen (Variante eins der Modelle eins und zwei sowie Variante vier von Modell zwei) verfügen über eine höhere Genauigkeit gegenüber den Varianten, die geringe oder mittlere Kosteneinflussgrößen bewerten. Motoren können einerseits geringe Kosten verursachen als auch intensive Kostentreiber darstellen.

Die Konfusionsmatrix teilt die Ergebnisse in Form einer Heatmap in vier Kategorien ein [25], basierend auf der anteiligen (Nicht-) Übereinstimmung zwischen vorhergesagten und tatsächlichen Werten (siehe Tabelle 6). Konkret zeigt diese im linken oberen Quadranten den hohen Anteil korrekt vorhergesagter zu tatsächlichen Werten (True Positive, TP) beziehungsweise gleichermaßen auch die geringen Anteile von Werten in den drei übrigen Kategorien. Auf dem gegenüberliegenden rechts unten befindlichen Quadranten sind vorhergesagte und tatsächliche Werte negativ (True Negative, TN). Diese beiden Kategorien tragen also zur Modellgenauigkeit (siehe Tabelle 6) bei. Der linke untere Quadrant beschreibt die Anzahl an Beobachtungen mit negativen Vorhersagen, während der reale Wert positiv ist (False Negative, FN). Der rechte obere Quadrant enthält jene tatsächlich negativen Werte, die positiv vorhergesagt worden sind (False Positive, FP). Die Modellgenauigkeit (accuracy) aus Tabelle 6 misst den Anteil korrekter Klassifikationen an der Grundgesamtheit und wird wie folgt definiert:

$$accuracy = \frac{\text{correct classifications}}{\text{total classifications}} = \frac{(TP+TN)}{(TP+TN+FP+FN)} \quad [26]$$

Bild 2 stellt die beiden Modellvarianten mit der größten Genauigkeit gegenüber. Beide Modellvarianten enthalten jeweils nur Einträge aus den Kategorien TP und FN, wobei das Modell mit der höheren Genauigkeit einen höheren TP-Anteil aufweist.

Zusammenfassend lässt sich auf Basis der ausgewerteten industriellen Fallstudie festhalten, dass sich ein MTBA-Wert von über 36 Monaten negativ auf die zu erwartenden Instandhaltungskosten, insbesondere von Pumpen, auswirkt. Eine Verkürzung der Wartungs- beziehungsweise Inspektionsintervalle verursacht ebenfalls zusätzliche Kosten, die in diesem Kontext untersucht und gegenübergestellt werden müssten beziehungsweise nicht bekannt sind. In Bezug auf das Schadensbild sind, über alle Objekttypen hinweg, Lagerdefekte besonders negativ im Sinne der Instandhaltungskostentreiber aufgefallen. Bezüglich der Auftragsart haben Reparaturen in fast jeder Modellvariante den größten Beitrag (< 6 %) zu den Kosten des jeweiligen Modells beige-steuert (Eine Ausnahme: Modell zwei, Variante zwei: Wartung mit circa 7 % Modellbeitrag). In Bezug auf das Bauteilalter haben sich ältere Anlagen beziehungsweise Bauteile kostentechnisch etwas negativer gegenüber jüngeren Anlagen ausgedrückt. Der jeweilige Modellbeitrag liegt je Altersgruppe im einstelligen Prozentbereich (< 5 %). In Bezug auf die jeweiligen Werksstandorte hat sich Standort D als Instandhaltungskostentreiber gegenüber den drei weiteren Standorten herauskristallisiert. Ein Standort hat die Instandhaltungskosten für Pumpen jedoch nur mangelhaft erfasst.

5 Forschungsausblick

Im Rahmen der vorangegangenen Fallstudie wurden die historischen Kosteneinflussfaktoren identifiziert, welche die Entscheidung über Instandhaltungsstrategien maßgeblich beeinflussen. Dabei zeigten sich insbesondere Instandhaltungskosten, Wiederbeschaffungswert und Produktionsvolumen als entscheidende Größen für die strategische Planung. Deutlich wurde jedoch, dass bislang eine integrierte Betrachtung ökologischer Faktoren, etwa hinsichtlich Energieverbrauch, Ressourceneffizienz oder CO₂-Emissionen, fehlt. Dadurch bleibt der Einfluss ökologischer





Bild 2 Vergleich der Konfusionsmatrizen: (links: Modell 2, Variante 4) versus (rechts: Modell 1, Variante 1). Grafik: Fraunhofer Austria Research GmbH

Bild 3 LOOP-Modell zur ökonomischen und ökologischen Bewertung von Instandhaltungsmaßnahmen [12]. Grafik: Fraunhofer Austria Research GmbH



Aspekte auf die Lebenszyklusbewertung (Life Cycle Assessment, LCA) von Instandhaltungsmaßnahmen bislang unzureichend erprobt.

