

Studienreports des Lehrstuhls für Produktionswirtschaft, Band 11

KI-basierte Instandhaltungsplanung und –steuerung im öffentlichen Verkehr – Status quo und konzeptionelle Überlegungen



Impressum

Winkler, Herwig / Hayat, Mubashir / Rüster, Moritz: KI-basierte Wartungsauftragsplanung und -steuerung im öffentlichen Verkehr – Status quo und konzeptionelle Überlegungen

Reihe: Studienberichte des Lehrstuhls für Produktionswirtschaft, Band 11

Brandenburgische Technische Universität Cottbus-Senftenberg
IKMZ – Universitätsbibliothek

Cottbus, 15. September 2025

DOI: <https://doi.org/10.26127/BTUOpen-7161>

Die vorliegende Studie wurde im Rahmen des Forschungsprojekts D4M durchgeführt. Um die Verfügbarkeit umweltfreundlicher öffentlicher Verkehrsmittel wie Schienenfahrzeuge oder Busse zu erhöhen, soll künstliche Intelligenz (KI) eingesetzt werden, um Planungs- und Steuerungsprozesse für Inspektion, Wartung und Reparatur zu optimieren. Ziel ist es, die notwendigen Wartungsarbeiten kostengünstiger und mit kürzeren Arbeitszeiten durchzuführen. D4M untersucht und entwickelt von 08/2024 bis 07/2027 KI-basierte Lösungen, um diese Herausforderungen zu bewältigen.

Die Instandhaltung öffentlicher Verkehrsmittel wie Bahnsysteme, Busse, Flugzeuge usw. hat einen großen Einfluss auf deren Verfügbarkeit, Sicherheit und Wirtschaftlichkeit. Der Erfolg der Instandhaltungsplanung hängt derzeit stark von der Erfahrung und den Fähigkeiten des Planers ab.

Für die Planung von Instandhaltungsaufträgen und die Steuerung der Instandhaltungsarbeiten sind im Vorfeld vielfältige Daten aus typspezifischen Revisionsvorschriften und individuellen Erkenntnissen bereitzustellen, um den Zustand von Systemen und Komponenten zu beurteilen und den Umfang der Instandhaltung zu bestimmen. Die Vielzahl unterschiedlicher Fahrzeugsysteme, die zu unterschiedlichen Zeitpunkten gewartet, überholt und repariert werden müssen, führt zu komplexen Anforderungen an die Instandhaltungsdepots bei der Auftragsplanung. Instandhaltungsarbeiten sind daher als Projekte mit langer Vorlaufzeit zu planen und in den zuständigen Werken vorzubereiten. Qualifizierte Mitarbeiter haben frühzeitig die erforderlichen Maschinen und Werkzeuge sowie die notwendigen Materialien zu planen. Nur durch eine geeignete Auftragsplanung können die Arbeiten wirtschaftlich durchgeführt und die in der Fabrik verbrachte Zeit gemäß den Kundenanforderungen eingehalten werden.

Ziel ist es, ein geeignetes Datenmodell zu erstellen, das aus Revisionsvorschriften und stochastischen Ergebnissen von Befunden besteht und auf realen Instandhaltungsanforderungen basiert. Mit Hilfe der Datenbank sollen wöchentlich KI-Algorithmen für die Grobplanung von Instandhaltungsprozessen generiert werden. Basierend auf den prognostizierten Ergebnissen der Grobplanung soll ein weiterer KI-Ansatz (Reinforcement Learning) zur Unterstützung der konkreten Anlagensteuerung in der Fertigung eingesetzt werden.

Gefördert durch:



Bundesministerium
für Digitales und
Staatsmodernisierung

aufgrund eines Beschlusses
des Deutschen Bundestages



Durch eine sorgfältige Instandhaltung von Zügen, Bussen und Flugzeugen lässt sich die Verfügbarkeit, Betriebssicherheit und Wirtschaftlichkeit dieser Verkehrsmittel maßgeblich sichern. Bislang wurden die dafür relevanten planungsintensiven Prozesse in Zugwerkstätten mit herkömmlichen statischen Planungssystemen durchgeführt. Diese Systeme bilden zwar eine Grundlage für die Organisation der Instandhaltungsarbeiten, sind jedoch nicht in der Lage, optimierte Instandhaltungsprogramme zu erstellen. Infolgedessen treten während der tatsächlichen Durchführung der Instandhaltungsmaßnahmen häufig ungeplante Zusatzaufgaben auf, die den Arbeitsablauf in den Instandhaltungswerkstätten stören und sowohl die wirtschaftliche als auch die betriebliche Effizienz beeinträchtigen. Es hat sich gezeigt, dass solche Störungen häufig zu erhöhten Instandhaltungskosten, längeren Durchlaufzeiten und einer verminderten Anlageneffizienz führen. Daher besteht ein wachsender Bedarf, bei der Instandhaltungsplanung und -steuerung im öffentlichen Verkehrssektor von statischen zu dynamischeren, datengesteuerten Ansätzen überzugehen.

Künstliche Intelligenz (KI) bietet in dieser Hinsicht ein erhebliches Potenzial, da sie die Entwicklung von Vorhersagefähigkeiten, dynamischer Planung und intelligenter Ressourcenzuweisung erleichtert. Zu diesem Zweck werden in dieser Studie bestehende Forschungsarbeiten zu KI-Ansätzen für die Wartungsplanung und -steuerung in diesen Bereichen des öffentlichen Verkehrs systematisch untersucht und bewertet. Anhand einer deskriptiven Analyse werden neue Forschungstrends vorgestellt, während eine detaillierte Inhaltsanalyse die Ergebnisse der relevantesten Artikel in diesem Bereich zusammenfasst. Die Analyseergebnisse zeigen, dass sich die meisten Forschungsarbeiten isoliert auf bestimmte Aspekte wie die Vorhersage der verbleibenden Nutzungsdauer und die Fehlerdiagnose konzentrieren. In der Praxis umfasst die Wartungsplanung und -steuerung jedoch eine komplexe Koordination vieler Aktivitäten (z. B. Inspektion, Ressourcenzuweisung und Personal- und Aufgabenplanung usw.). Daher sind die Autoren der Ansicht, dass noch holistischere Lösungen erforderlich sind, die Instandhaltungsaktivitäten und Werkstattbeschränkungen integrieren und über Einzelkomponentenvorhersagen hinaus zu einer Optimierung der Instandhaltung auf Systemebene führen, die in realen Instandhaltungsbetrieben validiert werden kann.

Darüber hinaus wird in diesem Studienbericht ein konzeptioneller Rahmen vorgestellt, der die Planung und Steuerung von Instandhaltungsaufträgen in Instandhaltungswerkstätten des öffentlichen Nahverkehrs verbessern soll. Der vorgeschlagene Rahmen dient als Grundmodell für den Einsatz von KI-Technologien zur Reduzierung von Ineffizienzen, zur Verbesserung der Terminplanung und letztlich zur Unterstützung einer zeitnahen und kosteneffizienten Instandhaltungsplanung und -steuerung für Züge.

Univ.-Prof. Ing. Mag. Dr. Herwig Winkler
M.Sc. Mubashir Hayat
M.Sc. Moritz Rüster

Lehrstuhlinhaber:



Univ.-Prof. Ing. Mag. Dr.
Herwig Winkler

✉ Winkler@b-tu.de
☎ +49 (0) 355 69 4120

Projektansprechpartner:



Wissenschaftliche Mitarbeiterin
M.Sc. Mubashir Hayat

✉ Mubashir.Hayat@b-tu.de
☎ +49 (0) 355 69 4083



Wissenschaftlicher Mitarbeiter
M.Sc. Moritz Rüster

✉ Moritz.Ruester(at)b-tu.de
☎ +49 (0) 355 69 4082

Besucheranschrift:

📍 BTU Cottbus-Senftenberg
Lehrstuhl für Produktionswirtschaft
Forschungszentrum 3H
Konrad-Wachsmann-Allee 13
03046 Cottbus

☎ +49 (0)355 69-4089
Fax +49 (0)355 69-4091
🌐 www.b-tu.de/fg-produktionswirtschaft

Zusammenfassung	9
I. Aufbau des Studienberichts	11
1. Ausgangspunkt	13
2. Forschungsfragen	15
3. Forschungsmethodik	16
II. Systematische Literaturrecherche zu KI in der Wartungsauftragsplanung und -steuerung	17
1. Suchstrategie für die Datenerhebung	18
2. Prisma-Richtlinien für die Analyse von Artikeln	19
3. Deskriptive Analyse der gesammelten Artikel	20
a) Publikationstrends in diesem Bereich	20
b) Analyse der Schlüsselwörter in diesem Bereich	21
c) Verteilung der Veröffentlichungen nach Clustern	26
d) Intensität der Schlüsselwörter in diesem Bereich	27
e) Trends im Anwendungsbereich	28
4. Inhaltsanalyse der schließlich ausgewählten Artikel	30
a) Verteilung nach Wartungsstrategien	30
b) Analyse auf Basis identifizierter Cluster	32
c) Analyse nach öffentlichen Verkehrssektoren	35
5. Erkenntnisse aus der systematischen Literaturrecherche	42
III. Konzeptioneller Rahmen für KI in der Planung und Steuerung von Instandhaltungsaufträgen	43
1. Grundlegende Komponenten der KI-basierten Wartungsauftragsplanung und -steuerung	46
2. KI-MOPC-Architektur für den Schieneninstandhaltungsworkshop	48

3.	Konzeptionelles Modell von AI-MOPC für die Eisenbahninstandhaltungswerkstatt	50
4.	Erkenntnisse aus dem konzeptionellen Rahmen	52
IV.	Verstärkendes Lernen in der Wartungsauftragsplanung und -steuerung	54
1.	Suchstrategie für die Datenerfassung	56
2.	Deskriptive Analyse der gesammelten Artikel	57
a)	Publikationstrends in diesem Bereich	57
b)	Analyse auf Grundlage der identifizierten Cluster	58
4.	In diesem Forschungsbereich verwendete Modelle des verstärkenden Lernens	62
5.	Konzeptioneller Rahmen für verstärktes Lernen in der Wartungsauftragsplanung und -steuerung	63
a)	Hauptfunktionen von Wartungsauftragsplanung und -steuerung	64
b)	Komponenten des verstärkenden Lernens	66
c)	Implementierungsüberlegungen zur Umsetzung	67
d)	Verstärkender Lern-Feedback-Loop	68
6.	Erkenntnisse aus dem verstärkenden Lernen in der Wartungsauftragsplanung und -steuerung	69
V.	Schlussfolgerung und Ausblick	70
	Literaturverzeichnis	74
	Weitere Studienberichte des Lehrstuhls für Produktionswirtschaft	83

AI / KI	Künstliche Intelligenz
ANN	Künstliche neuronale Netze
BM	Bayesianische Modelle
CNN	Convolutional Neural Networks
DF	Datenfusion
DL	Deep Learning / Mehrschichtiges Lernen
DPG	Policy Gradient-Algorithmus
DRL	Deep Reinforcement Learning
DT	Entscheidungsbäume
EML	Ensemble-Maschinelles Lernen
LSTM	Langzeit-Kurzzeitgedächtnis
MDP	Markovscher Entscheidungsprozess
ML	Maschinelles Lernen
MOPC	Wartungsauftragsplanung und –steuerung
MILP	Gemischt-ganzzahlige lineare Programmierung
RL	Verbleibende Nutzungsdauer
RUL	Restnutzungsdauer
SVM	Support-Vektor-Maschine

Zweck: Die Instandhaltung von öffentlichen Verkehrsmitteln wie Zügen, Bussen und Flugzeugen spielt eine entscheidende Rolle für deren Verfügbarkeit, Sicherheit und Wirtschaftlichkeit. Eine effektive Planung und Steuerung von Instandhaltungsaufträgen reduziert nicht nur Betriebsstörungen in diesen öffentlichen Verkehrssystemen, sondern optimiert auch die Ressourcenzuweisung und minimiert die Gesamtkosten. Angesichts der zunehmenden Komplexität der heutigen öffentlichen Verkehrsnetze besteht jedoch ein wachsender Bedarf an fortschrittlichen, datengesteuerten Instandhaltungsansätzen. In diesem Zusammenhang hat sich künstliche Intelligenz (KI) als leistungsstarke Technologie für die Wartungsplanung und -steuerung etabliert. Der Hauptzweck dieser Studie ist es, den aktuellen Stand der Technik und konzeptionelle Überlegungen für die KI-basierte Wartungsauftragsplanung und -steuerung (AI-MOPC) für Wartungswerkstätten im öffentlichen Verkehr vorzustellen.



Methodik: In dieser Studie werden bestehende Forschungsarbeiten zu KI-Ansätzen für die Wartungsplanung und -steuerung im öffentlichen Verkehr systematisch überprüft und untersucht. Es wird eine deskriptive Analyse durchgeführt, um neue Forschungstrends aufzuzeigen, während eine detaillierte Inhaltsanalyse die Ergebnisse der relevantesten Artikel in diesem Forschungsbereich zusammenfasst. Auf der Grundlage der Erkenntnisse aus der Überprüfung wurde ein konzeptioneller Rahmen für AI-MOPC vorgeschlagen, der die Planung und Steuerung von Wartungsaufträgen in Werkstätten für den öffentlichen Verkehr verbessern soll. Das vorgeschlagene AI-MOPC ist in vier Schichten gegliedert: Datenmodelle, KI-Algorithmen, Entscheidungsmodule sowie Integration und Benutzeroberfläche. Der Rahmen bietet eine umfassende Wartungsplanung und -steuerung in der Werkstatt, indem er nicht nur potenzielle Ausfälle prognostiziert, sondern auch die Ressourcenzuweisung und die Ausführungsreihenfolge dynamisch an den tatsächlichen Status der Werkstatt anpasst.



Ergebnisse: Die Analyseergebnisse zeigen, dass sich die meisten Forschungsarbeiten isoliert auf bestimmte Aspekte wie die Vorhersage der verbleibenden Nutzungsdauer und die Fehlerdiagnose konzentrieren. In der Praxis erfordert die Wartungsplanung und -steuerung jedoch eine komplexe Koordination vieler Aktivitäten, z. B. Inspektion, Ressourcenzuweisung und Personal- und Aufgabenplanung usw. Daher sind die Autoren der Ansicht, dass noch ganzheitlichere Lösungen erforderlich sind, die Wartungsaktivitäten und Fertigungsbeschränkungen integrieren und über Einzelkomponentenprognosen hinaus zu einer Wartungsoptimierung auf Systemebene führen, die in realen Wartungseinrichtungen validiert werden kann. In diesem Zusammenhang wird in dieser Studie ein Rahmenkonzept für AI-MOPC vorgestellt, das als Grundmodell für den Einsatz von KI-Technologien zur Reduzierung von Ineffizienzen, zur Verbesserung der Planung und letztlich zur Unterstützung einer zeitnahen und kosteneffizienten Planung und Steuerung von Wartungsaufträgen im öffentlichen Verkehr, d. h. im Eisenbahn-, Luftfahrt- und Automobilbereich, dient.



Quelle: Pixbay.com



Ausgangssituation

Bislang wurden planungsintensive Prozesse in der Instandhaltung des öffentlichen Nahverkehrs mit herkömmlichen Planungssystemen durchgeführt. Der Planungsprozess ist komplex und zeitaufwendig. Daher sind die Ergebnisse aus wirtschaftlicher Sicht teilweise unbefriedigend, d. h. höhere Kosten, längere Vorlaufzeiten und eine geringere Anlageneffizienz.




Projektziele

1. Erstellung eines geeigneten Datenmodells auf Basis der Testvorschriften und stochastischer Ergebnisse. **2.** Entwicklung von KI-Algorithmen für die Grobplanung von Instandhaltungsarbeiten. **3.** Ein weiterer KI-Ansatz soll zur Unterstützung der konkreten Anlagensteuerung in der Fertigung eingesetzt werden.



Erwartete Ergebnisse

Datenmodelle, verschiedene KI-basierte Algorithmen für die hierarchische Planung und Steuerung sowie ein konkretes Anwendungsbeispiel zur Demonstration der Nutzung von Daten in der Instandhaltung des öffentlichen Nahverkehrs. Implementierung und Testergebnisse der Arbeiten in der Instandhaltungswerkstatt der Deutschen Bahn in Cottbus.




Quelle: Pixbay.com

Zusammenfassung	9
I. Aufbau des Studienberichts	11
1. Ausgangspunkt	13
2. Forschungsfragen	15
3. Forschungsmethodik	16
II. Systematische Literaturrecherche zu KI in der Wartungsauftragsplanung und -steuerung	17
1. Suchstrategie für die Datenerhebung	18
2. Prisma-Richtlinien für die Analyse von Artikeln	19
3. Deskriptive Analyse der gesammelten Artikel	20
a) Publikationstrends in diesem Bereich	20
b) Analyse der Schlüsselwörter in diesem Bereich	21
c) Verteilung der Veröffentlichungen nach Clustern	26
d) Intensität der Schlüsselwörter in diesem Bereich	27
e) Trends im Anwendungsbereich	28
4. Inhaltsanalyse der schließlich ausgewählten Artikel	30
a) Verteilung nach Wartungsstrategien	30
b) Analyse auf Basis identifizierter Cluster	32
c) Analyse nach öffentlichen Verkehrssektoren	35
5. Erkenntnisse aus der systematischen Literaturrecherche	42
III. Konzeptioneller Rahmen für KI in der Planung und Steuerung von Instandhaltungsaufträgen	43
1. Grundlegende Komponenten der KI-basierten Wartungsauftragsplanung und -steuerung	46
2. KI-MOPC-Architektur für den Schieneninstandhaltungsworkshop	48

Ausgangspunkt und Forschungsfragen

Behandelte Fragen



Forschungsfrage 1:
Wie ist der aktuelle Stand der künstlichen Intelligenz in der Wartungsauftragsplanung und -steuerung im öffentlichen Verkehr?

Forschungsfrage 2:
Wie können Wartungsaufträge in Wartungswerkstätten des öffentlichen Nahverkehrs mithilfe von KI geplant und gesteuert werden?

Ausgangspunkt

Die Wartungsplanung und -steuerung von öffentlichen Verkehrssystemen (z. B. Züge, Busse, Flugzeuge) ist eines der wichtigsten Elemente des Verkehrsmanagements, da sie die Wartungsaktivitäten mit den betrieblichen Zielen in Einklang bringt. Daher sind Wartungsmanager ständig auf der Suche nach besseren Entscheidungshilfetools, um optimierte Wartungsprogramme zu gewährleisten und damit ungeplante Arbeiten während der Wartungsdurchführung in der Werkstatt zu reduzieren. Bislang fehlen Wartungsorganisationen häufig Tools und Entscheidungshilfemodelle, die sie bei einer effektiven und effizienten Entscheidungsfindung unterstützen (Bukhsh et al. 2019). Eine Studie zeigt, dass ineffektive Wartungsstrategien die Produktionskapazität um 5 bis 20 % verringern können, während ungeplante Ausfallzeiten Unternehmen jährlich etwa 50 Milliarden US-Dollar kosten (Coleman und Deuel 2017).

Da öffentliche Verkehrsnetze immer komplexer werden, besteht zudem ein wachsender Bedarf an fortschrittlichen, datengesteuerten Instandhaltungsansätzen. Um diesen Herausforderungen zu begegnen, hat sich KI als leistungsstarkes Werkzeug für das Instandhaltungsmanagement etabliert. Die häufigste Aufgabe von KI in diesem Bereich ist die Vorhersage, gefolgt von der Bewertung des aktuellen Systemzustands und der Zuweisung von Ressourcen, einschließlich der Terminierung und Planung (Jevinger und Persson, 2024). Es gibt umfangreiche Literatur zum Einsatz von KI-Techniken für die Instandhaltung im öffentlichen Verkehr. Einige relevante Veröffentlichungen sind im Folgenden aufgeführt:



Eisenbahnsektor

- Maschinelle Lernmodelle und Multi-Agenten-Systeme wurden eingesetzt, um die Wartungsgenauigkeit und -effizienz im Eisenbahnsektor zu verbessern (Putra et al. 2021; Rokhforoz und Fink 2021).
- Eine der Studien beschreibt einen Big-Data-Analytics-Ansatz zur proaktiven Optimierung der Wartung von Schienenfahrzeugen (Albakay, Hempel und Sharif 2019). Darüber hinaus wurden Modelle entwickelt, um die Wartungsstrategien für Schienenfahrzeuge durch Data Mining zu verbessern (Prabhakaran et al. 2022).
- Andere Studien haben verschiedene KI- und ML-Ansätze (z. B. künstliche neuronale Netze, Support-Vektor-Maschinen, lineare Regression usw.) untersucht, um die Fehlerdiagnose im öffentlichen Verkehr zu verbessern (Demidova 2020; Giobergia et al. 2018a; Davari et al. 2021).



Luftfahrtsektor

- Eine Kombination aus CNN und LSTM-Netzwerken wurde verwendet, um die Restlebensdauer (RUL) von Flugzeugtriebwerken vorherzusagen (Hermawan et al. 2020).
- In ähnlicher Weise wurde ein multikriterieller genetischer Algorithmus entwickelt, um das Lebenszyklusmanagement von Flugzeugkomponenten zu optimieren (Kabashkin und Susanin 2024). Ihre Fallstudien zu mechanischen, avionischen und Triebwerksteilen zeigen erhebliche Kosteneinsparungen durch Optimierung, wobei optimierte Zeitpläne dynamisch an den Zustand der Komponenten angepasst werden.
- In ähnlicher Weise zeigten Lee und Mitici (2023), dass ein DRL-Ansatz den Wartungszeitpunkt durch die Verwendung von RUL-Vorhersagen optimieren kann, wodurch ungeplante Ausfallzeiten reduziert und die Wartungseffizienz verbessert werden.


Quelle: Bukhsh et al. (2019), Coleman und Deuel (2017), Jevinger und Persson (2024), Putra et al. (2021), Rokhforoz und Fink (2021), Albakay et al. (2019), Prabhakaran et al. (2022), Demidova (2020); Giobergia et al. (2018a); Davari et al. (2021), Hermawan, et. al (2020), Kabashkin und Susanin (2024), Lee und Mitici (2023)

Ausgangspunkt



Automobilbranche

- Fortschrittliche DL-Techniken wie kombinierte LSTM-Netzwerke und Zeitreihenanalysen haben sich als besonders effektiv für die Vorhersage der RUL von Automobilsystemen erwiesen (Chen et al. 2021; Giordano et al. 2022).
- Chen et al. (2021) verwendeten DL-Methoden wie CNN/LSTM, um durch die Analyse von Betriebsrouten und Umgebungsbedingungen erfolgreich vorherzusagen, wann und wo Fahrzeugwartungen erforderlich sind, und ermöglichten so zeitnahe, standortbezogene Wartungsmaßnahmen für Fahrzeugflotten.
- Darüber hinaus gehen bestimmte Veröffentlichungen über traditionelle Wartungsthemen hinaus, wie beispielsweise die Anwendung von KI für die Überwachung des Batteriezustands in Fahrzeugen (H. Liu, Song und Zhang 2021) oder die Verbesserung der Cybersicherheit von Fahrzeugen (Kavousi-Fard et al. 2020a).



Andere Branchen

Über den öffentlichen Verkehr hinaus wurden verschiedene KI-Modelle auch in der allgemeinen Instandhaltung eingesetzt.

- Eine Studie im Produktionsbereich zeigt beispielsweise die hervorragende Leistungsfähigkeit von ML-basierten Algorithmen zur Zustandsvorhersage und -planung, die herkömmliche Wartungsstrategien übertreffen (Wesendrup und Hellingrath, 2023).
- Wartungsentscheidungen können effizienter getroffen werden, indem Aufgaben auf der Grundlage des tatsächlichen Zustands der Windkraftanlagen in Echtzeit mithilfe dynamischer Modellierungstechniken wie Q-Learning geplant werden (Rasay et al. 2024).
- Eine Fallstudie hat gezeigt, dass RL eine effektive Methode für die Wartungsplanung ist, selbst wenn nur begrenzte Lebenszyklusdaten verfügbar sind (Y. Liu, Yang und Guo 2022).

Es gibt zwar umfangreiche Literatur zum Einsatz von KI-Techniken für die Instandhaltung im öffentlichen Verkehr. Die meisten bisherigen Forschungsarbeiten sind jedoch sehr spezifisch und konzentrieren sich isoliert auf bestimmte Aspekte der Instandhaltung, wie z. B. die Vorhersage der Restlebensdauer (RUL), die Fehlerdiagnose und Entscheidungshilfesysteme für Reparatur und Austausch. In der Praxis umfasst die Wartungsplanung und -steuerung jedoch die komplexe Koordination vieler Aktivitäten, z. B. Inspektion, Ermittlung der erforderlichen Materialien und Komponenten, Zuweisung von Ressourcen und Planung des Personals und der Aufgaben. Es gibt noch keine Forschungsarbeiten, die sich mit einem speziellen KI-basierten Wartungsplanungs- und -steuerungssystem befassen. Daher besteht ein Bedarf an ganzheitlicheren Lösungen, die Wartungsaktivitäten und Fertigungsbeschränkungen integrieren und über die Vorhersage einzelner Komponenten hinaus zur Optimierung der Wartung auf Systemebene führen.

Quelle: Chen et al. (2021), H. Liu, Song und Zhang (2021), Kavousi-Fard et al. (2020a), Wesendrup und Hellingrath (2023), Rasay et al. (2024), Y. Liu, Yang und Guo (2022)

Forschungsfragen

Obwohl eine Vielzahl von Forschungsarbeiten verfügbar ist, gibt es jedoch keine systematische Studie, die sich speziell mit dem Einsatz von KI-Methoden für die Wartungsplanung und -steuerung im öffentlichen Verkehr befasst. Um diese Lücke zu schließen, führt diese Studie eine systematische Literaturrecherche durch, um die folgende Forschungsfrage zu beantworten: **Wie ist der aktuelle Stand der künstlichen Intelligenz in der Wartungsauftragsplanung und -steuerung im öffentlichen Verkehr?** Ziel ist es, den aktuellen Forschungsstand zusammenzufassen, Trends und Lücken zu identifizieren und damit einen Beitrag zu zukünftigen Forschungsarbeiten zu leisten, die die Effizienz von Instandhaltungsstrategien für Verkehrssysteme verbessern könnten.

Darüber hinaus gibt es noch keine Forschungsarbeiten, die sich mit einem speziellen KI-basierten System für die Wartungsplanung und -steuerung befassen. Daher besteht ein Bedarf an ganzheitlicheren Lösungen, die Wartungsaktivitäten und betriebliche Einschränkungen integrieren und über die Vorhersage einzelner Komponenten hinaus zur Optimierung der Wartung auf Systemebene führen. Ein KI-basiertes System zur Planung und Steuerung von Wartungsaufträgen könnte Wartungsmanager bei der End-to-End-Planung unterstützen, von der Ermittlung des Wartungsbedarfs bis zur Terminierung und Ausführung, und könnte in realen Zugwartungsanlagen validiert werden. In diesem Zusammenhang präsentiert diese Studie einen neuartigen, KI-basierten konzeptionellen Rahmen und liefert einen Fahrplan zur Beantwortung der folgenden Forschungsfrage: **Wie können Wartungsaufträge in Zugwartungswerkstätten mithilfe von KI geplant und gesteuert werden?**



Forschungsmethodik

Dieser Studienbericht gliedert sich in zwei Hauptphasen, nämlich eine systematische Literaturrecherche (SLR) und die Erstellung konzeptioneller Rahmenwerke.

Phase 1. Systematische Literaturrecherche (SLR): Die SLR wird durchgeführt, um den Status quo darzustellen, wichtige Forschungslücken zu identifizieren und die Forschungsziele im Zusammenhang mit künstlicher Intelligenz in der Wartungsplanung und -steuerung im öffentlichen Verkehrssektor zu definieren. Bei der SLR werden die Richtlinien der Preferred Reporting Items for Systematic Reviews and Meta-Analyses (PRISMA) für die Sammlung und Analyse von Artikeln befolgt. PRISMA ist eine weit verbreitete Methode zur Durchführung von SLR in verschiedenen Bereichen (David et al. 2023).

- Die SLR wird anhand von Publikationen aus den Datenbanken Web of Science (WoS) und Science Direct durchgeführt. Die Artikel durchlaufen einen ersten Screening-Prozess auf der Grundlage von Einschluss- und Ausschlusskriterien, um ihre Relevanz für die KI-gesteuerte Instandhaltung im öffentlichen Verkehrssektor sicherzustellen. Die ausgewählten Studien werden anschließend einer detaillierten Analyse unterzogen, um Erkenntnisse über KI-Modelle zu gewinnen, die in der Instandhaltungsplanung und -steuerung im öffentlichen Verkehr eingesetzt werden.
- Nach der Sammlung und Analyse der Literatur wurden Balkendiagramme und die Software-Tools VOSviewer verwendet, um die Daten zu visualisieren und die Forschungsergebnisse effektiv zu präsentieren. Die Verwendung von Balkendiagrammen ermöglicht eine klare Darstellung der Publikationstrends und zeigt das Wachstum und die Entwicklung der Forschung im Bereich der KI-gesteuerten Instandhaltung im Laufe der Zeit. VOSviewer wurde hingegen aufgrund seiner benutzerfreundlichen Kartierung und visuell ansprechenden Grafiken für die erweiterte bibliometrische Analyse eingesetzt (Van Eck und Waltman 2010). Insbesondere wurde VOSviewer für die Analyse von Stichwortnetzwerken, die Analyse der Stichwortdichte und die Visualisierung von Stichwortüberlagerungen verwendet.

Phase 2. Konzeptioneller Rahmen: Auf der Grundlage der Erkenntnisse aus der SLR wird anschließend ein konzeptioneller Rahmen entwickelt, um ein KI-basiertes Modell für die Wartungsauftragsplanung und -steuerung (AI-MOPC) vorzuschlagen. Der konzeptionelle Rahmen ist in drei Abschnitte gegliedert:

- Grundlegende Komponenten von AI-MOPC: Hier werden die grundlegenden Elemente beschrieben, die für die Integration von KI in die Wartungsplanung erforderlich sind. Der Rahmen besteht aus mehreren Schlüsselkomponenten, d. h. Datenmodellen, KI-Algorithmen, Entscheidungsmodellen und der Integration in bestehende Informationssysteme und Benutzeroberflächen.
- Konzeptionelles Modell von AI-MOPC: Es wird ein theoretisches Modell vorgeschlagen, um den Arbeitsablauf und die Entscheidungsstruktur von AI-MOPC zu definieren.
- Verstärkendes Lernen in MOPC: Untersucht die Rolle der Technik des verstärkenden Lernens bei der Optimierung der Wartungsauftragsplanung und Entscheidungsfindung.

Quelle: David et al. (2023), Van Eck und Waltman (2010)

Zusammenfassung	9
I. Aufbau des Studienberichts	11
1. Ausgangspunkt	13
2. Forschungsfragen	15
3. Forschungsmethodik	16
II. Systematische Literaturrecherche zu KI in der Wartungsauftragsplanung und -steuerung	17
1. Suchstrategie für die Datenerhebung	18
2. Prisma-Richtlinien für die Analyse von Artikeln	19
3. Deskriptive Analyse der gesammelten Artikel	20
a) Publikationstrends in diesem Bereich	20
b) Analyse der Schlüsselwörter in diesem Bereich	21
c) Verteilung der Veröffentlichungen nach Clustern	26
d) Intensität der Schlüsselwörter in diesem Bereich	27
e) Trends im Anwendungsbereich	28
4. Inhaltsanalyse der schließlich ausgewählten Artikel	30
a) Verteilung nach Wartungsstrategien	30
b) Analyse auf Basis identifizierter Cluster	32
c) Analyse nach öffentlichen Verkehrssektoren	35
5. Erkenntnisse aus der systematischen Literaturrecherche	42
III. Konzeptioneller Rahmen für KI in der Planung und Steuerung von Instandhaltungsaufträgen	43
1. Grundlegende Komponenten der KI-basierten Wartungsauftragsplanung und -steuerung	46
2. KI-MOPC-Architektur für den Schieneninstandhaltungsworkshop	48

Suchstrategie für die Datenerhebung

Merkmale der Suchzeichenfolge

Technologien	•Künstliche Intelligenz/KI •Maschinelles Lernen/ML
Anwendungen	•Wartungsplanung •Instandhaltungssteuerung •Wartungsplanung
Branchen	•Luftfahrt/Flugzeuge •Automobil/Fahrzeuge •Eisenbahn/Schiene

Endgültig entwickelte Suchstrings:


TS=((("Künstliche Intelligenz" ODER „KI“ ODER „Maschinelles Lernen“ ODER „ML“) UND („Wartung“) UND (Planung ODER Terminierung ODER Steuerung) UND (Luftfahrt ODER Automobil ODER Schiene ODER Fahrzeug))

Wichtigste Erkenntnisse

- Die Suchstrategie konzentrierte sich in erster Linie auf künstliche Intelligenz und Instandhaltung im öffentlichen Verkehr. Daher wurden in den Suchbegriff Schlüsselwörter zu KI-Technologien, Instandhaltungsanwendungen und spezifischen Verkehrssektoren aufgenommen.
- Die Schlüsselwörter „künstliche Intelligenz“ und „maschinelles Lernen“ wurden verwendet, um den technologischen Aspekt zu erfassen. Da maschinelles Lernen ein weit verbreiteter Bestandteil der künstlichen Intelligenz ist, wurde es ausdrücklich als technologisches Schlüsselwort in den String aufgenommen.
- Darüber hinaus ist der Begriff „Wartung“ an sich recht weit gefasst, sodass er mit spezifischen Aspekten wie Planung, Steuerung oder Terminierung kombiniert wurde, um den Anwendungskontext auf unser Thema einzugrenzen.
- Um sicherzustellen, dass alle relevanten Sektoren abgedeckt sind, wurden der Suchbegriff auch Begriffe hinzugefügt, die die Verkehrsmittel bezeichnen, d. h. Flugzeug, Fahrzeug, Bahn, zusammen mit den Namen der Sektoren.

PRISMA-Richtlinien für die Analyse von Artikeln

PRISMA-Flussdiagramm



Wichtige Erkenntnisse

Um einen transparenten und strukturierten Screening-Prozess zu gewährleisten, wurden die PRISMA-Richtlinien angewendet.

Identifizierung: Mithilfe der Suchstrategie wurden insgesamt 357 Publikationen gefunden und zur Überprüfung in Zotero importiert.


Screening und Eignung: Nach Entfernung von 19 doppelten Einträgen blieben 338 einzigartige Artikel für die erste Bewertung übrig. Diese Artikel wurden organisiert, ihre Titel und Abstracts sorgfältig geprüft und anhand ihrer Relevanz für das Thema KI-gesteuerte Wartungsplanung/-terminierung/-steuerung im öffentlichen Verkehr bewertet. Im Ergebnis wurden 182 Artikel ausgeschlossen, die keinen klaren thematischen Bezug zum Thema hatten. Damit blieben 156 Artikel übrig, die einer Volltextprüfung unterzogen wurden.

Detaillierte Analyse: Nach der Lektüre des vollständigen Inhalts der 156 Artikel wurden weitere 42 Artikel ausgeschlossen, da sie keine ausreichende thematische Relevanz aufwiesen (z. B. weil sie in ihren Zusammenfassungen oder Schlüsselwörtern zwar erwähnt wurden, aber nicht substantiell auf die Wartungsplanung/-terminierung/-steuerung eingingen). Schließlich wurden 114 Artikel als die relevantesten identifiziert und für eine detaillierte Analyse ausgewählt.

Deskriptive Analyse der gesammelten Artikel | Publikationstrends in diesem Bereich

Die deskriptive Analyse ist ein nützlicher Ansatz zur Untersuchung großer Mengen wissenschaftlicher Literatur, um Trends und Muster aufzudecken. Die erste Datenbankrecherche ergab 338 verschiedene Veröffentlichungen zum Thema KI in der Wartungsplanung und -steuerung im öffentlichen Verkehr. Daher wurden bibliometrische Analysen durchgeführt, um die allgemeinen Forschungstrends in diesem Bereich zu untersuchen und darzustellen. Bemerkenswert ist, dass der Großteil der Forschung in diesem Bereich in den letzten 10 Jahren durchgeführt wurde.

Publikationstrend



Wichtige Erkenntnisse

Verteilung der Veröffentlichungen

- Zeitschriftenartikel: 250
- Konferenzbeiträge: 85
- Buchkapitel: 3

Wichtigste Themenbereiche

- Ingenieurwesen: 184
- Informatik: 106
- Verkehrswesen: 41
- Kommunikation: 27
- Automatisierungstechnik: 25

Publikationstrend

- Der stetige Anstieg zeigt ein wachsendes Interesse und eine zunehmende Entwicklung in diesem Bereich.

Deskriptive Analyse der gesammelten Artikel | Analyse der Schlüsselwörter in diesem Bereich

Da die gesammelten Daten sehr umfangreich sind, wird für eine bessere Konstruktion und Visualisierung der bibliometrischen Netzwerke in dieser Studie eine Netzwerkvisualisierungssoftware verwendet, z. B. VOSviewer [<https://www.vosviewer.com>]. VOSviewer bietet eine Vielzahl von Visualisierungsperspektiven für bestimmte Aspekte und liefert drei unterschiedliche Sichtweisen auf die Ergebnisse, nämlich Netzwerk-, Overlay- und Dichtevisualisierungen, die sich durch eine benutzerfreundliche Darstellung und ansprechende Grafiken auszeichnen (Van Eck, Waltman, 2010). Für die gesammelten Daten haben wir eine Netzwerk-, Dichte- und Overlay-Analyse durchgeführt. Die detaillierten Ergebnisse der Analyse werden einzeln dargestellt.

Analyse mit VOSviewer**Netzwerkvisualisierung**

Die Netzwerkvisualisierung in VOSviewer zeigt die Beziehungen zwischen Elementen wie Schlüsselwörtern an. Jedes Element wird als Knoten dargestellt, und die Verbindungen zwischen ihnen werden als Linien angezeigt. Die Nähe der Knoten spiegelt die Stärke ihrer Verbindung wider: Elemente, die stark miteinander verbunden sind, erscheinen näher beieinander und umgekehrt. Die Größe eines Knotens gibt seine Häufigkeit an, und Elemente werden in der Regel zu Clustern zusammengefasst, die jeweils durch eine andere Farbe dargestellt werden. Diese Visualisierung ist besonders nützlich, um thematische Gruppierungen und strukturelle Beziehungen innerhalb eines Forschungsbereichs zu identifizieren.