Eine regelmäßige und systematische Instandhaltung verlängert die Lebensdauer von Maschinen und verhindert potenzielle Ausfälle. Damit liefert sie auch Einblicke in den Zustand von Produkten und Systemen während der Nutzung, einschließlich Subsystemen und Komponenten. Dies wirkt sich positiv auf Materialnutzung und Energieverbrauch aus und trägt somit zu mehr Ressourceneffizienz und dem Abfallmanagement bei. Es besteht daher ein enger Zusammenhang zwischen „effektiver Instandhaltung“ und den CE-Zielen [11, 27].

Im, in **Bild 3** dargestellten, LOOP-Modell werden die drei kreislauforientierten Instandhaltungsaktivitäten – Retrofit, Refurbishment und Remodernisation – mit bestehenden Strategien beziehungsweise Maßnahmen der Instandhaltung bewertet. Systemwechsel- (Replacement-) Strategie als Ersatz des bestehenden Systems durch ein neues (zum Beispiel durch Neukauf) oder Ersatz des bestehenden Systems durch ein gebrauchtes (zum Beispiel durch Erwerb eines Second-Hand-Systems). Korrigierende Instandhaltungsstrategie (Repair): Durchführung von Instandhaltungsmaßnahmen im Schadensfall gemäß gültigen Spezifikationen und Normen. [12]

Die Inputparameter des Modells gliedern sich in ökonomische (Gesamtkosten) und ökologische (CO₂-Rucksack) Faktoren, sowie konstante Werte zur geplanten Restnutzungsdauer. Die Gesamtkosten werden aus direkten Personal- und Materialkosten ermittelt, der CO₂-Rucksack ergibt sich aus der Kombination relevanter Umweltfaktoren der Lebensphasen, die sowohl investitionsbedingte als auch betriebs- und instandhaltungsbedingte An-

teile enthalten. Das Ziel ist es, das Loop-Modell in einer breiten industriellen Anwendung zu erproben und dabei die automatisierte Gesamtkostenermittlung als zentralen Bestandteil zu integrieren. Diese ermöglicht eine präzisere Identifikation und Quantifizierung von Kosteneinflussfaktoren, wodurch die Berechnung der Lebenszykluskosten (LCC) deutlich genauer erfolgen kann. Durch die Erweiterung des Modells soll eine verfeinerte Parametrisierung erreicht werden, bei der vorhandene Datenquellen mit neu ergänzten Datenanschlüssen effizient verknüpft und relevante Informationen automatisiert in das Modell eingespeist werden.

Vor diesem Hintergrund zielen geplante Forschungsvorhaben darauf ab, basierend auf dem eingeführten Loop-Modell [12], die Umsetzung durch die Kopplung der Ergebnisse und Methodiken dieses Beitrags mit LCA-Analysen, sowie durch die Entwicklung einer standardisierten Datenpipeline zur Integration und Auswertung von Instandhaltungs-, Energie- und Prozessdaten. Die Validierung in der industriellen Anwendung und dessen Übertragbarkeit auf andere Anlagentypen und Branchen, die Erweiterung um soziale und risikobasierte Indikatoren sowie die Integration in digitale Zwillinge ist darüber hinaus Gegenstand der Forschungsvorhaben. Als nächsten Schritt schlagen die Autoren vor, das entwickelte Modell auf einen praxisnahen Anwendungsfall in die Metallindustrie zu übertragen. Dadurch kann die Anwendbarkeit erneut in einer weiteren Branche gezeigt, die Datenintegration getestet und das Zusammenspiel von ökonomischer und ökologischer Optimierung im industriellen Kontext validiert und das Modell angepasst und verfeinert werden. Dadurch entsteht ein Instrument, das Kosten- und Emissionsziele simultan adressiert und datenbasiert zu einer ökologisch nachhaltigen Entscheidungsfindung im Asset Management beiträgt.

6 Zusammenfassung

Diese Arbeit zeigt, dass eine ganzheitliche Bewertung von Instandhaltungsmaßnahmen nur durch die Verknüpfung ökonomischer und ökologischer Perspektiven möglich ist. Im Beitrag wurden die ökonomischen Faktoren um die Ermittlung von historischen Kosteneinflussfaktoren erweitert, wodurch zusätzlich im Fallbeispiel ein Standortvergleich ermöglicht wurde. Für die vollständige Prognoserechnung müssen diese Kosteneinflussfaktoren durch Zeitwerte wie Zinsen, Inflation etc. höher aufgelöst werden. Eine ökologische Bewertung war im Fallbeispiel mangels Datenverfügbarkeit nicht im Modell abbildbar. Das Ziel ist es, auf dieser Basis eine nachhaltige, kreislaforientierte Instandhaltungsstrategie zu entwickeln, die technische Leistungsfähigkeit, Ressourceneffizienz und Wirtschaftlichkeit vereint. Den Rahmen bildet das Loop-Modell, das ökonomische und ökologische Faktoren bereits theoretisch kombiniert.