Dichtevisualisierung

Die Dichtevisualisierung bietet eine andere Perspektive, indem sie sich auf die Konzentration von Elementen und deren Verbindungen konzentriert. Anstelle der Darstellung einzelner Verbindungen wird ein Bild im Stil einer Heatmap angezeigt, in dem Bereiche mit einer hohen Dichte an Elementen oder starken Verbindungen in wärmeren Farben wie Gelb oder Rot und Bereiche mit geringerer Dichte in kühleren Farben wie Grün oder Blau dargestellt werden. Auf diese Weise lässt sich schnell erkennen, welche Themen oder Entitäten im Datensatz die größte Aufmerksamkeit erhalten. Dies ist besonders nützlich, um Hotspots der Forschungsaktivität zu erkennen oder ein intuitives Gefühl dafür zu bekommen, wo sich der wissenschaftliche Schwerpunkt konzentriert.

Überlagerungsvisualisierung


Die Überlagerungsvisualisierung erweitert die Netzwerkvisualisierung um eine zeitliche oder wirkungsbezogene Dimension der Elemente. In diesem Modus werden die Knoten anhand eines Attributs, beispielsweise dem durchschnittlichen Erscheinungsjahr, farblich gekennzeichnet. Diese Art der Visualisierung hilft dabei, aufkommende Trends, aktuelle Entwicklungen oder einflussreiche Werke innerhalb eines Fachgebiets zu identifizieren. Die relationale Struktur der Netzwerkansicht bleibt erhalten, wird jedoch um Informationen darüber erweitert, wie sich das Fachgebiet verändert hat oder welche Elemente eine größere Bedeutung haben.

b.tu



Deskriptive Analyse der gesammelten Artikel | Analyse der Schlüsselwörter in diesem Bereich

Verteilung von Schlüsselwörtern basierend auf Clustern



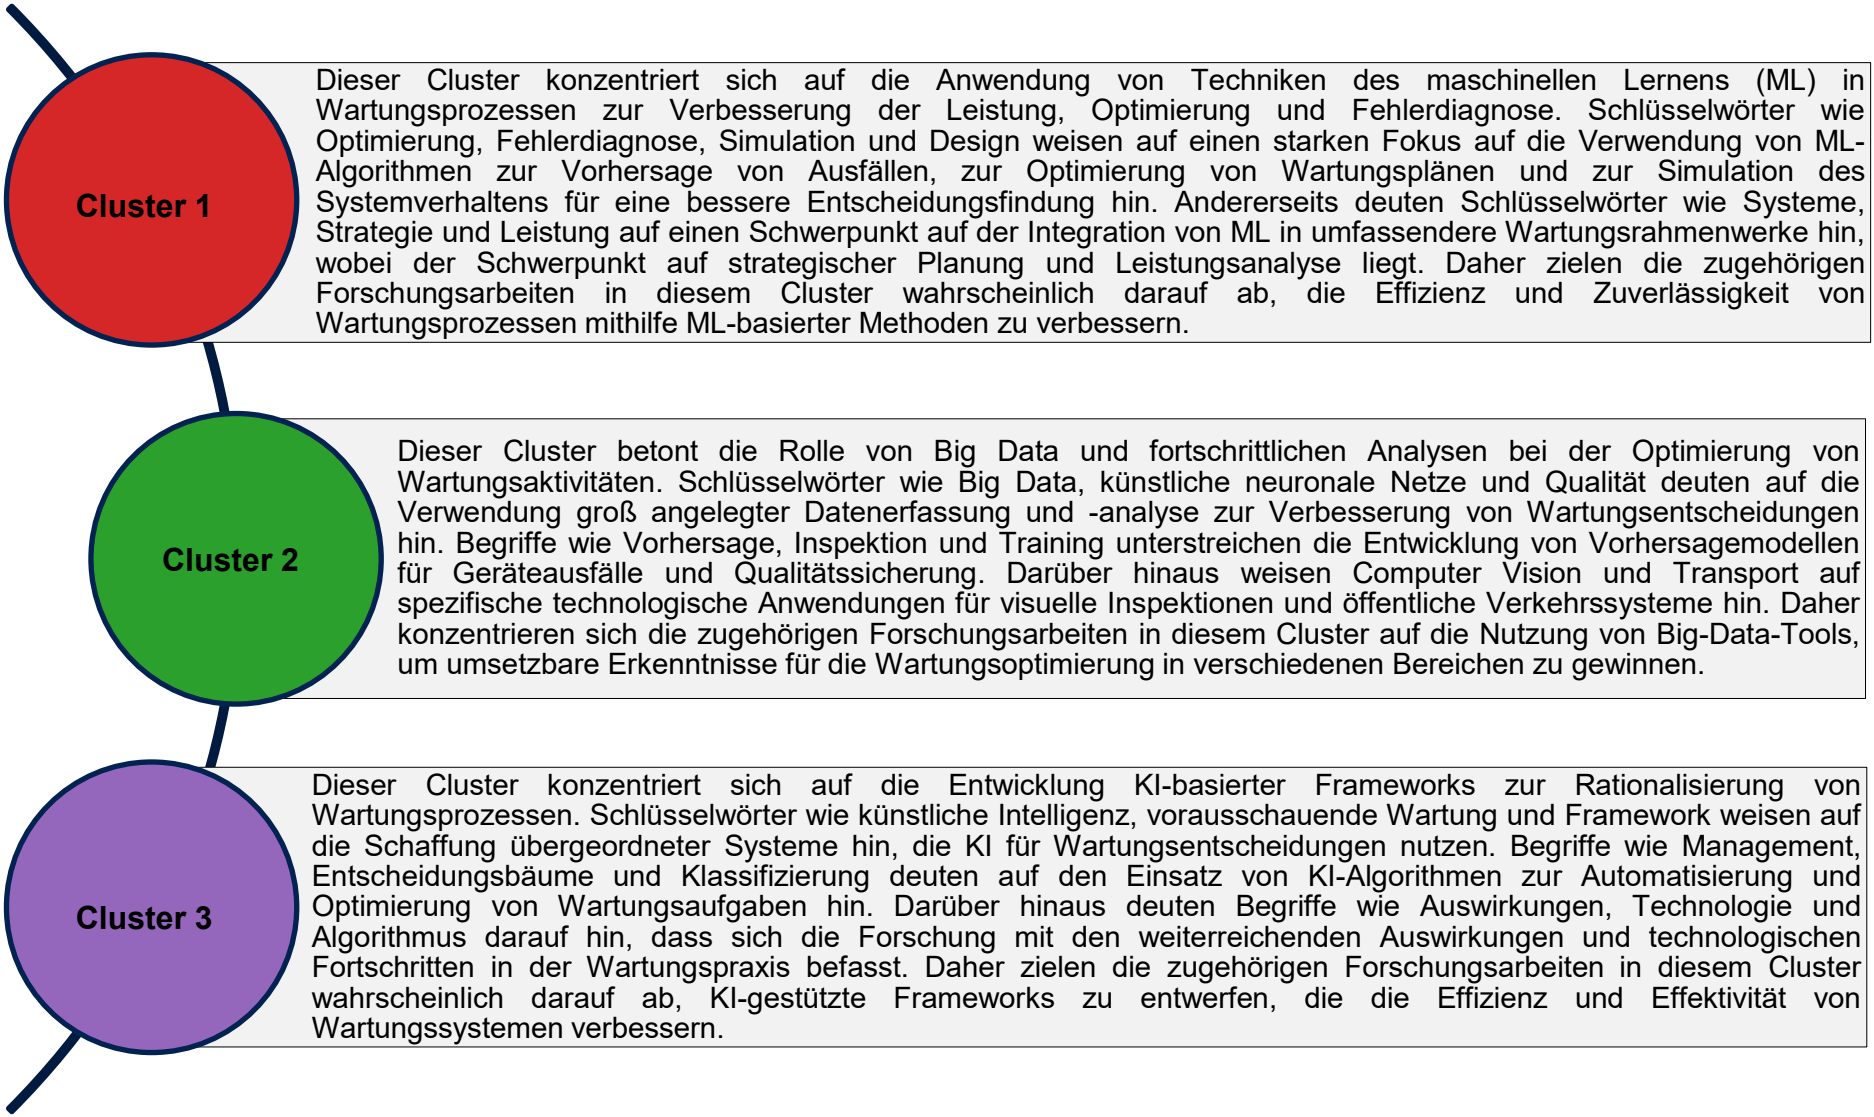
Cluster-Name

Cluster 1: Maschinelles Lernen für die Wartung
 Cluster 2: Big-Data-Analyse für die Wartungsoptimierung
 Cluster 3: Deep Learning in der vorausschauenden Wartung
 Cluster 4: Digitale Zwillinge und Datenanalyse in der Wartung
 Cluster 5: Künstliche Intelligenz-basierte Frameworks für die Instandhaltung
 Cluster 6: Verstärkendes Lernen in der Instandhaltung

Erkenntnisse aus der Inhaltsanalyse

- Das gemeinsame Vorkommen von Schlüsselwörtern in den ausgewählten 338 Artikeln wurde untersucht.
- Es wurde ein Kriterium festgelegt, um nur Schlüsselwörter mit einer Häufigkeit von ≥ 4 auszuwählen. Durch dieses Kriterium wurden 75 der 2025 Schlüsselwörter mit der festgelegten Häufigkeitsschwelle gefunden.
- **Am häufigsten gemeinsam auftretende Schlüsselwörter:**
 - Maschinelles Lernen – Vorkommen: 76, Gesamtlinkstärke: 180
 - Künstliche Intelligenz – Vorkommen: 44, Gesamtlinkstärke: 125
 - Wartung – Vorkommen: 34, Gesamtlinkstärke: 104
- Die Ergebnisse zeigen außerdem, dass vorausschauende Wartung, Deep Learning und Optimierungen mit 38, 22 bzw. 17 Vorkommen die häufigsten Schlüsselwörter sind, die zusammen mit unserem Hauptsuchbegriff auftreten.

Deskriptive Analyse der gesammelten Artikel | Analyse der Schlüsselwörter in diesem Bereich



Deskriptive Analyse der gesammelten Artikel | Analyse der Schlüsselwörter in diesem Bereich

Cluster 4

Dieser Cluster untersucht die Implementierung von Deep-Learning-Techniken (DL) in der vorausschauenden Instandhaltung. Schlüsselwörter wie neuronale Netze, Zustandsüberwachung und Anomalieerkennung verdeutlichen den Einsatz von DL-Algorithmen zur Erkennung von Mustern und Anomalien im Systemverhalten, wodurch eine frühzeitige Fehlererkennung ermöglicht wird. Schlüsselwörter wie Zeitreihen, Fehlererkennung und UAV deuten auf die Anwendung von DL bei der Verarbeitung komplexer Datentypen (z. B. Zeitreihendaten) zur Identifizierung von Fehlern und zur Überwachung von Remote-Systemen wie unbemannten Luftfahrzeugen (UAVs) hin. Daher konzentrieren sich die zugehörigen Forschungsarbeiten in diesem Cluster wahrscheinlich auf die Nutzung der Fähigkeiten von DL zur Verbesserung der Genauigkeit und Zuverlässigkeit der vorausschauenden Wartung.

Cluster 5

Dieser Cluster konzentriert sich auf die Integration von digitalen Zwillingen (DTs) und Datenanalyse für Wartungszwecke. Schlüsselwörter wie digitaler Zwilling, Datenanalyse und Sensoren deuten auf einen Schwerpunkt bei der Erstellung virtueller Modelle physischer Systeme zur Simulation, Überwachung und Analyse von Echtzeit-Betriebsdaten hin. Darüber hinaus weisen Begriffe wie Zuverlässigkeit, Prognosen und Sicherheit auf einen Schwerpunkt bei der Gewährleistung der Zuverlässigkeit und Sicherheit von Systemen durch prädiktive Analysen hin. Schlüsselwörter wie Herausforderungen und Nachhaltigkeit deuten darauf hin, dass umfassendere Themen wie die Einführung digitaler Zwillinge in verschiedenen Wartungskontexten behandelt werden. Daher zielen die zugehörigen Forschungsarbeiten in diesem Cluster wahrscheinlich darauf ab, Wartungspraktiken durch virtuelle Modellierung und datengestützte Erkenntnisse zu verbessern.


Cluster 6

Dieser Cluster betont den Einsatz von Techniken des verstärkenden Lernens (RL) für die Wartung, insbesondere für die zustandsorientierte Wartung. Schlüsselwörter wie „verstärkendes Lernen“, „tiefes verstärkendes Lernen“ und „Zustandsüberwachung“ deuten auf die Anwendung von RL-Algorithmen hin, um optimale Wartungsstrategien auf der Grundlage des Systemzustands zu erlernen. Andere Begriffe wie Methodik, Luftfahrt und IoT deuten auf Anwendungen in bestimmten Bereichen wie der Luftfahrt und IoT-fähigen Systemen hin. Die Einbeziehung von Industrie 4.0 spiegelt die Ausrichtung dieser Forschung auf fortschrittliche Fertigungs- und Wartungsparadigmen wider. Daher konzentrieren sich die zugehörigen Forschungsarbeiten in diesem Cluster wahrscheinlich auf den Einsatz von RL zur dynamischen Anpassung von Wartungsstrategien an Echtzeit-Systemzustände.

Deskriptive Analyse der gesammelten Artikel | Verteilung der Veröffentlichungen nach Clustern

Veröffentlichungen nach Clustern

- Maschinelles Lernen für die Instandhaltung
- Big-Data-Analyse zur Optimierung der Wartung
- KI-basierte Frameworks für die Wartung
- Deep Learning in der vorausschauenden Wartung
- Digitale Zwillinge und Datenanalyse in der Instandhaltung
- Verstärkendes Lernen für die Instandhaltung
- Überlappende Cluster



Weitere Einblicke

Meistzitierte Artikel:

- Zhu, Li, et al. (2018): **1183**
- Kumar, M, et al. (2017): **260**
- Tang, Ruifan, et al. (2022): **200**
- Filz, André, et al. (2021): **114**
- Sui, Zezhi, et al. (2020): **114**
- Zhai, Simon, et al. (2021): **91**

Top-Forscher:

- Flammini, Francesco: **4**
- Meisch, Richard: **4**
- Vittorini, Valeria: **3**
- Baralis, Elena: **3**
- Mellia, Marco: **3**


Flammini, Francesco:

- Links: **9**
- Gesamtlinkstärke: **19**

Quelle: Zhu, Li, et al. (2018); Kumar, M, et al. (2017), Tang, Ruifan, et al. (2022), Filz, André, et al. (2021), Sui, Zezhi, et al. (2020), Zhai, Simon, et al. (2021)

Deskriptive Analyse der gesammelten Artikel | Intensität der Schlüsselwörter in diesem Bereich

Dichte der Schlüsselwörter



Wichtige Erkenntnisse

- Die Intensität der Farben zeigt die Konzentration und Bedeutung bestimmter Begriffe, wobei Rot und Gelb eine höhere Dichte an Schlüsselwörtern anzeigen.
- Vorausschauende Wartung und Deep Learning weisen nach den Hauptthemen künstliche Intelligenz, maschinelles Lernen und Wartung die höchste Dichte auf. Daher können diese als die wichtigsten Themen innerhalb des Forschungsbereichs angesehen werden.
- RL und DRL weisen zwar eine relativ geringe Dichte auf, dies bedeutet jedoch nicht, dass sie in diesem Bereich unbedeutend sind. Die Inhaltsanalyse zeigt, dass die meisten Artikel in diesem Bereich trotz der geringeren Keyword-Dichte ebenfalls substantiell sind. Die geringere Dichte ist in erster Linie darauf zurückzuführen, dass in den meisten Artikeln spezifische algorithmische Begriffe wie Q-Learning, Deep Q-Learning usw. anstelle von allgemeineren Kategorienamen verwendet werden.

Wichtige Erkenntnisse

2020–2021:


- Algorithmen der künstlichen Intelligenz in der Instandhaltung mit speziellem Fokus auf Fehlerdiagnose, Steuerung/ autonome Systeme usw.

2022–2023:

- Maschinelle Lernmodelle, insbesondere Deep Learning, Reinforcement Learning/Deep Reinforcement Learning in der vorausschauenden Instandhaltung.

2023 und darüber hinaus:

- Integration des Internets der Dinge für Datenanalyse und Leistungsstatus. Nachhaltigkeit und Zuverlässigkeit sind ebenfalls Schwerpunktthemen.



Deskriptive Analyse der gesammelten Artikel | Trends im Anwendungsbereich

Von 2020 bis 2021 lag der Forschungsschwerpunkt auf der Anwendung von KI-Algorithmen in der Instandhaltung, mit besonderem Fokus auf Fehlerdiagnose und autonomen Instandhaltungssystemen. In diesem Zeitraum konnten traditionelle KI-Techniken wie Expertensysteme und einfache Klassifikatoren zur Erkennung von Gerätefehlern und zur Unterstützung von Instandhaltungsentscheidungen eingesetzt werden. Es bestand auch Interesse an der Verwendung von KI für Steuerungssysteme im Zusammenhang mit Instandhaltungsvorgängen, wodurch die Grundlage für autonomere Instandhaltungsprozesse geschaffen wurde.

In den Jahren 2022 und 2023 verlagerte sich der Schwerpunkt deutlicher auf maschinelle Lernmodelle, insbesondere auf fortschrittliche Methoden wie Deep Learning und Reinforcement Learning, im Zusammenhang mit der vorausschauenden Instandhaltung. In diesem Zeitraum wurden angewandte tiefe neuronale Netze wie tiefe Faltungsneuronale Netze und rekurrenten neuronalen Netze usw. eingesetzt, um Ausfälle besser vorherzusagen und die verbleibende Lebensdauer von Komponenten abzuschätzen. Gleichzeitig wurde Reinforcement Learning zur Optimierung der Wartungsplanung und Ressourcenzuweisung eingesetzt, wobei die Wartungsplanung als sequentiell Entscheidungsproblem behandelt wurde. Die Literatur aus dieser Zeit spiegelt eine Zunahme datengesteuerter vorausschauender Wartungsansätze wider, die die zunehmende Verfügbarkeit von Sensordaten und Rechenleistung für das Training komplexer Modelle nutzen.


Bis 2023 und darüber hinaus gibt es einen klaren Trend zur Integration von Internet-of-Things-Technologien (IoT) und groß angelegter Datenanalyse in KI-basierte Wartungssysteme. Darüber hinaus sind Nachhaltigkeit und Zuverlässigkeit zu wichtigen Faktoren geworden: In der aktuellen Forschung wird häufig diskutiert, wie KI-gesteuerte Wartung zu einem nachhaltigeren Betrieb beiträgt und eine höhere Zuverlässigkeit von Transportdienstleistungen gewährleistet. Zusammenfassend lässt sich sagen, dass die Overlay-Analyse einen Zeitrahmen aufzeigt, in dem sich frühe KI-Anwendungen in der Wartung (Fehlerdiagnose und Automatisierung) zu ausgeklügelten vorausschauenden Wartungslösungen mit Deep Learning und RL entwickelt haben und nun weiter in Richtung IoT-gestützter, nachhaltiger Wartungsstrategien voranschreiten.