Die Verfügbarkeit und Qualität der Datengrundlage stellt eine zentrale Herausforderung für die Weiterentwicklung des Modells dar. Sowohl die ökonomische als auch die ökologische Bewertung erfordern valide, konsistente und vergleichbare Daten, die in der Praxis häufig nur eingeschränkt vorliegen. Insbesondere sind die Daten für die Gesamtkostenermittlung oftmals lückenhaft oder historisch unvollständig dokumentiert, beispielsweise in Form handschriftlicher Aufzeichnungen älterer Anlagen. Um diese Defizite zu überwinden, ist der Einsatz moderner Datenerfassungs- und -Management Systeme erforderlich, die eine standardisierte Digitalisierung, Strukturierung und Integration bestehender Informationen ermöglichen.

Im Bereich der ökologischen Bewertung zeigt sich die Problematik der Datenverfügbarkeit gleichermaßen. Es fehlt vielfach an einer einheitlichen, standardisierten Datenbasis, die eine konsistente Verknüpfung mit ökonomischen Parametern zulässt. Zur Schaffung einer belastbaren Bewertungsgrundlage wird daher der Aufbau eines zentralen, standardisierten Datensystems von den Autoren empfohlen. Dieses kann durch die Einbindung bestehender digitaler Instrumente, wie des Digitalen Produktpasses (DPP), unterstützt werden. Eine derartige Systematik kann die harmonisierte Erfassung, Vergleichbarkeit und Integration ökologischer und ökonomischer Einflussgrößen ermöglichen und somit eine wesentliche Voraussetzung für nachhaltige und datenbasierte Instandhaltungsentscheidungen schaffen. Ein zusätzlicher Fokus soll auf die Weiterentwicklung der ökologischen Faktoren gelegt werden, um diese in realen Anwendungsfällen zu erproben oder mangels Datenverfügbarkeit alternative Bewertungsmöglichkeiten zu entwickeln.

Auf diese Weise kann langfristig ein standardisierbares Framework entstehen, das Unternehmen ermöglicht, Instandhaltungsstrategien entlang des gesamten Lebenszyklus ökonomisch effi-