Inhaltsanalyse der schließlich ausgewählten Artikel | Verteilung nach Wartungsstrategien

Artikelverteilung basierend auf den Wartungsstrategien

- Es wurde eine Inhaltsanalyse durchgeführt, um Erkenntnisse aus der endgültigen Auswahl von 114 Artikeln zusammenzufassen.
- Die Artikel wurden anhand der Art der Wartungsstrategie oder des behandelten Aspekts kategorisiert

- Wartungsplanung
- Wartungsplanung und -prognose
- Zustandsbasierte Wartung
- Vorausschauende Instandhaltung (PdM)
- Wartungssteuerung
- Wartungsentscheidungsunterstützungssystem
- Sonstige Strategien




Wichtigste Erkenntnisse

- Die Wartungsplanung ist mit 39 von 114 Artikeln der häufigste Schwerpunkt. Darauf folgen die Wartungsplanung und -prognose mit 35 Artikeln.
- Eine kleinere Anzahl von Artikeln befasste sich explizit mit Wartungssteuerungs- und Entscheidungsunterstützungssystemen, nämlich jeweils 3 Artikel pro Kategorie.
- Die zustandsorientierte Instandhaltung, die häufig Fehlerdiagnose und Echtzeit-Zustandsüberwachung umfasst, wurde in 8 Artikeln behandelt, die vorausschauende Instandhaltung in 5 Artikeln.
- Insgesamt haben die Forscher Prioritäten gesetzt, wann und welche Wartungsarbeiten durchgeführt werden sollen, d. h. sie haben den Zeitpunkt der Wartung festgelegt und ermittelt, was repariert werden muss, um ungeplante Ausfallzeiten zu reduzieren und die Wartungsarbeiten effizient zu verwalten.
- **Keiner der Artikel enthält einen speziellen Rahmen für die Planung und Steuerung von Wartungsaufträgen.**

Inhaltsanalyse der schließlich ausgewählten Artikel | Analyse auf Basis identifizierter Cluster

Verteilung der Artikel basierend auf den Wartungsstrategien




Wichtigste Erkenntnisse

- Aus der VOSviewer-Klassifizierung der Schlüsselwörter in sechs Cluster schließen wir, dass jeder Cluster ein bestimmtes Forschungsthema widerspiegelt.
- Bei der Analyse der Artikel anhand dieser Cluster stellen wir fest, dass das verstärkende Lernen mit 64 Artikeln die größte Kategorie im Forschungsbereich bildet. Dieser hohe Anteil ist auf das Auftreten sequenzieller Entscheidungsprobleme zurückzuführen, die sich gut mit verstärktem Lernen lösen lassen.
- Darüber hinaus bilden klassische ML-Algorithmen (d. h. Support-Vektor-Maschinen, Random Forests, Bayes'sche Klassifikatoren usw.) mit 29 Artikeln einen bedeutenden Anteil für Aufgaben wie Fehlerdiagnose, Vorhersage der Restlebensdauer usw. Eine Reihe von Artikeln in diesem Cluster wandten auch statistische Methoden wie genetische Algorithmen für die Terminplanung, Bayes'sche Netzwerke für die Entscheidungsunterstützung, Fuzzy-Logik für Wartungsrichtlinien usw. an.
- Vier der Artikel haben KI-Frameworks zur Optimierung der Wartung vorgestellt.
- Die übrigen überlappenden Cluster, d. h. Big-Data-Analyse für die Wartungsoptimierung, Deep Learning in der vorausschauenden Wartung, digitale Zwillinge und Datenanalyse in der Wartung, konzentrieren sich hauptsächlich auf die Datenanalyse in der vorausschauenden Wartung.

Inhaltsanalyse der schließlich ausgewählten Artikel | Analyse auf Basis identifizierter Cluster

Analyse der Dokumente auf Grundlage identifizierter Cluster

- Maschinelles Lernen für die Instandhaltung
- Big-Data-Analyse zur Wartungsoptimierung
- KI-basierte Frameworks für die Instandhaltung
- Deep Learning in der vorausschauenden Instandhaltung
- Digitale Zwillinge und Datenanalyse in der Instandhaltung
- Verstärkendes Lernen für die Instandhaltung



Wichtigste Erkenntnisse

Cluster 1: Anwendung klassischer maschineller Lernverfahren (z. B. SVM, DTs, BMs usw.) für die Fehlerdiagnose und die Vorhersage der Restlebensdauer (RUL)

Cluster 2: Verwendung von Sensordaten und MDP, ANN usw. zur Verbesserung der Entscheidungsfindung und Optimierung im Bereich Wartung.

Cluster 3: Entscheidungsunterstützungssysteme/-rahmenwerke (keine spezifischen Modelle/Algorithmen verwendet)

Cluster 4: Anwendung von ANNs, CNNs, LSTM usw. für die Fehlererkennung, RUL und Zustandsüberwachung

Cluster 5: Nutzung von Echtzeitdaten zur Diagnose von Problemen, Vorhersage von Ausfällen und Optimierung der Wartung durch Simulation (keine spezifischen Modelle/Algorithmen verwendet)

Cluster 6: Anwendung von Q-Learning, Deep Q-Learning, DPG, Monte-Carlo-Algorithmen usw. für die Planung und Steuerung von Wartungsaufgaben



Maschinelles Lernen für die Wartung

- Pebrianti et al. (2024) wenden tiefe konvolutionelle neuronale Netze auf die Flugzeugwartung an, indem sie Bild- und Sensordaten analysieren, um Komponentenausfälle vorherzusagen.
- Ferdous et al. (2024) demonstrieren eine praktische ML-Anwendung in der Eisenbahninstandhaltung, indem sie Sensordaten analysieren, um den Bedarf an Gleis- und Zugkomponenten vorherzusagen.
- Mohan et al. (2021) schlagen einen maschinellen Lernansatz innerhalb eines Rahmens für die totale produktive Instandhaltung vor, um unerwartete Ausfälle von Anlagen virtuell zu eliminieren.
- Samanta und Williamson (2023) geben einen Überblick über ML-Methoden zur Abschätzung der Restlebensdauer von Lithium-Ionen-Batterien in Elektrofahrzeugen und -geräten.



Big-Data-Analyse zur Optimierung

- Consilvio et al. (2024) stellen einen Rahmen vor, der Big Data nutzt, um Wartungsarbeiten im U-Bahn-System intelligent zu planen und zu priorisieren.
- Kabashkin (2024) schlägt einen neuartigen Eisberg-Ansatz vor, der umfangreiche Flugzeugsensordaten, KI und sogar Blockchain kombiniert, um sowohl offensichtliche als auch versteckte Systemfehler zu überwachen.
- Oh und Kim (2023) entwickeln eine Plattform unter Verwendung von LSTM-Netzwerken zur Analyse massiver Ströme von Fahrzeugsensor- und Fehlerdaten für die vorausschauende Wartung elektronischer Steuereinheiten.
- Kabashkin und Susanin (2024) schlagen ein Datenanalyse-Framework vor, das Leistungsdaten von Flugzeugkomponenten über einen bestimmten Zeitraum integriert, um Entscheidungen über Wartung und Austausch zu unterstützen.



KI-Frameworks für die Wartung

- Lu et al. (2024) stellen einen KI-basierten Rahmen vor, der maschinelles Lernen mit modellbasierten Methoden kombiniert, um den Zustand von Fahrzeugsteuerungssystemen zu überwachen.
- Hinostroza et al. (2024) präsentieren ein Framework, das KI-Planungsalgorithmen nutzt, um ein unbemanntes Bodenfahrzeug für autonome Inspektionen von Industrieanlagen zu koordinieren.
- Massaro, Selicato und Galiano (2020) stellen eine maßgeschneiderte intelligente elektronische Steuereinheit mit KI-Algorithmen als Teil eines Frameworks für die Wartung von Busflotten vor.
- Sanz, Blesa und Puig (2021) schlagen ein Wartungsframework für Industrie 4.0 vor, das IoT-Sensoren, Robotik und KI-Analysen miteinander verbindet, um die Qualität von Geräten und Produkten in Echtzeit zu überwachen.

Quelle: Pebrianti et al. (2024), Ferdous et al. (2024), Mohan et al. (2021), Samanta und Williamson (2023), Consilvio et al. (2024), Kabashkin (2024), Oh und Kim (2023), Lu et al. (2024), Hinostroza et al. (2024), Sanz, Blesa und Puig (2021)



Deep Learning in der vorausschauenden Instandhaltung

- Chaudhuri und Ghosh (2024) stellen eine Reihe von Deep-Learning-Modellen vor, die groß angelegte Telematik- und Sensordaten von Fahrzeugflotten analysieren, um Ausfälle vorherzusagen.
- Kim et al. (2024) schlagen ein Deep-Learning-Modell auf Basis einer hybriden Transformer-Architektur vor, um Anomalien in Klimaanlagen von Eisenbahnen zu erkennen.
- Patil et al. (2023) liefern eine gründliche Analyse der Anwendung von maschinellem Lernen und Deep-Learning-Techniken auf die vorausschauende Wartung in der Automobilfertigung und im Maschinenbau.



Digitale Zwillinge und Datenanalyse

- Vashishth et al. (2025) untersuchen, wie digitale Zwillingstechnologie in Logistik- und Transportsystemen eingesetzt wird, um den Zustand von Anlagen in Echtzeit zu überwachen.
- Nuvvula et al. (2024) stellen eine Strategie für das Management einer Elektrofahrzeugflotte vor, die prädiktive Analysen von Fahrzeug- und Ladedaten nutzt, um den Betrieb zu optimieren.
- Jafari und Byun (2022) präsentieren ein Digital-Twin-Framework für Lithium-Ionen-Batterien, bei dem das Twin-Modell Daten des Batteriemanagementsystems nutzt, um den Ladezustand und den Gesundheitszustand der Batterie vorherzusagen.




Verstärkendes Lernen für die Instandhaltung

- Razzaghi et al. (2024) geben einen Überblick darüber, wie RL-Techniken auf Wartungsprobleme in der Luftfahrt angewendet werden.
- Huang et al. (2023) stellen einen Multi-Agenten-Rahmen für Deep Reinforcement Learning vor, der es einem Team unbemannter Bodenfahrzeuge ermöglicht, Formationen zu bilden und bei Aufgaben zusammenzuarbeiten.
- Y. Liu, Yang und Guo (2022) untersuchen einen RL-Ansatz für Wartungs- und Betriebsentscheidungen, der den gesamten Produktlebenszyklus berücksichtigt.

Quelle: Chaudhuri und Ghosh (2024), Kim et al. (2024), Patil et al. (2023), Vashishth et al. (2025), Nuvvula et al. (2024), Jafari und Byun (2022), Razzaghi et al. (2024), Huang et al. (2023), Y. Liu, Yang und Guo (2022)

Inhaltsanalyse der schließlich ausgewählten Artikel | Analyse nach ÖPNV-Sektor

Fokus des Anwendungsbereichs



Wichtigste Erkenntnisse

- Wir haben die schließlich ausgewählten Beiträge nach Anwendungsbereich analysiert, um Einblicke zu gewinnen, wie KI und ML auf die Wartungsanforderungen im öffentlichen Verkehr zugeschnitten werden.
- In der Luftfahrt hat tiefgreifendes Reinforcement Learning für die probabilistische RUL-Schätzung maßgeblich zur Optimierung der Wartungsintervalle und zur Reduzierung der Ausfallzeiten von Flugzeugen beigetragen.
- Anwendungen im Eisenbahnbereich befassen sich mit vorausschauender Wartung durch maschinelle Lernmodelle mit besonderem Schwerpunkt auf Fehlererkennung, Wartungsplanung und Gleis.
- Der Automobilsektor konzentriert sich auf die Überwachung des Fahrzeugzustands, wo Deep Learning und Anomalieerkennungstechniken die Fehlerdiagnose und das Flottenmanagement verbessern.
- Darüber hinaus gibt es mehrere Studien, die sich mit vorausschauender Wartung, Komponentenprognosen und RUL-Schätzung für andere relevante Anwendungen befassen, z. B. Windkraftanlagen, Stromnetze, Pipelines und industrielle Fertigungssysteme usw.

Inhaltsanalyse der schließlich ausgewählten Artikel | Die 10 relevantesten Artikel aus der Luftfahrt

Quelle	Ziele	KI/ML-Modell	Wartungsaspekt	Kurzfristige Ergebnisse
Tseremoglou, van Kessel und Santos (2023)	Optimierung von Wartungsplänen durch Vorhersage der verbleibenden Nutzungsdauer von Komponenten	DRL und MILP	Wartungs-planung	Das vorgeschlagene MILP-Modell erzeugt stabilere Wartungspläne und reduziert die Wartungsstillstandszeiten im Vergleich zu anderen Methoden.
Vos et al. (2023)	Maximierung der Flottenverfügbarkeit bei Minimierung der Wartungskosten	RL	Wartungs-planung	Es wurde gezeigt, dass eine RL-basierte Strategie die Gesamtverfügbarkeit der Flotte verbessern kann, obwohl der große Aktionsraum bei der Planung rechnerische Herausforderungen mit sich bringt.
Ribeiro et al. (2022)	Entwicklung interaktiver Tools, mit denen menschliche Planer mithilfe von ML-Unterstützung zustandsbasierte Wartungspläne entwerfen und visualisieren können	ML integriert mit einem RL-Agenten	Wartungs-planung (zustands-basierte Wartung)	Einführung eines neuartigen Ansatzes für die Mensch-Computer-Interaktion, der Wartungsplanern die Interaktion mit einem ML-Agenten erleichtert, was zu zuverlässigeren Wartungsplänen und einem besseren Verständnis der KI-gesteuerten Empfehlungen durch den Benutzer führt
Lee und Mitici (2023)	Nutzung von DRL und RUL-Prognosen für proaktive Entscheidungen zur Flugzeugwartung	DRL kombiniert mit probabilistischer RUL-Schätzung	Voraus-schauende Wartungs-planung	Zeigte, dass ein DRL-Ansatz den Wartungszeitpunkt durch die Verwendung von RUL-Prognosen optimieren kann, wodurch ungeplante Ausfallzeiten reduziert und die Wartungseffizienz verbessert werden
Tseremoglou und Santos (2024)	Zur Planung der Flugzeugwartung unter Unsicherheit	DRL	Wartungs-planung (zustandsba-sierte Wartung)	Es wurde gezeigt, dass ein Deep-RL-Algorithmus mit unsicheren Systeminformationen umgehen und dennoch die Entscheidungen zur Wartungsplanung verbessern kann, wodurch unter Bedingungen mit teilweiser Beobachtbarkeit eine höhere Verfügbarkeit erreicht wird.

Inhaltsanalyse der schließlich ausgewählten Artikel | Die 10 relevantesten Artikel aus der Luftfahrt

Quelle	Ziele	KI/ML-Modell	Wartungsaspekt	Kurzfristige Ergebnisse
Dangut, Skaf und Jennions (2022)	Verbesserung der Fehlerprognose in Flugzeugsystemen durch Behebung von Klassenungleichgewichten in Wartungsdaten	BACHE-Algorithmus mit ML-Klassifikatoren	Vorausschauende Wartung	Der vorgeschlagene Ansatz verbesserte die Genauigkeit der Fehlererkennung durch den Ausgleich seltener Fehlerfälle im Datensatz, was zu einer zuverlässigeren Identifizierung seltener, aber kritischer Fehler führte.
Kabashkin und Susanin (2024)	Unterstützung von Entscheidungen über die Reparatur oder den Austausch von Flugzeugkomponenten während ihres gesamten Lebenszyklus	Entscheidungsunterstützungsmodell (ML-basierte Prognosen)	Wartungsplanung	Bereitstellung eines Modells, das die Wartung und den Austausch von Komponenten über ihren Lebenszyklus hinweg optimiert, was zu einer verbesserten langfristigen Zuverlässigkeit der Flotte und zu Kosteneinsparungen führt.
Zhou et al. (2022)	Vorhersage des Ersatzteilbedarfs und Planung des Komponentenaustauschs durch Identifizierung konkurrierender Ausfallrisiken in der Flottenausrüstung	Hybrides Lernalgorithmus (statistische Zuverlässigkeitsmodelle mit ML)	Wartungsplanung und Ersatzteilmanagement	Verbessert die Vorhersage von Komponentenausfällen und den entsprechenden Ersatzteilbedarf, ermöglicht effiziente Strategien für den Austausch von Komponenten und reduziert Ausfallzeiten in der gesamten Flotte.
Rahim et al. (2020)	Minimierung der Lebenszyklus- und Wartungskosten für kritische Flugzeugkomponenten durch optimierte Planung	KI-gestütztes Optimierungsmodell	Wartungsplanung	Entwicklung einer Wartungsplanungsstrategie, die die Gesamtkosten für kritische Komponenten durch Optimierung der Inspektions- und Austauschintervalle ohne Beeinträchtigung der Sicherheit senkt
Dang et al. (2024)	Verbesserung der Transparenz von KI-gesteuerten Entscheidungen zur Wartungsplanung mithilfe erklärbarer KI-Techniken	Erklärbare KI integriert in Wartungsplanungsalgorithmen	Wartungsplanung (zustandsabhängige Wartung)	Es wurde nachgewiesen, dass die Bereitstellung von ursächlichen Erklärungen für von KI empfohlene Wartungspläne das Vertrauen und Verständnis der Nutzer erhöht und gleichzeitig eine effiziente Planung der Flugzeugwartung ermöglicht.

Inhaltsanalyse der schließlich ausgewählten Artikel | Die 10 relevantesten Artikel im Bereich Schienenverkehr

Quelle	Ziele	KI/ML-Modell	Wartungsaspekt	Kurzfristige Ergebnisse
Kaewunruen, Sresakoolchai und Zhu (2021)	Optimierung langfristiger Zeitpläne für die Erneuerung und Wartung von Schienen mithilfe von Deep Reinforcement Learning	DRL	Erneuerungs- und Instandhaltungsplanung	Der DRL-Ansatz generierte kosteneffiziente Instandhaltungs- und Erneuerungspläne, die das Ausfallrisiko reduzierten und sich als vielversprechend für die Automatisierung komplexer Planungsentscheidungen für die Instandhaltung der Schieneninfrastruktur erwiesen.
Famurewa, Zhang und Asplund (2017)	Entwicklung diagnostischer, prädiktiver und präskriptiver Analysen für die Instandhaltung der Eisenbahninfrastruktur	Datenanalyse-Framework	Unterstützung bei Instandhaltungsentscheidungen	Vorstellung eines Analyseansatzes, der Fehler diagnostiziert, Ausfälle vorhersagt und Instandhaltungsmaßnahmen vorschlägt, wodurch die Entscheidungsfindung für die Instandhaltung und Zuverlässigkeit der Infrastruktur verbessert wird
Khouzani, Golroo und Bagheri (2017)	Stochastische Modellierung der Verschlechterung der Gleisgeometrie für eine optimierte Wartungsplanung	Stochastische Verschleißmodellierung	Wartungsplanung	Das Modell prognostiziert die Verschlechterung der Gleisgeometrie im Laufe der Zeit und hilft Planern dabei, Wartungsarbeiten (z. B. Stopfarbeiten) zum optimalen Zeitpunkt zu planen, um Kosten und Sicherheit in Einklang zu bringen.
Gao, Szugs und Ahlbrink (2018)	Integration mehrerer Datenquellen zur Schieneninspektion zur Erkennung von Oberflächen- und Untergrundfehlern	DF und ML	Vorausschauende Instandhaltung	Verbesserte Fehlererkennungsgenauigkeit durch Kombination verschiedener Daten (z. B. Ultraschall, Sichtprüfungen), wodurch Schienenfehler früher erkannt und das Ausfallrisiko verringert werden können
Gerum, Altay und Baykal-Gürsoy (2019)	Entwicklung einer datengestützten Richtlinie für die vorausschauende Planung von Instandhaltungsmaßnahmen im Schienenverkehr	ML	Wartungsplanung	Nachweis, dass die Verwendung datengesteuerter Modelle zur Planung der Gleiswartung Ausfälle (wie Gleisverformungen oder -brüche) wirksam verhindern und Wartungsintervalle optimieren kann.