LITERATUR

- [1] Gallina, V.; Steinwender, A.; Zudor, E. et al.: Business model development concept for SMEs in the era of twin transition. *Procedia Computer Science* 232 (2024) 1, S. 523–532
- [2] Madreiter, T.; Trajanoski, B.; Martinetti, A. et al.: Sustainable Maintenance: What are the key technology drivers for ensuring Positive Impacts of Manufacturing Industries? *IFAC-PapersOnLine* 58 (2024) 19, S. 616–621
- [3] McKinsey & Company: Capturing the true value of Industry 4.0. Stand: 13.04.2022. Internet: <https://www.mckinsey.com/capabilities/operations/our-insights/capturing-the-true-value-of-industry-four-point-zero>. Zugriff am 10.10.2025
- [4] Ucar, A.; Karakose, M.; Kırımca, N.: Artificial Intelligence for Predictive Maintenance Applications: Key Components, Trustworthiness, and Future Trends. *Applied Sciences* 14 (2024) 2, S. 898
- [5] Greimel, L.; Guhl, J.; Toth, D. et al.: Instandhaltung für die Positive Impact Production. *ZWF Zeitschrift fuer Wirtschaftlichen Fabrikbetrieb* 119 (2024) 9, S. 653–658
- [6] Matti, C.; Jensen, K.; Goran, P. et al.: Towards a fair and sustainable Europe 2050: Social and economic choices in sustainability transitions. pp. 1018–5593 (2023)
- [7] Kara, S.; Hauschild, M.; Sutherland, J. et al.: Closed-loop systems to circular economy: A pathway to environmental sustainability? *CIRP Annals* 71 (2022) 2, S. 505–528
- [8] Foundation, E. M.: The circular economy in detail. Internet: <https://www.ellenmacarthurfoundation.org/the-circular-economy-in-detail-deep-dive>
- [9] DIN e. V.: VDI Verein Deutscher Ingenieure e.V. Deutsche Normungsroadmap Circular Economy. DKE Deutsche Kommission Elektrotechnik Elektronik und Informationstechnik
- [10] José Sobral; Luis Ferreira: The Importance of Reliability and Maintenance for the Circular Economy: from Consumers to Users. In: *EURO-MAINTENANCE* 2018
- [11] Mügge, J.; Hahn, I. R.; Riedelsheimer, T. et al.: Digital Twins for Circular Economy - Enabling Decision Support for R-Strategies. *Industrie 4.0 Management* 2022 (2022) 6, S. 42–46
- [12] Greimel, L.; Nemeth, T.; Wiesner, J.-O. et al.: LOOP: An assessment framework for circular-oriented maintenance in product lifecycle management. *Procedia CIRP* 134 (2025), S. 1095–1100
- [13] Schenkelberg, K.; Seidenberg, U.; Ansari, F.: Supervised Machine Learning for Knowledge-Based Analysis of Maintenance Impact on Profitability. *IFAC-PapersOnLine* 53 (2020) 2, S. 10651–10657
- [14] Kambanou, M. L.: Life Cycle Costing: Understanding How It Is Practised and Its Relationship to Life Cycle Management - A Case Study. *Sustainability* 12 (2020) 8, S. 3252
- [15] Fourie, C. J.; Tendayi, T. G.: A decision-making framework for effective maintenance management using life cycle costing (LCC) in a rolling stock environment. *South African Journal of Industrial Engineering* 27 (2016) 4
- [16] Carlos A Parra: Review of the basic processes of a Maintenance and Reliability Management Model PROJECT: Design and Construction of the Third Set of Locks in the ACP (AUTORIDAD DEL CANAL DE PANAMÁ) IngeCon MWH GLOBAL. Unpublished 2015
- [17] Barahmand, Z.; Eikeland, M. S.: Techno-Economic and Life Cycle Cost Analysis through the Lens of Uncertainty: A Scoping Review. *Sustainability* 14 (2022) 19, S. 12191
- [18] Gouveia, J. R.; Pinto, S. M.; Campos, S. et al.: Life Cycle Assessment and Cost Analysis of Additive Manufacturing Repair Processes in the Mold Industry. *Sustainability* 14 (2022) 4, S. 2105
- [19] Kerdlap, P.; Cornago, S.: Life Cycle Costing: Methodology and Applications in a Circular Economy. In: *An Introduction to Circular Economy*. Springer, Singapore 2021, pp. 499–525
- [20] Schenkelberg, K.; Seidenberg, U.; Ansari, F.: A Simulation-based Process Model for Analyzing Impact of Maintenance on Profitability. 2020 25th IEEE International Conference on Emerging Technologies and Factory Automation (ETFA), Vienna, Austria, 2020, S. 805–812
- [21] Muchiri, P.; Pintelon, L.; Gelders, L. et al.: Development of maintenance function performance measurement framework and indicators. *International Journal of Production Economics* 131 (2011) 1, S. 295–302
- [22] Kumar, U.; Galar, D.; Parida, A. et al.: Maintenance performance metrics: a state-of-the-art review. *Journal of Quality in Maintenance Engineering* 19 (2013) 3, S. 233–277
- [23] Madreiter, T.; Ansari, F.: From OEE to OSEE: How to reinforce Production and Maintenance Management Indicator Systems for Sustainability? *IFAC-PapersOnLine* 58 (2024) 8, S. 204–209
- [24] Kuhlmann, P.; Benter, M.; Neumann, M.; Eckart, C.: Digitalisierung der MTM-Methoden. Perspektiven zur Gestaltung produktiver und ergonomiegerechter Arbeit in Produktion und Logistik. Hamburg 2023

DANKSAGUNG

Die beschriebenen Ergebnisse und Entwicklungen entstanden im Rahmen eines Projekts der Förderung des BMWET.

- [25] Murel, J.; Kavlakoglu, E.: Was ist eine Konfusionsmatrix? Artificial Intelligence. Stand: 18.01.2024. Internet: <https://www.ibm.com/de-de/think/topics/confusion-matrix>. Zugriff am 20.10.2025
- [26] Google LLC.: Classification: Accuracy, recall, precision, and related metrics. Google for Developers. Stand: 08/2025. Internet: <https://developers.google.com/machine-learning/crash-course/classification/accuracy-precision-recall>. Zugriff am 20.10.2025
- [27] Winquist, E.; Horn, S.; Tuovila, H. et al.: R-strategies in circular economy Textile, battery, and agri-food value chains R-strategies in circular economy Textile, battery, and agri-food value chains Referencing instructions. 2025

Dipl.-Ing. Lisa Greimel

Dr. Felix Kamhuber

Dr. Luisa Chalupa

Fraunhofer Austria Research GmbH
Theresianumgasse 7, 1040 Wien
www.fraunhofer.at

**Univ.-Prof. Dr.-Ing.
Fazel Ansari**

Technische Universität Wien |
Fraunhofer Austria Research GmbH
Theresianumgasse 27 | Theresianumgasse 7
1040 Wien

LIZENZ



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