Inhaltsanalyse der schließlich ausgewählten Artikel | Die 10 relevantesten Artikel im Bereich Schienenverkehr

Quelle	Ziele	KI/ML-Modell	Wartungs- aspekt	Kurzfristige Ergebnisse
Hu und Liu (2016)	Vorhersage der Verschlechterung der Gleisgeometrie mithilfe von maschinellem Lernen	SVM	Planung vorbeugender Instandhaltungsmaßnahmen	Das SVM-Modell sagte Trends zur Verschlechterung der Gleisgeometrie genau voraus und ermöglichte so eine proaktive Planung von Wartungsarbeiten, bevor die Gleisqualität unter die Sicherheitsgrenzwerte fiel.
Zhang, Zhou und Liu (2020)	Vorhersage des Auftretens von Schienenbrüchen mithilfe von Techniken des maschinellen Lernens	ML-Klassifizierung (z. B. Random Forest)	Wartungsplanung	Es wurde die Fähigkeit erreicht, Gleisabschnitte mit hohem Risiko für Schienenbrüche zu identifizieren, sodass vorbeugende Reparaturen geplant und die Eisenbahnsicherheit erheblich verbessert werden konnten.
Li et al. (2014)	Analyse von Faktoren, die Zugverspätungen und die Netzgeschwindigkeit beeinflussen, mithilfe von maschinellem Lernen	ML	Wartungsplanung und -terminierung	Identifizierung von wartungsbezogenen Faktoren, die sich auf die Netzgeschwindigkeit (Pünktlichkeit) auswirken, um Anpassungen der Wartungspläne vorzunehmen, Verzögerungen zu reduzieren und die Pünktlichkeit des Gesamtdienstes zu verbessern
Lasisi und Attah-Okine (2019)	Verbesserung der Genauigkeit von Vorhersagen zu Schienenfehlern mithilfe von Ensemble-Lernmethoden	EML	Zustandsbasierte Wartungsplanung	Ensemble-Modelle verbesserten die Genauigkeit der Fehlererkennung und -vorhersage, was zu gezielteren Instandhaltungsmaßnahmen und einer effizienteren Nutzung der Reparaturressourcen im Schienennetz führte.
Mohammadi und He (2022)	Überwachung von Schienenwelligkeit und Vorhersage von Gleisverschleiß zur Verlängerung der Lebensdauer von Gleisen und Schienenfahrzeugen	ML	Wartungsplanung	Ermöglichte die frühzeitige Erkennung von Schienenwelligkeit, wodurch rechtzeitige Schleifarbeiten durchgeführt und die Lebensdauer von Gleisen und Rädern verlängert werden konnten.

Inhaltsanalyse der schließlich ausgewählten Artikel | Die 10 relevantesten Artikel aus dem Bereich Automobilindustrie

Quelle	Ziele	KI/ML-Modell	Wartungsaspekt	Kurzfristige Ergebnisse
Jakobsson et al. (2020)	Vorhersage der verbleibenden Nutzungsdauer schwerer Bergbaufahrzeuge auf Grundlage ihrer Nutzungsdaten	NN	Vorausschauende Wartung	Das Modell prognostiziert anhand von Betriebsdaten die Lebensdauer von Fahrzeugkomponenten genau, ermöglicht eine proaktive Wartungsplanung und reduziert unerwartete Ausfälle von Schwerlastfahrzeugen.
Gong et al. (2023)	Diagnose und Überwachung von Störungen an Elektrofahrzeugen mithilfe indirekter Messungen in Kombination mit KI	KI-gesteuerte Signalverarbeitung	Vorausschauende Wartung	Die vorgeschlagene Methodik erkennt schnell und präzise Fehler an Elektromotoren und Batterien von Elektrofahrzeugen allein anhand indirekter Signale, verbessert die Reaktionszeiten bei der Wartung und reduziert den Bedarf an zusätzlichen Sensoren.
Gugaratshan et al. (2023)	Kontinuierliche Aktualisierung von Modellen zur Zuverlässigkeit, Verfügbarkeit und Wartbarkeit von Fahrzeugen anhand von Sensordaten aus dem Betrieb	ML	Wartungsplanung	Es wurde gezeigt, dass die Einbeziehung von Echtzeit-Multivariaten-Sensordaten in Zuverlässigkeitsmodelle die Fehlerprognose erheblich verbessert und den Wartungszeitpunkt für kritische Fahrzeugsysteme (z. B. Bremsen, Motor) optimiert.
Chen et al. (2021)	Vorhersage des Wartungsbedarfs von Fahrzeugen durch Integration von Deep-Learning-Modellen mit GIS-Daten	Deep Learning (z. B. CNN/LSTM)	Vorausschauende Wartung	Erfolgreiche Vorhersage, wann und wo Fahrzeugwartungen erforderlich sind, durch Analyse von Betriebsrouten und Umgebungsbedingungen, wodurch zeitnahe, standortbezogene Wartungsmaßnahmen für Fahrzeugflotten ermöglicht werden
Danilo Giordano et al. (2022)	Bewertung und Ableitung von Best Practices für die Implementierung vorausschauender Wartung in einer Automobilproduktionsumgebung	ML	Vorausschauende Wartung	Hervorhebung effektiver datengesteuerter Wartungsstrategien (und häufiger Fallstricke) in einer realen Fallstudie aus der Automobilbranche mit Leitlinien zu Datenqualität, Modellauswahl und Integration für zukünftige Implementierungen

Inhaltsanalyse der schließlich ausgewählten Artikel | Die 10 relevantesten Artikel aus dem Bereich Automobilindustrie

Quelle	Ziele	KI/ML-Modell	Wartungs- aspekt	Kurzfristige Ergebnisse
Giobergia et al. (2018b)	Verwendung großer Mengen von Sensordaten aus Fahrzeugen, um Komponentenausfälle im Voraus vorherzusagen	Datenauswertung und ML	Vorausschauende Wartung	Zeigte, dass die Auswertung hochdimensionaler Fahrzeugsensordaten Frühwarnmuster für Komponentenausfälle aufdecken kann, wodurch die Fehlererkennung verbessert und Wartungsarbeiten geplant werden können, bevor es zu Ausfällen in Fahrzeugflotten kommt
H. Liu, Song und Zhang (2021)	Diagnose von Fehlern in Elektro-/Hybridfahrzeugen mithilfe verbesserter Algorithmen für maschinelles Lernen	Verbesserter ML-Algorithmus (z. B. verbesserte SVM/ANN)	Vorausschauende Wartung	Das verbesserte maschinelle Lernmodell identifiziert Batterie- und Motorstörungen in Fahrzeugen mit neuen Energien präzise und trägt so zu einem zuverlässigeren Betrieb und einer rechtzeitigen Wartung von Elektrofahrzeugflotten bei.
Kavousi-Fard et al. (2020b)	Erkennung von Anomalien in Fahrzeugbetriebsdaten aus Sicherheits- und Zuverlässigkeitsgründen	DL	Anomalie-erkennung	Das Modell erkennt mit hoher Genauigkeit abnormale Muster in Fahrzeugdaten (die möglicherweise auf Komponentenfehler oder Cyberangriffe hinweisen) und bietet ein Frühwarnsystem, das umgehend Wartungs- oder Sicherheitsmaßnahmen auslösen kann.
Ji et al. (2021b)	Identifizierung von Anomalien im Kupplungsbetrieb von Hybrid-Elektrofahrzeugen mithilfe von maschinellem Lernen	ML	Zustandsüberwachung	Erfolgreiche Erkennung ungewöhnlicher Kupplungseingriffsmuster, die auf Verschleiß oder Fehler im Getriebe von Hybridfahrzeugen hinweisen, wodurch eine gezielte vorbeugende Wartung des Kupplungssystems ermöglicht wird.
Aeddula et al. (2024)	Anwendung von KI-gesteuerter vorausschauender Wartung in autonomen Fahrzeugflotten als Teil einer Produkt-Service-System-Strategie	KI-gesteuertes Analyse-Framework	Vorausschauende Wartung / Wartungsplanung	Die Untersuchung identifizierte Überlegungen, Einschränkungen und Verbesserungen für die Implementierung einer KI-basierten Wartung in autonomen Fahrzeugdiensten und demonstrierte die Bedeutung des Ansatzes für die Verbesserung der Flottenzuverlässigkeit und die Gestaltung eines effektiven PSS.

Erkenntnisse aus der systematischen Literaturrecherche

Die systematische Literaturrecherche lieferte einen umfassenden Überblick über künstliche Intelligenz und maschinelles Lernen in der Wartungsplanung und -steuerung im öffentlichen Verkehr. Die Untersuchung ergab mehrere wichtige Erkenntnisse, neue Trends und Anwendungsmöglichkeiten von KI für die Wartungsplanung und -steuerung im öffentlichen Verkehr. Erstens zeigt die deskriptive Analyse, dass das Forschungsvolumen in diesem Bereich in den letzten zehn Jahren stetig zugenommen hat, was auf ein wachsendes Interesse an diesem Forschungsgebiet hindeutet. Wir haben festgestellt, dass sich ein Großteil der Studien auf KI in prädiktiven und zustandsorientierten Instandhaltungsansätzen konzentriert, um Ausfälle von Anlagen vorherzusagen bzw. deren Zustand zu überwachen. In diesen Arbeiten sind die Themen Instandhaltungsplanung und -terminierung vorherrschend, was dem allgemeinen Bestreben entspricht, Ausfallzeiten zu minimieren und Ausfälle durch bessere Erkenntnisse zu vermeiden.

Zweitens zeigt unsere Clusteranalyse hinsichtlich der verwendeten KI-Techniken, dass keine einzelne Methode den Bereich dominiert, sondern dass eine Vielzahl von Ansätzen ausprobiert und oft kombiniert werden. Reinforcement Learning hat Aufmerksamkeit für die Formulierung von Wartung als sequentielles Entscheidungsproblem gewonnen und ist insbesondere in Wartungsplanungsszenarien vielversprechend. Deep Learning wurde aufgrund seiner Fähigkeit, komplexe Muster in Sensordaten zu modellieren, für viele vorausschauende Wartungsaufgaben eingesetzt. Klassische Methoden des maschinellen Lernens (wie SVMs, Random Forests und Bayes'sche Modelle) werden für die Fehlerdiagnose, die Vorhersage der Restlebensdauer und die Wartungsplanung verwendet. Darüber hinaus verwenden eine Reihe von Artikeln hybride Ansätze, beispielsweise die Kombination von physikalischen Modellen mit KI zur Unterstützung von Wartungsarbeiten.

Schließlich haben wir bei der Analyse der Anwendungsbereiche festgestellt, dass KI-gesteuerte Wartung in den Bereichen Luftfahrt, Eisenbahn und Automobil erhebliche Vorteile bietet, darunter eine verbesserte Fehlerprognose, eine optimierte Wartungsplanung, reduzierte Ausfallzeiten und eine verbesserte Entscheidungsunterstützung für die Wartung. Die Analyse der Anwendungsbereiche zeigt, dass es zwar gemeinsame Themen im Bereich der Wartung gibt, jeder Sektor jedoch auch seine eigenen Prioritäten hat. In der Luftfahrt drehen sich KI-Anwendungen häufig um hochpräzise Prognosen für kritische Komponenten und die Optimierung von Flottenwartungsplänen, um ungeplante Flugausfälle zu vermeiden. Im Eisenbahnsektor konzentrieren sich die meisten Arbeiten auf sensorbasierte Zustandsüberwachung und Fehlererkennung sowie auf Planungsmodelle, die Wartungstermine rund um den Zugbetrieb planen. Im Automobilsektor liegt der Schwerpunkt auf der Nutzung von Fahrzeugdaten zur Implementierung vorausschauender Wartungsmaßnahmen, die die Betriebskosten senken können.

Die meisten Veröffentlichungen konzentrieren sich auf spezifische Aspekte, z. B. die Vorhersage der RUL, Fehlerdiagnosen, Entscheidungsunterstützungssysteme für Reparatur und Austausch usw. In der Praxis umfasst die Wartungsplanung und -steuerung jedoch eine komplexe Koordination vieler Aktivitäten (z. B. Inspektion, Ermittlung des Material- und Komponentenbedarfs, Ressourcenzuweisung sowie Personal- und Aufgabenplanung usw.). Daher sind die Autoren der Meinung, dass ganzheitlichere Lösungen erforderlich sind, die Wartungsaktivitäten und Fertigungsbeschränkungen integrieren und über die Vorhersage einzelner Komponenten hinaus zu einer Optimierung der Wartung auf Systemebene führen. Ein solches Wartungsplanungs- und -steuerungssystem könnte Wartungsmanager bei der End-to-End-Planung (von der Erkennung eines Bedarfs bis zur Planung und Durchführung der Wartung) unterstützen und in realen Wartungseinrichtungen validiert werden.

Zusammenfassung	9
I. Aufbau des Studienberichts	11
1. Ausgangspunkt	13
2. Forschungsfragen	15
3. Forschungsmethodik	16
II. Systematische Literaturrecherche zu KI in der Wartungsauftragsplanung und -steuerung	17
1. Suchstrategie für die Datenerhebung	18
2. Prisma-Richtlinien für die Analyse von Artikeln	19
3. Deskriptive Analyse der gesammelten Artikel	20
a) Publikationstrends in diesem Bereich	20
b) Analyse der Schlüsselwörter in diesem Bereich	21
c) Verteilung der Veröffentlichungen nach Clustern	26
d) Intensität der Schlüsselwörter in diesem Bereich	27
e) Trends im Anwendungsbereich	28
4. Inhaltsanalyse der schließlich ausgewählten Artikel	30
a) Verteilung nach Wartungsstrategien	30
b) Analyse auf Basis identifizierter Cluster	32
c) Analyse nach öffentlichen Verkehrssektoren	35
5. Erkenntnisse aus der systematischen Literaturrecherche	42
III. Konzeptioneller Rahmen für KI in der Planung und Steuerung von Instandhaltungsaufträgen	43
1. Grundlegende Komponenten der KI-basierten Wartungsauftragsplanung und -steuerung	46
2. KI-MOPC-Architektur für den Schieneninstandhaltungsworkshop	48

3.	Konzeptionelles Modell von AI-MOPC für die Eisenbahninstandhaltungswerkstatt	50
4.	Erkenntnisse aus dem konzeptionellen Rahmen	52
IV.	Verstärkendes Lernen in der Wartungsauftragsplanung und -steuerung	54
1.	Suchstrategie für die Datenerfassung	56
2.	Deskriptive Analyse der gesammelten Artikel	57
a)	Publikationstrends in diesem Bereich	57
b)	Analyse auf Grundlage der identifizierten Cluster	58
4.	In diesem Forschungsbereich verwendete Modelle des verstärkenden Lernens	62
5.	Konzeptioneller Rahmen für verstärktes Lernen in der Wartungsauftragsplanung und -steuerung	63
a)	Hauptfunktionen von Wartungsauftragsplanung und -steuerung	64
b)	Komponenten des verstärkenden Lernens	66
c)	Implementierungsüberlegungen zur Umsetzung	67
d)	Verstärkender Lern-Feedback-Loop	68
6.	Erkenntnisse aus dem verstärkenden Lernen in der Wartungsauftragsplanung und -steuerung	69
V.	Schlussfolgerung und Ausblick	70
	Literaturverzeichnis	74
	Weitere Studienberichte des Lehrstuhls für Produktionswirtschaft	83

In der Literatur konnten wir kein spezielles KI-basiertes System für die Wartungsplanung und -steuerung finden. **Die meisten vorgestellten KI-Lösungen konzentrieren sich isoliert auf bestimmte Aspekte, z. B. die Vorhersage der Restlebensdauer, die Fehlerdiagnose und Entscheidungshilfesysteme für Reparatur und Austausch.** In der Praxis umfasst die Wartungsplanung und -steuerung jedoch die komplexe Koordination vieler Aktivitäten, z. B. Inspektion, Ermittlung der erforderlichen Materialien und Komponenten, Zuweisung von Ressourcen und Planung des Personals und der Aufgaben. Daher besteht ein Bedarf an ganzheitlicheren Lösungen, die Wartungsaktivitäten und Fertigungsbeschränkungen integrieren und über die Vorhersage einzelner Komponenten hinaus zur Optimierung der Wartung auf Systemebene führen. Ein KI-basiertes System zur Wartungsplanung und -steuerung könnte Wartungsmanager bei der End-to-End-Planung unterstützen, von der Ermittlung des Wartungsbedarfs bis zur Terminierung und Durchführung, und könnte in realen Zugwartungsanlagen validiert werden.

In diesem Zusammenhang stellen wir einen neuartigen, KI-basierten konzeptionellen Rahmen vor und liefern einen Fahrplan zur Beantwortung der folgenden Forschungsfrage: **Wie können Wartungsaufträge im öffentlichen Verkehr, insbesondere in Zugwartungswerkstätten, mithilfe von KI geplant und gesteuert werden?** Zunächst haben wir die grundlegenden Elemente skizziert, die für die Integration von KI in die Wartungsplanung erforderlich sind. Dazu gehören vier Schlüsselkomponenten: Datenmodelle, KI-Algorithmen, Entscheidungsfindungsmodelle und die Integration in bestehende Informationssysteme und Benutzeroberflächen. Auf der Grundlage dieser grundlegenden Elemente wurde dann die Architektur eines KI-MOPC für Eisenbahnwartungswerkstätten entworfen. Abschließend wird ein theoretisches Modell vorgeschlagen, um den Arbeitsablauf und die Entscheidungsstruktur des KI-MOPC in Eisenbahnwartungswerkstätten zu definieren. Das primäre Ziel des vorgeschlagenen KI-MOPC-Systems in einer Eisenbahnwerkstatt ist es, Echtzeit-Entscheidungsprozesse in den Bereichen Wartungsauftragsplanung und -steuerung zu ermöglichen. Das vorgeschlagene Modell stellt eine bedeutende Weiterentwicklung gegenüber herkömmlichen Methoden dar, da es KI-gesteuerte Automatisierung, prädiktive Analysen und Echtzeitoptimierung nutzt. Dieses KI-gestützte System integriert die Wartungsplanung und -steuerung und verbessert gleichzeitig die Entscheidungsprozesse, wodurch Ausfallzeiten reduziert und eine optimale Ressourcennutzung in der Eisenbahnwerkstatt gewährleistet werden.

Grundlegende Komponenten der KI-basierten Wartungsauftragsplanung und -steuerung


Das KI-basierte System zur Planung und Steuerung von Wartungsaufträgen (AI-MOPC) lässt sich in vier wesentliche Komponenten unterteilen: Datenmodelle, KI-Algorithmen, Entscheidungsmodule, Integration in bestehende Systeme und Benutzeroberfläche. Jedes dieser Elemente spielt eine entscheidende Rolle bei der Schaffung eines robusten und effizienten AI-MOPC-Systems, das einen nahtlosen Datenfluss, genaue Vorhersagen und umsetzbare Erkenntnisse gewährleistet.



1. Datenmodelle

Datenmodelle bilden die Grundlage des AI-MOPC-Systems, indem sie Rohdaten aus Sensoren, Geräte logs und Betriebsdaten von Anlagen strukturieren und organisieren. Richtig konzipierte Datenmodelle gewährleisten eine genaue Darstellung der zugrunde liegenden Systeme und erleichtern fortgeschrittene Analysen.

- Woods et al. (2024) haben eine Ontologie für Wartungsaktivitäten erstellt, um Arbeitsauftragsdaten zu strukturieren, darunter Ersatz, Inspektion und Verbesserung der Datenqualität.
- Hodkiewicz et al. (2024) haben IOF-Maint eingeführt, eine modulare Wartungsontologie, die auf die Industrial Ontology Foundry abgestimmt und für Anlagenwartungsdaten implementiert wurde.
- Stewart et al. (2024) setzten natürliche Sprachverarbeitung (NLP) und Deep Learning ein, um Entitäten aus Arbeitsaufträgen zu extrahieren und in einen Wissensgraphen von Wartungsereignissen zu integrieren. Diese Modelle erleichtern die Vereinheitlichung heterogener Datenquellen, einschließlich Sensorwerten, ERP-Datensätzen und Wartungshandbüchern, und ermöglichen so automatisiertes Schlussfolgern.




2. KI-Algorithmen

AI-MOPC-Systeme können eine Reihe von KI- und Optimierungsalgorithmen einsetzen, um Ausfälle vorherzusagen, Wartungsaufgaben zu planen und Zeitpläne zu optimieren. Überwachte Lernverfahren wie neuronale Netze, Random Forests und Support-Vektor-Maschinen (SVMs) werden häufig für die Fehlervorhersage und die RUL-Schätzung eingesetzt. Die meisten aktuellen Studien haben jedoch den Schwerpunkt auf die Anwendung von Reinforcement Learning (RL) im Kontext von Entscheidungsprozessen gelegt.

- Eine Literaturrecherche zeigt, dass sowohl RL als auch Deep RL in der Lage sind, kontinuierliche Zustandsüberwachungsdaten zu nutzen, um dynamische Wartungsstrategien zu erlernen, die Kosten und Ausfallzeiten minimieren (Ogunfowora und Najjaran 2023).
- Silva et al. (2023) wenden einen RL-Agenten auf die Flugzeugwartungsplanung an: Eine statische Richtlinie plant im Voraus und eine adaptive Richtlinie plant neu, wenn neue Informationen eintreffen, was zu flexiblen und effizienten Wartungsplänen führt.

Quelle: Woods et al. (2024), Hodkiewicz et al. (2024), Stewart et al. (2024), Ogunfowora und Najjaran (2023), Silva et al. (2023)

Grundlegende Komponenten der KI-basierten Wartungsauftragsplanung und -steuerung



3. Entscheidungsmodule

Das Entscheidungsmodul übersetzt KI-Erkenntnisse in konkrete Wartungsmaßnahmen oder -pläne. Die Integration von Experten- und wissensbasierten Komponenten ist zu einem vorherrschenden Merkmal moderner KI-basierter Entscheidungsunterstützungssysteme geworden. Das Entscheidungsmodul ist in der Lage, Prognosen aus maschinellem Lernen mit Solvern sowie mit regelbasierter Logik zu kombinieren, um Wartungsaufgaben zu planen.

- Öhlinger et al. (2022) stellen einen KI-gestützten Ansatz für die Wartungsauftragsplanung vor, bei dem der Schwerpunkt auf einer ganzheitlichen Planungsoptimierung mit Entscheidungsunterstützung liegt, um unsichere Auftragsinformationen in umsetzbare Pläne umzuwandeln.
- Soori et al. (2024) zeigten, dass wissensbasierte Systeme formalisierte Regeln und Ontologien nutzen, um menschliches Denken nachzuahmen und so automatisierte Schlussfolgerungen und erklärable Entscheidungslogik zu ermöglichen. Diese Systeme können Wartungsheuristiken codieren, z. B. Prioritätsregeln, oder mehrere Kriterien wie Kosten, Ausfallzeiten und Sicherheit durch multikriterielle Optimierung bewerten.



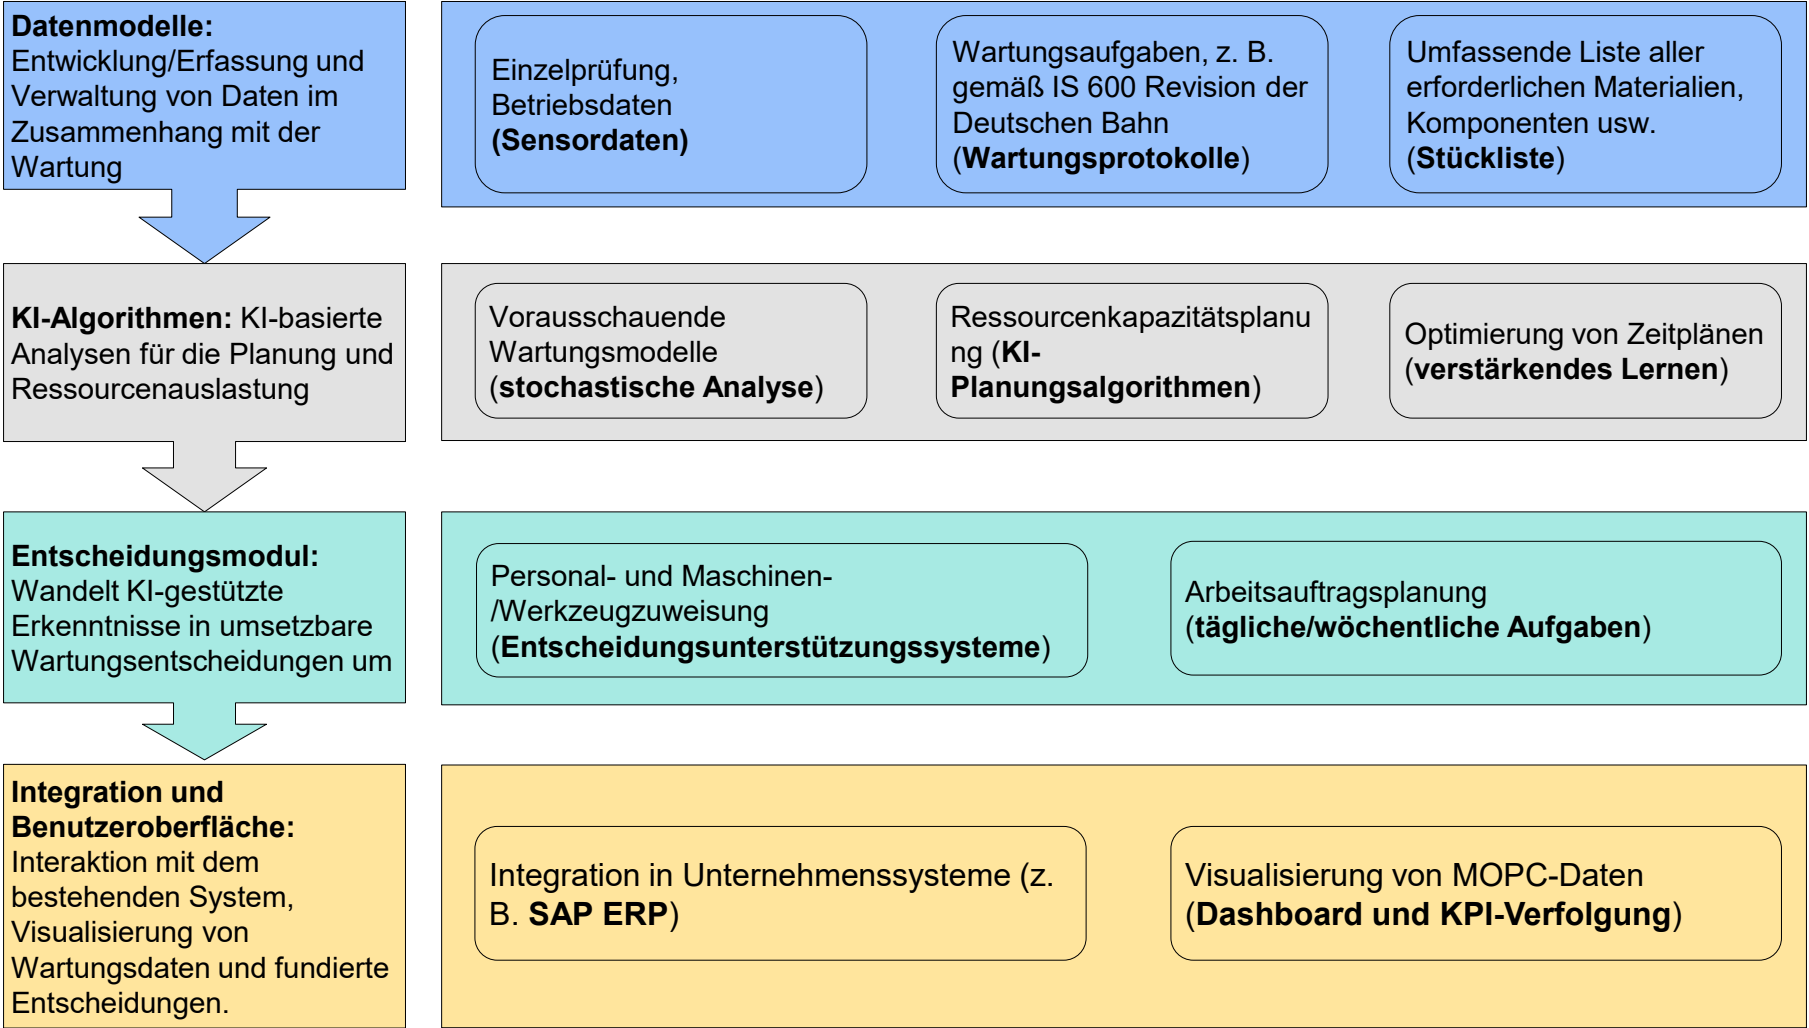
4. Integration und Benutzeroberfläche

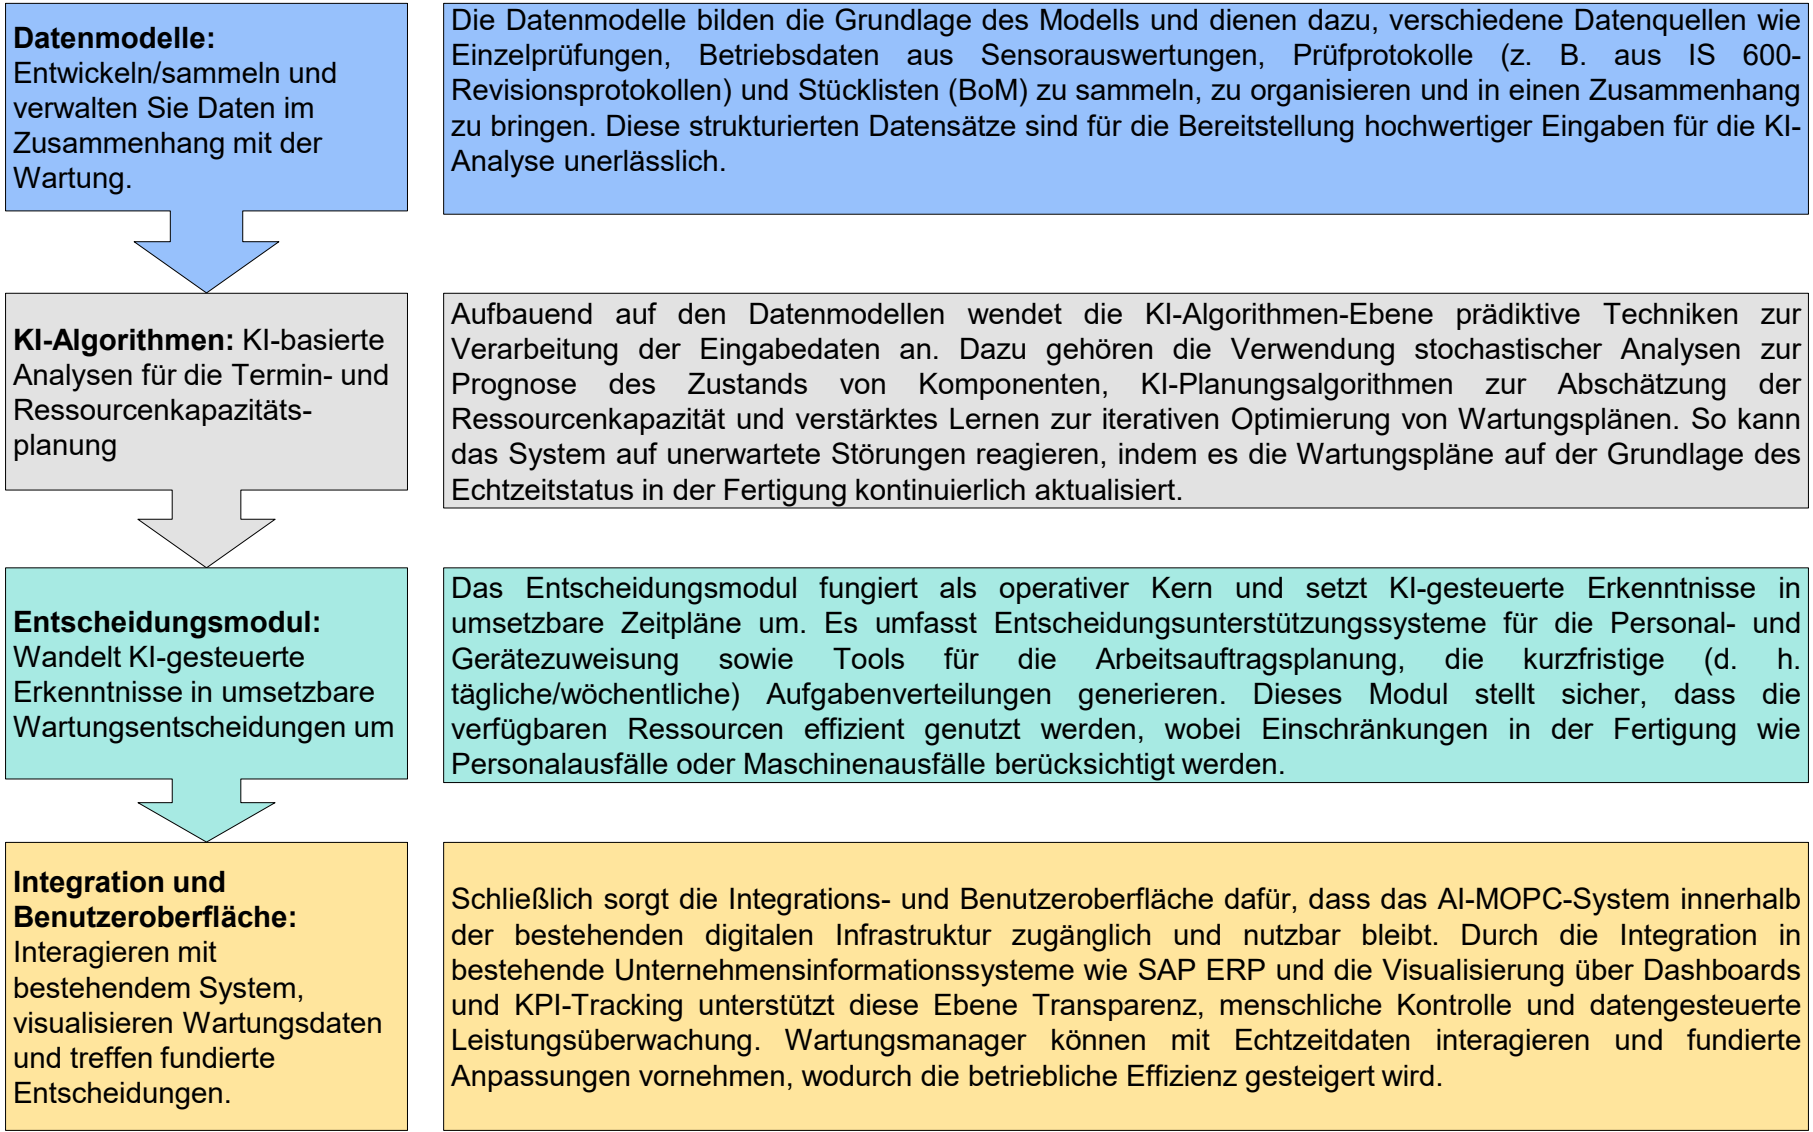
Die Integration von KI-MOPC-Modulen in bestehende industrielle Informationssysteme wie ERP ist ein entscheidender Aspekt der Systemfunktionalität. Sie nutzen Middleware und Microservices für das Internet der Dinge (IoT), um die Echtzeitübertragung von Daten aus Maschinen zu erleichtern.

- Costa et al. (2025) demonstrieren eine softwarebasierte Architektur, bei der IoT-Geräte Daten an einen Kontextbroker senden; diese Daten werden sowohl AI-Modulen als auch Frontend-Clients zur Verfügung gestellt. Die Plattform nutzt Grafana für die Erstellung von Dashboards und stellt ein Backend für AR/VR-Schnittstellen bereit. Darüber hinaus liefert die Benutzeroberflächenkomponente den Benutzern mithilfe von Dashboards und interaktiven Anzeigen Erkenntnisse aus der künstlichen Intelligenz.
- Jüngste Studien haben Augmented Reality und Virtual Reality als innovative Schnittstellen für Wartungsanwendungen identifiziert. Beispielsweise legen KI-basierte Entscheidungssysteme den Schwerpunkt auf eine benutzerzentrierte Gestaltung, z. B. moderne UI-Module, die die Visualisierung wichtiger Kennzahlen, die Filterung von Wartungsdaten und die Einleitung klarer Maßnahmen erleichtern (Soori et al. 2024).

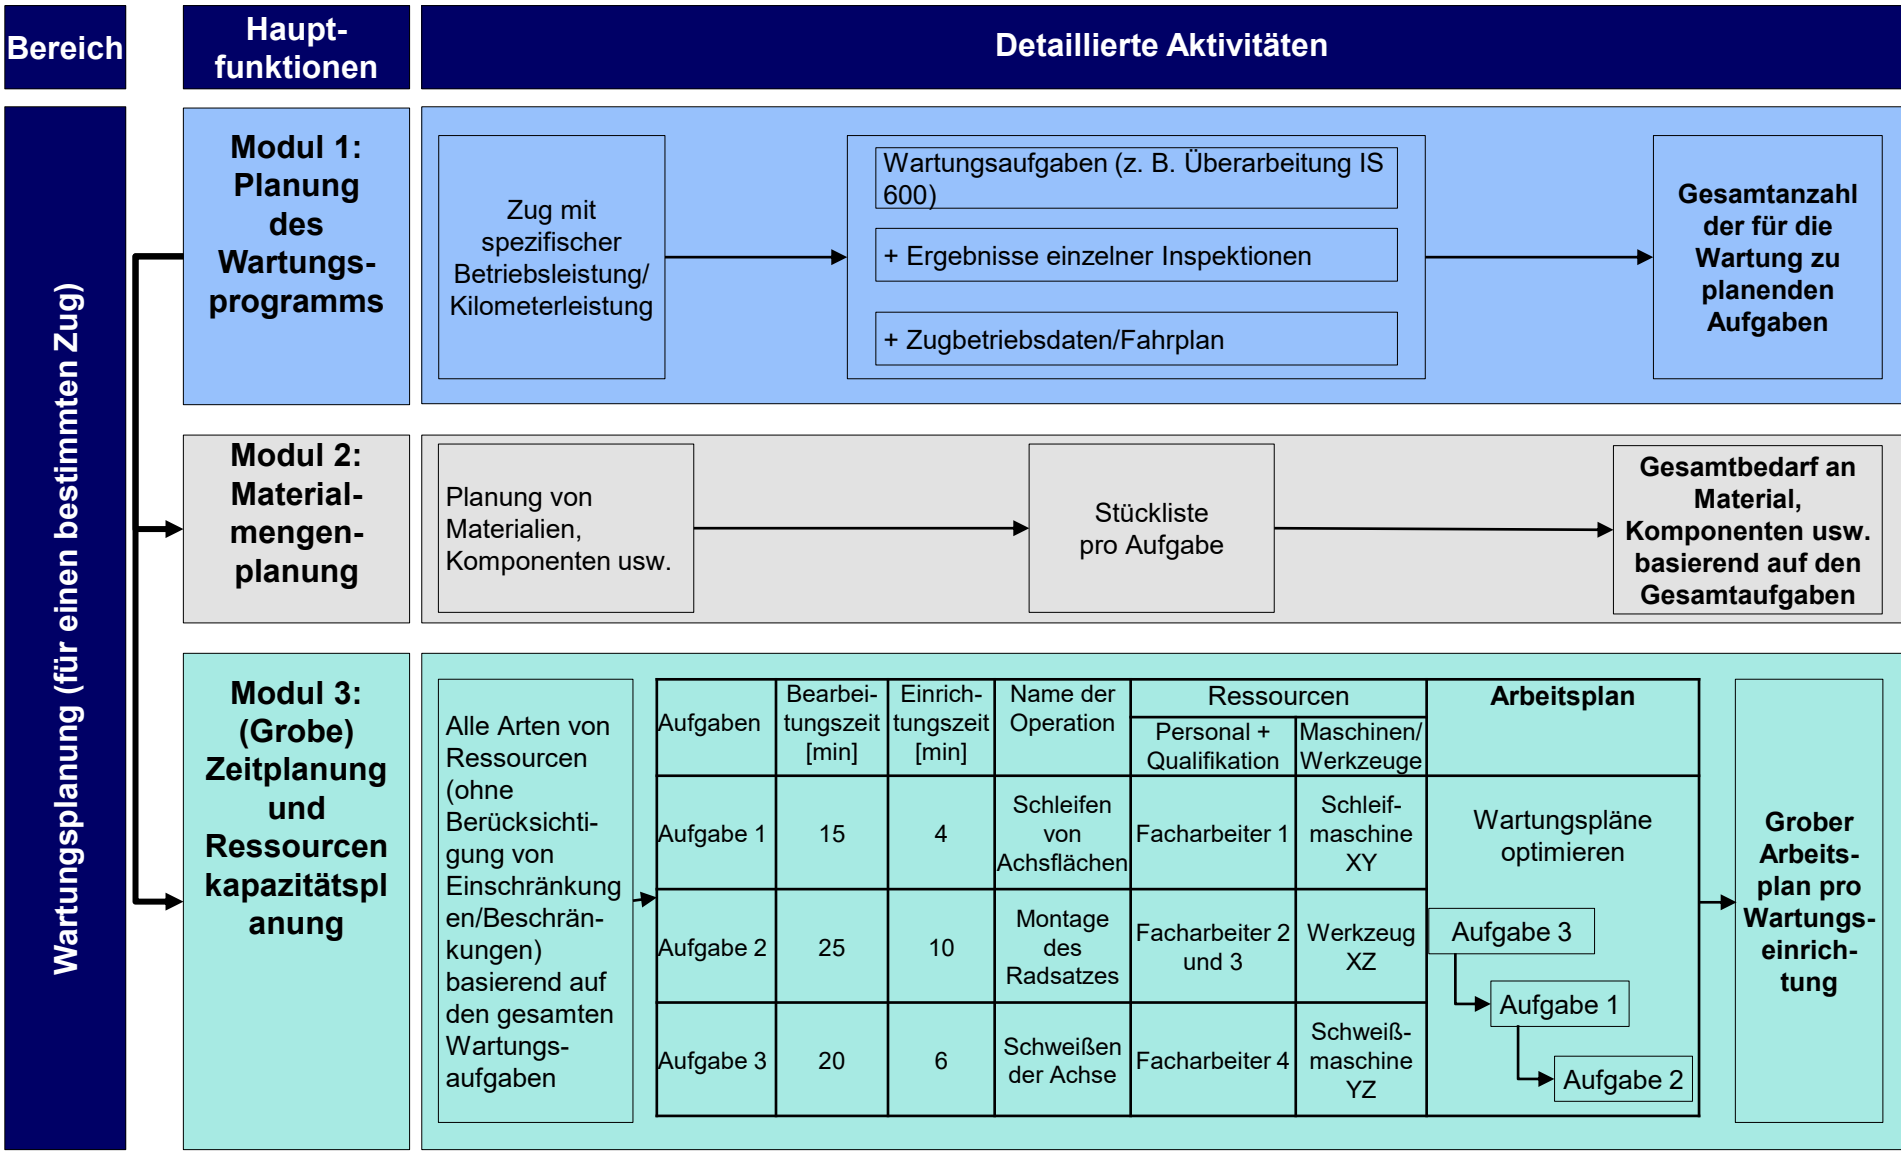
Quelle: Öhlinger et al. (2022), Soori et al. (2024), Costa et al. (2025)

KI-MOPC-Architektur für den Schieneninstandhaltungsworkshop





Konzeptionelles Modell von AI-MOPC für Bahnstandhaltungswerkstätten



Wartungskontrolle (in einer bestimmten Wartungseinrichtung)

Bereich | **Hauptfunktionen** | **Detaillierte Aktivitäten**

Modul 4: Auftragsplanung (in der Fertigung)

Verfügbare Ressourcen (unter Berücksichtigung aller möglichen Einschränkungen in der Fertigung)

Grober Arbeitsplan aus Modul 3

Aufgaben	Bearbeitungszeit [min]	Einrichtungszeit [min]	Name der Operation	Ressourcen		Auftragsplanung/ Umplanung
				Personal	Maschinen /Werkzeuge	
Aufgabe 1	15	4	Achsenflächen schleifen	Facharbeiter 1	Schleifmaschine XY	Optimierung der Wartungspläne/ Neuberechnung der Zeitpläne unter effizienter Nutzung der verfügbaren Ressourcen
Aufgabe 2	25	1	Montage des Radsatzes	Facharbeiter 2 und 3	Werkzeug XZ (nicht verfügbar)	
Aufgabe 3	20	6	Schweißen der Achse	Facharbeiter 4 (abwesend)	Schweißmaschine YZ	

Auftragsreihenfolge kurzfristig, z. B. täglich/ wöchentlich, um die Anforderungen zu erfüllen

Auftragsabwicklung

Modul 5: Auftragsüberwachung (in der Fertigung)

Verfolgung von Prozessen/Ergebnissen in der Fertigung

Vergleich der Planung mit dem tatsächlichen Auftragsstatus in der Fertigung

KPI-Analyse:

- Qualität
- Menge
- Zeit
- Kosten

Erkenntnisse aus dem konzeptionellen Rahmen

Das Hauptziel des vorgeschlagenen AI-MOPC-Systems in einer Eisenbahnwerkstatt ist es, Entscheidungsprozesse in den Bereichen Wartungsauftragsplanung und -steuerung in Echtzeit zu ermöglichen. Das vorgeschlagene Modell stellt eine bedeutende Weiterentwicklung gegenüber herkömmlichen Methoden dar, da es künstliche Intelligenz (KI)-gesteuerte Automatisierung, prädiktive Analysen und Echtzeitoptimierung nutzt. Dieses KI-gestützte System integriert die Wartungsplanung und -steuerung und verbessert gleichzeitig die Entscheidungsprozesse, wodurch Ausfallzeiten reduziert und eine optimale Ressourcennutzung in der Eisenbahnwerkstatt gewährleistet werden.

Gemäß dem vorgestellten Modell beginnt der Prozess mit den Ergebnissen einzelner Inspektionen. In dieser Phase werden die aus den Wartungsprotokollen und Inspektionen gesammelten Daten mit stochastischen Methoden analysiert, um die Wahrscheinlichkeit von Komponentenausfällen und Verschleißmustern zu bewerten. Die stochastische Analyse berücksichtigt Schwankungen der Betriebsbedingungen, Verschleiß und Unsicherheiten hinsichtlich der Lebensdauer von Komponenten, sodass Wartungspläne dynamisch angepasst werden können. Die aus der stochastischen Analyse abgeleiteten Ergebnisse dieser einzelnen Inspektionen werden in das Standardwartungsprogramm integriert. So wird sichergestellt, dass ein umfassender und gut dokumentierter Überblick über alle für den Zug erforderlichen Wartungsarbeiten verfügbar ist.

Sobald der Gesamtbedarf an Wartungsaufgaben ermittelt ist, wird die Materialmenge geplant, um sicherzustellen, dass die richtigen Materialien, Komponenten, Ersatzteile usw. für die auszuführenden Aufgaben verfügbar sind. Die Modelle der künstlichen Intelligenz können angewendet werden, um automatisch eine Stückliste (BOM) für jede Wartungsaufgabe zu erstellen, indem sie vergangene Wartungsaufzeichnungen, aktuelle Lagerbestände, Lieferzeiten der Lieferanten usw. analysieren. Sie können auch den zukünftigen Materialbedarf auf der Grundlage von erwarteten Ausfällen und geplanten Wartungsaufgaben vorhersagen und so die Lagerbestände optimieren und Verzögerungen aufgrund von Komponentenengpässen minimieren. Diese vorausschauende Bestandsverwaltung stellt sicher, dass die Wartungswerkstätten immer über die erforderlichen Materialien verfügen, ohne dass es zu Überbeständen kommt, wodurch Kosten und Verschwendung reduziert werden.

Für die erforderlichen Wartungsaufgaben werden KI-Algorithmen verwendet, um einen groben Arbeitsplan für die Wartungswerkstatt zu erstellen, ohne dabei Einschränkungen oder Beschränkungen in der Fertigung zu berücksichtigen. Der Ansatz besteht darin, Aufgaben dynamisch auf Mitarbeiter und Maschinen zu verteilen und gleichzeitig eine optimale Verteilung der Arbeitslasten sicherzustellen. Durch die Analyse früherer Effizienzdaten der Werkstatt optimiert die KI kontinuierlich die Zeitpläne, um Leerlaufzeiten zu minimieren und den Durchsatz zu verbessern. So entsteht ein dynamischer und hochoptimierter grober Arbeitsplan für die Wartungsanlage.

Erkenntnisse aus dem konzeptionellen Rahmen

Der Übergang von der Planung zur Ausführung wird durch eine ML-gesteuerte Auftragsplanung in der Fertigung erleichtert, die sich durch kontinuierliche Überwachung der Fertigungsbedingungen an Echtzeitbeschränkungen anpasst. Herkömmliche Ansätze zur Wartungsplanung haben Schwierigkeiten mit unerwarteten Ereignissen wie der Nichtverfügbarkeit von Werkzeugen oder der Abwesenheit von Mitarbeitern, was zu einer ineffizienten Umplanung führt. Im Gegensatz dazu können maschinelle Lernverfahren (d. h. verstärktes Lernen) solche Einschränkungen sofort erkennen und Aufgaben autonom neu zuweisen oder Zeitpläne in Echtzeit anpassen. Wenn beispielsweise ein wichtiges Werkzeug nicht verfügbar ist, identifiziert der RL-Agent alternative Werkzeuge oder Arbeitsstationen, um den Arbeitsablauf aufrechtzuerhalten. Ebenso identifiziert der RL-Agent bei Abwesenheit eines qualifizierten Mitarbeiters anderes qualifiziertes Personal oder plant Aufgaben neu, ohne den gesamten Wartungszeitplan zu stören. Diese Flexibilität ermöglicht es Werkstätten, auch bei unvorhergesehenen Störungen eine hohe Betriebseffizienz aufrechtzuerhalten.

Die vorgeschlagenen AI-MOPC-Systeme würden kontinuierlich Daten aus Wartungsvorgängen analysieren und mit dem geplanten Zeitplan vergleichen. Echtzeit-Tracking-Systeme werden eingesetzt, um den Fortschritt jedes Wartungsauftrags zu überwachen, sodass Wartungsmanager die tatsächlichen Ausführungszeiten mit den erwarteten Zeitplänen vergleichen können. Dieser Überwachungsprozess ermöglicht die sofortige Identifizierung von Verzögerungen oder Ineffizienzen und stellt sicher, dass Korrekturmaßnahmen ohne Unterbrechung des gesamten Arbeitsablaufs umgesetzt werden können. Darüber hinaus wird eine Leistungsbewertung auf der Grundlage bestimmter Leistungskennzahlen (KPIs) wie Qualität, Quantität, Aufgabenbearbeitungszeit und Kosten durchgeführt. Diese KPIs liefern wertvolle Erkenntnisse über die Effektivität der Wartungsarbeiten und ermöglichen es den Wartungsmanagern, datengestützte Entscheidungen zur kontinuierlichen Verbesserung zu treffen. Abweichungen vom geplanten Wartungszeitplan werden durch Ausgleichsmaßnahmen behoben, die eine Umplanung von Aufgaben, eine Neuzuweisung von Ressourcen oder eine Anpassung der Arbeitslastverteilung umfassen können, um die Betriebseffizienz aufrechtzuerhalten.

- | | | |
|----|--|----|
| 3. | Konzeptionelles Modell von AI-MOPC für die Eisenbahninstandhaltungswerkstatt | 50 |
| 4. | Erkenntnisse aus dem konzeptionellen Rahmen | 52 |

IV.	Verstärkendes Lernen in der Wartungsauftragsplanung und -steuerung	54
------------	---	-----------

- | | | |
|----|---|----|
| 1. | Suchstrategie für die Datenerfassung | 56 |
| 2. | Deskriptive Analyse der gesammelten Artikel | 57 |
| a) | Publikationstrends in diesem Bereich | 57 |
| b) | Analyse auf Grundlage der identifizierten Cluster | 58 |
| 4. | In diesem Forschungsbereich verwendete Modelle des verstärkenden Lernens | 62 |
| 5. | Konzeptioneller Rahmen für verstärktes Lernen in der Wartungsauftragsplanung und -steuerung | 63 |
| a) | Hauptfunktionen von Wartungsauftragsplanung und -steuerung | 64 |
| b) | Komponenten des verstärkenden Lernens | 66 |
| c) | Implementierungsüberlegungen zur Umsetzung | 67 |
| d) | Verstärkender Lern-Feedback-Loop | 68 |
| 6. | Erkenntnisse aus dem verstärkenden Lernen in der Wartungsauftragsplanung und -steuerung | 69 |

V.	Schlussfolgerung und Ausblick	70
-----------	--------------------------------------	-----------

Literaturverzeichnis	74
-----------------------------	-----------

Weitere Studienberichte des Lehrstuhls für Produktionswirtschaft	83
---	-----------


Der Status quo der KI in der Wartungsauftragsplanung und -steuerung (dargestellt anhand einer systematischen Literaturrecherche in Phase 1 des Studienberichts) zeigt, dass es eine umfangreiche Literatur gibt, die sich mit der Anwendung von Reinforcement Learning (RL) zur Optimierung von Wartungsaktivitäten in öffentlichen Verkehrsmitteln wie Zügen, Flugzeugen und Fahrzeugen befasst. Um den genauen Stand von RL in diesem Zusammenhang zu erfassen, wird ein systematischer Ansatz gewählt, um eine deskriptive Analyse seiner Verwendung im Bereich der Wartung öffentlicher Verkehrsmittel durchzuführen. Zunächst wurden relevante Forschungsartikel mithilfe einer effizienten und gut strukturierten Suchstrategie gesammelt, um eine umfassende Abdeckung des Themenbereichs sicherzustellen. Anschließend wurden die Veröffentlichungstrends untersucht, um das zeitliche Wachstum und das Forschungsinteresse in diesem Bereich zu verstehen. Anschließend wurden Keyword-Ko-Occurrences und Clusteranalysen verwendet, um wichtige Themenbereiche und Forschungsrichtungen zu identifizieren. Die bibliometrische Analyse ergab einen schnell wachsenden Trend zur Einführung von RL für verschiedene Wartungsaufgaben. Durch die Ko-Auftreten von Schlüsselwörtern und Clusteranalysen wurde die Literatur in fünf Themenbereiche kategorisiert, die die Forschungslandschaft widerspiegeln, nämlich (1) Deep RL für die Wartungsplanung, (2) RL und Modelltraining, (3) Wartungsoptimierung und Entscheidungsfindung, (4) Datenmodelle für die Systemsteuerung und vorausschauende Wartung und (5) Algorithmen für die Zuweisung von Wartungsressourcen.

Auf der Grundlage der Erkenntnisse aus der Untersuchung wird geschlossen, dass die derzeitige Implementierung von RL in der Instandhaltung zwar ihre Machbarkeit bewiesen hat, die bestehende Forschung jedoch RL nur für spezifische Probleme der Instandhaltungsplanung und -terminierung implementiert hat. Es gibt keine Forschungsarbeiten zum Einsatz von RL für die Planung und Steuerung von Wartungsaufträgen in einer speziellen Wartungswerkstatt für öffentliche Verkehrsmittel. In diesem Zusammenhang stellt dieser Artikel den Status quo vor und schlägt einen RL-basierten konzeptionellen Rahmen vor, um einen Fahrplan zu erstellen und die folgende Forschungsfrage zu beantworten: **Wie kann RL für die Planung und Steuerung von Wartungsaufträgen in Wartungswerkstätten für öffentliche Verkehrsmittel eingesetzt werden?**

Der Rahmen ist in drei Kerndimensionen gegliedert, nämlich MOPC-Funktionen, RL-Komponenten und Implementierungsüberlegungen. Er bietet einen klaren Fahrplan für die systematische Integration von RL in Wartungswerkstätten und deckt alle wesentlichen Planungs- und Steuerungsaufgaben wie Materialschätzung, Kapazitätsplanung, Auftragsplanung und Überwachung in der Fertigung ab.

Suchstrategie für die Datenerhebung

Merkmale der Suchzeichenfolge




Wichtigste Erkenntnisse

- Die Suchstrategie konzentrierte sich in erster Linie auf verstärktes Lernen und Wartung im öffentlichen Verkehr. Daher wurden in den Suchbegriff Schlüsselwörter aus den Bereichen verstärktes Lernen, Wartung und Verkehr aufgenommen.
- . Die Schlüsselwörter „verstärktes Lernen“ und „tiefes verstärktes Lernen“ wurden verwendet, um den technologischen Aspekt zu erfassen. Da tiefes verstärktes Lernen (DRL) eine weit verbreitete Form des verstärkenden Lernens ist, wurde es ausdrücklich als technologisches Schlüsselwort in den String aufgenommen.
- Um sicherzustellen, dass alle relevanten Sektoren abgedeckt sind, wurden neben den Namen der Sektoren auch Begriffe hinzugefügt, die die Verkehrsmittel bezeichnen, z. B. Flugzeug, Fahrzeug, Schiene.
- Es wurden nur englischsprachige Dokumente berücksichtigt, darunter Zeitschriftenartikel, Übersichtsartikel, Konferenzberichte und Buchkapitel, die in den letzten 10 Jahren veröffentlicht wurden.

Deskriptive Analyse der gesammelten Artikel | Publikationstrends in diesem Bereich

Publikationstrends



Wichtige Erkenntnisse

Erfasste Daten

- 167 Publikationen: 132 aus Web of Science, 35 aus Science Direct
- Ausschluss: 29 Duplikate, 4 vor 10 Jahren veröffentlichte Publikationen, 1 Leitartikel

Verteilung der Veröffentlichungen

- Gesamtzahl: 133
- Zeitschriftenartikel: 113
- Konferenzbeiträge: 20


Publikationstrend

- Der stetige Anstieg unterstreicht den raschen technologischen Fortschritt und das Interesse an der Anwendung von Reinforcement Learning für die Instandhaltung im öffentlichen Verkehr.

Beschreibende Analyse der gesammelten Artikel | Analyse auf der Grundlage identifizierter Cluster

Verteilung der Schlüsselwörter basierend auf Clustern

- Schlüsselwörter in Cluster 1
- Schlüsselwörter in Cluster 2
- Schlüsselwörter in Cluster 3
- Schlüsselwörter in Cluster 4
- Schlüsselwörter in Cluster 5




Cluster-Name

- Cluster 1: Tiefes Verstärkungslernen für die Wartungsplanung
- Cluster 2: Verstärkendes Lernen und Modelltraining
- Cluster 3: Wartungsoptimierung und Entscheidungsfindung
- Cluster 4: Datenmodelle für Systemsteuerung und vorausschauende Wartung
- Cluster 5: Algorithmen für die Zuweisung von Wartungsressourcen


Wichtigste Erkenntnisse

- Das gemeinsame Vorkommen von Schlüsselwörtern in den ausgewählten 113 Artikeln wurde untersucht.
- Es wurde ein Kriterium festgelegt, um nur Schlüsselwörter mit einer Häufigkeit von ≥ 3 auszuwählen. Durch dieses Kriterium wurden 70 von 758 Schlüsselwörtern mit der festgelegten Häufigkeitsschwelle gefunden.
- **Am häufigsten gemeinsam auftretende Schlüsselwörter:**
 - Verstärkendes Lernen – Vorkommen: 53, Gesamtlinkstärke: 163
 - Tiefes Verstärkungslernen – Vorkommen: 34, Gesamtlinkstärke: 58
 - Wartung – Vorkommen: 21, Gesamtverknüpfungsstärke: 110
- Die Optimierungen, die Systemsteuerung und die vorausschauende Wartung sind mit 22, 16 bzw. 8 Vorkommen auch die häufigsten Schlüsselwörter, die zusammen mit unserem Hauptsuchbegriff auftreten, sodass sie als die am häufigsten wiederkehrenden Begriffe in diesem Bereich angesehen werden können.

b-tu Brandenburgische
Technische Universität
Cottbus - Senftenberg



Beschreibende Analyse der gesammelten Artikel | Analyse auf der Grundlage identifizierter Cluster




Cluster 1: Tiefes verstärkendes Lernen für die Wartungsplanung

Dieser Cluster konzentriert sich auf Anwendungen von DRL zur Planung von Wartungsaufgaben. Repräsentativ für diesen Cluster sind Arbeiten wie der DRL-Ansatz für den Betrieb und die Wartung von UAV-Schwärmen, bei dem ein Agent die Aufgabenverteilung und Wartung für eine Drohnenflotte plant, um einen kontinuierlichen Betrieb sicherzustellen (L. Liu und Yang 2023). Mohammadi & He (2022) entwickelten eine DDQN-basierte Methode zur Optimierung langfristiger Wartungs- und Erneuerungspläne für Eisenbahnschienen unter Kosten- und Risikobeschränkungen. Eine weitere Arbeit nutzt DRL-Algorithmen sowohl für die Wegplanung einzelner Agenten zur Kollisionsvermeidung als auch für die Formationsteuerung mehrerer Agenten zur Aufrechterhaltung der Formation (Zhou et al. 2019). Jede dieser Arbeiten zeigt, wie DRL-Techniken optimale Wartungs- und Planungsrichtlinien in komplexen Domänen lernen und dabei Heuristiken in Bezug auf Kosteneffizienz und Systemzuverlässigkeit übertreffen.



Cluster 2: Verstärkendes Lernen und Modelltraining

Die Veröffentlichungen in diesem Cluster betonen methodische Innovationen beim Training von RL-Modellen für Wartungsprobleme. Chen et al. (2024) stellten beispielsweise einen expertengesteuerten Deep-RL-Ansatz für das Management eines Hybridfahrzeugantriebsstrangs vor, bei dem ein Fuzzy-Logik-Controller dem RL-Agenten Experten-Demonstrationen liefert (Chen et al. 2024). Eine weitere Studie integrierte überwachtes Lernen mit RL für die Wartung von Eisenbahnradern (Sresakoolchai, Ngamkhanong und Kaewunruen 2025). Die überwachte Komponente lernt, den Radverschleiß vorherzusagen, während die RL-Komponente optimale Wartungsmaßnahmen lernt. In einer anderen Arbeit wurde ein TD3-RL-Agent mit fortgeschrittenen Trainingstricks verbessert, die zu einem schnelleren Lernen und einer robusteren Richtlinie für die Nutzung von Batterien/Brennstoffzellen führten (Saba et al. 2025).




Cluster 3: Wartungsoptimierung und Entscheidungsfindung

Dieser Cluster konzentriert sich auf den Einsatz von RL zur Optimierung von Wartungsplänen und -entscheidungen. So haben beispielsweise Liu et al. (2022) ein Entscheidungsunterstützungsverfahren unter Verwendung von Q-Learning zur Optimierung der Wartungsplanung und anderer Lebenszyklusmaßnahmen vorgestellt, das an einem Fahrzeugproduktionsfall validiert wurde. In ähnlicher Weise formulieren Dai & Liang (2025) ein prioritätsgewichtetes Inspektionsplanungsproblem für die Wartung von Basisstationen und lösen es mit Hilfe von Algorithmen zur Suche in großen Nachbarschaften. Andere Studien berichten über Metriken wie reduzierte Ausfallzeiten, Kosteneinsparungen, höheren Durchsatz oder Verbesserungen der Zuverlässigkeit, die auf RL-basierte Wartungsrichtlinien zurückzuführen sind (Tham et al. 2023; S. S. Shuvo und Yilmaz 2020). Diese Arbeiten berücksichtigen auch praktische Überlegungen zur Umsetzung solcher RL-Entscheidungen, beispielsweise die Notwendigkeit des kontinuierlichen Lernens zur Anpassung an neue Daten und die Bedeutung der Erklärbarkeit in kritischen Wartungskontexten.

Quelle: L. Liu und Yang (2023), Mohammadi & He (2022), Zhou et al. (2019), Chen et al. (2024), Sresakoolchai et al. (2025), Saba et al. (2025), Liu et al. (2022), Dai & Liang (2025), Tham et al. 2023; S. S. Shuvo und Yilmaz 2020).

Beschreibende Analyse der gesammelten Artikel | Analyse auf der Grundlage identifizierter Cluster



Cluster 4: Datenmodelle für die Systemsteuerung und vorausschauende Wartung

Die Forschung in diesem Cluster konzentriert sich auf den Einsatz datengesteuerter künstlicher Intelligenz oder maschineller Lernmodelle zur Verbesserung der Systemsteuerung und zur Ermöglichung vorausschauender Wartung. Ein prominentes Beispiel ist die Untersuchung von Cavus et al., die hervorhebt, wie KI-Techniken, darunter tiefes Verstärkungslernen, das Batteriemanagement und die vorausschauende Wartung in Elektrofahrzeugen verbessern (Cavus, Dissanayake und Bell 2025). Ihre Arbeit zeigt, dass DRL-Steuerungen durch die Nutzung von IoT-Daten und genauen Modellen des Batteriezustands die Batterielebensdauer adaptiv verlängern und Wartungsmaßnahmen wie das Laden oder Austauschen proaktiv planen können. Darüber hinaus diskutieren Khan et al. digitale Zwillingmodelle für die Realisierung einer autonomen Wartung, bei der hochpräzise Simulationen mit Echtzeitdaten aktualisiert und mit RL gekoppelt werden, um Wartungsmaßnahmen direkt aus den Betriebsdaten zu planen (S. Khan et al. 2020).



Cluster 5: Algorithmen für die Zuweisung von Wartungsressourcen

Dieser Cluster umfasst Forschungen zu Algorithmen und Multi-Agenten-Systemen, die Wartungsressourcen wie Zeitfenster, Techniker, Ersatzteile usw. unter effizienter Nutzung von RL zuweisen. Viele dieser Studien formulieren Wartungsvorgänge als Multi-Agenten-Probleme oder komplexe Optimierungsaufgaben, die eine intelligente Planung begrenzter Ressourcen erfordern. Hao et al. stellen beispielsweise einen Multi-Agenten-Deep-RL-Algorithmus für kollaborative Kfz-Wartungsdienste vor, der Probleme der ungleichmäßigen Ressourcenverteilung und der Wartezeiten für Kunden in Wartungsketten-Dienstleistungsnetzwerken angeht (Hao et al. 2022). Eine andere Arbeit formuliert ein gemischt-ganzzahliges Modell, um gemeinsam zu entscheiden, welche Komponenten gewartet werden sollen und wie der Ersatzteilbestand zwischen den Einsätzen verwaltet werden soll, wobei ein benutzerdefinierter Algorithmus verwendet wird, um die Zuverlässigkeitsziele zu erfüllen und gleichzeitig die Gesamtwartungs- und Lagerkosten zu minimieren (Kong et al. 2024). In ähnlicher Weise befassen sich Shang et al. mit der Planung der Wartung verteilter Netzwerke mit einer stochastischen Monte-Carlo-Baumsuche-Methode zur Zuweisung von Wartungsmaßnahmen über einen Planungshorizont (Shang et al. 2020).

Quelle: Cavus, Dissanayake und Bell (2025), S. Khan et al. (2020), Hao et al. 2022), Kong et al. (2024), Shang et al. (2020)

In diesem Forschungsbereich verwendete Modelle des verstärkenden Lernens


Eine Vielzahl von Modellen des verstärkenden Lernens wurde bereits für die Instandhaltung von öffentlichen Verkehrsmitteln eingesetzt. Nachfolgend finden Sie eine Klassifizierung der in der Literatur am häufigsten verwendeten RL-Modelle. Im Allgemeinen lassen sich RL-Modelle in zwei Haupttypen einteilen: modellbasierte und modellfreie Ansätze. Beim modellbasierten RL wird ein Vorhersagemodell verwendet, um durch eine begrenzte Anzahl von Interaktionen mit der Umgebung eine Steuerungsstrategie abzuleiten. Der Agent erstellt aus diesen Interaktionen ein Modell und nutzt es, um Entscheidungen zu treffen und den Nutzen in zukünftigen Episoden zu maximieren (Shyalika, Silva und Karunananda 2020). Im Gegensatz dazu ermöglicht das modellfreie RL, auch als direktes Lernen bezeichnet, den Agenten, optimale Handlungen durch direkte Interaktion mit der Umgebung zu erlernen, ohne ein explizites Modell zu erstellen. Dies wird durch Versuch und Irrtum erreicht, sodass der Agent allein durch Erfahrung effektive Strategien entdecken kann. Modellfreie Ansätze unterstreichen die Flexibilität von RL bei der Anpassung an dynamische Umgebungen (M. A.-M. Khan et al. 2020). Unsere Literaturanalyse zeigt, dass sich der Großteil der Forschung auf modellfreie Ansätze konzentriert. Daher haben wir unsere Klassifizierungen auf modellfreies RL beschränkt.

Modellfreies RL wird weiter in wertbasiertes und richtlinienbasiertes RL unterteilt. Wertbasierte Modelle wie Q-Learning und Deep Q-Networks sind üblich für diskrete Wartungsentscheidungen, während richtlinienbasierte Methoden wie Proximal Policy Optimization und Deep Deterministic Policy Gradient für kontinuierliche oder multikriterielle Steuerungen verwendet werden. Neben den oben vorgestellten RL-Modellen gibt es mehrere Arbeiten, die Verbesserungen des Standard-RL zur Bewältigung domänenspezifischer Herausforderungen vorstellen. In Multi-Agenten-Wartungsumgebungen haben beispielsweise Algorithmen auf Basis der Wertzerlegung Erfolge gezeigt: Für die Koordination von Wartungsdiensten zwischen Kfz-Serviceagenten wurde ein kollaboratives, auf Bereitschaft basierendes Multi-Agenten-DRL entwickelt (Hao et al. 2022). Eine weitere fortschrittliche Technik ist das Meta-Reinforcement Learning, wie es in einer Studie zur aktiven Pantographsteuerung für Hochgeschwindigkeitszüge zu sehen ist: Ein Bayes-adaptiver Meta-RL-Algorithmus wurde eingeführt, um eine schnelle Anpassung an neue Umgebungen zu ermöglichen und damit die Einschränkung zu beheben, dass Standard-DRL bei veränderten Bedingungen umfangreiche Nachschulungen erfordert (H. Wang et al. 2024).

Verstärkungslernmodelle	
Wertbasierte Modelle für verstärktes Lernen	Richtlinienbasierte Modelle für verstärktes Lernen
Q-Lernen (Y. Liu, Yang und Guo 2022 ; Alzorgan et al. 2023)	Actor-Critic-Methoden (B. Wang et al. 2023 ; Hadi, Khosravi und Sarhadi 2024)
Tiefes Q-Lernen (DQN) (Figetakis et al. 2023 ; Kuan et al. 2020)	Tiefes deterministisches Politikgradientenverfahren (Ding, Gao und Shen 2020 ; L. Wang et al. 2024)
Double DQN (Mohammadi und He 2022 ; Jiang et al. 2025)	Proximal Policy Optimization (Tham et al. 2023 ; Zhao et al. 2022)
Monte Carlo (Lin et al. 2022 ; Sun et al. 2020)	

Konzeptioneller Rahmen für verstärktes Lernen in der Wartungsauftragsplanung und -steuerung

Ein konzeptioneller Rahmen für die RL-basierte Planung und Steuerung von Wartungsaufträgen für öffentliche Verkehrsbetriebe wurde vorgeschlagen. Der vorgeschlagene Rahmen besteht aus drei Dimensionen, nämlich den Hauptfunktionen des MOPC, den RL-Komponenten und der Umsetzung.



Konzeptioneller Rahmen für RL in MOPC | Hauptfunktionen von MOPC

In Industriezweigen wie der Automobilindustrie, der Luft- und Raumfahrt und der Elektronik besteht eine starke gegenseitige Abhängigkeit zwischen Produktion, Wartung und Qualität (Y. Wang et al. 2024). Insbesondere die Planung und Steuerung von Produktion und Wartung sind miteinander verbundene Konzepte und gehen Hand in Hand. Daher kann die Strategie für die Wartungsplanung und -steuerung in einer speziellen Wartungseinrichtung aus bestehenden Produktionsplanungs- und -steuerungssystemen übernommen werden. In diesem Zusammenhang werden die Funktionen der Wartungsplanung und -steuerung (MOPC) in Dimension 1 in Übereinstimmung mit den Grundfunktionen von PPC (Colangelo et al. 2022) abgeleitet.



**Wartungsprogramm-
planung**

Die Wartungsprogrammplanung umfasst die strukturierte Vorbereitung von Wartungsaufgaben auf der Grundlage vordefinierter Standards und Überarbeitungspläne. Beispielsweise müssen gemäß den Überarbeitungen der Deutschen Bahn bestimmte Wartungsarbeiten durchgeführt werden, nachdem ein Zug eine bestimmte Strecke oder bestimmte Zeiträume zurückgelegt hat (<https://www.bahnstatistik.de/AbkIS.Htm>, [https://de.wikipedia.org/wiki/Hauptuntersuchung_\(Bahn\)](https://de.wikipedia.org/wiki/Hauptuntersuchung_(Bahn))). Diese Standards gewährleisten Zuverlässigkeit und Sicherheit, indem sie obligatorische Wartungsarbeiten in bestimmten Intervallen festlegen. Darüber hinaus werden die Ergebnisse einzelner Inspektionen in die geplanten Wartungsaufgaben einbezogen, um potenzielle Ausfälle oder Leistungsprobleme zu beheben, die in den Standardwartungsplänen möglicherweise nicht berücksichtigt wurden. Das Endergebnis dieser Aufgaben ist eine gut dokumentierte und umfassende Übersicht über alle für den Zug erforderlichen Wartungsaufgaben.



**Materialmengen-
planung**

Die Materialmengengenauigkeit ist entscheidend, um sicherzustellen, dass alle erforderlichen Materialien und Komponenten vor Beginn des Wartungsprozesses verfügbar sind. Dies wird durch die Verwendung einer Wartungsstückliste erreicht, in der die Gesamtmenge jedes erforderlichen Artikels aufgeführt ist (M. Liu, Lai und Shen 2014). Unter Berücksichtigung der Lagerverfügbarkeit, der Vorlaufzeiten für die Beschaffung und möglicher Alternativen im Falle von Lieferkettenunterbrechungen wird eine umfassende Materialliste erstellt.

Quelle: Y. Wang et al. (2024), Colangelo et al. (2022), M. Liu, Lai und Shen (2014)

Konzeptioneller Rahmen für RL in MOPC | Hauptfunktionen von MOPC**Zeitplanung und
Kapazitätsplanung**

Die Zeitplanung und Ressourcenkapazitätsplanung konzentriert sich auf die Ermittlung und Zuweisung aller für Wartungsaktivitäten erforderlichen Ressourcen. Zu diesen Ressourcen gehören Personal, Personalqualifikationen und -fähigkeiten, Maschinen und Werkzeuge usw., die für bestimmte Wartungsaufgaben benötigt werden. Es wird ein grober Plan erstellt, um die Aufgaben in einer optimierten Reihenfolge zu logisch zu ordnen und so eine maximale Ressourcennutzung bei minimalen Leerlaufzeiten zu gewährleisten.

**Auftragsplanung**

Die Auftragsplanung umfasst die Zuweisung von Wartungsaufgaben in einer Weise, die die Ressourcennutzung in der Fertigung der Wartungseinrichtung optimiert. Dieser Planungsprozess berücksichtigt verschiedene Einschränkungen, wie z. B. die Verfügbarkeit von Maschinen, Schichtpläne und spezifische Einschränkungen in der Fertigung, die sich auf die Ausführung der Aufgaben auswirken können. Das Ziel der Auftragsplanung ist es, einen effizienten Wartungsplan zu erstellen, der eine nahtlose Ausführung der Aufgaben gewährleistet, ohne die Ressourcen zu überlasten.

**Auftragsüber-
wachung**

Die Auftragsüberwachung soll sicherstellen, dass die Wartungsausführung in der Fertigung mit dem geplanten Zeitplan übereinstimmt. Mithilfe von Echtzeit-Tracking-Systemen wird der Fortschritt jedes Wartungsauftrags überwacht, sodass Wartungsmanager den Ist-Zustand mit dem Plan vergleichen können. Die Leistungsbewertung erfolgt häufig auf der Grundlage von Leistungskennzahlen (KPIs) wie Qualität, Quantität, Aufgabenbearbeitungszeit und Kosten. Diese KPIs liefern wertvolle Erkenntnisse über die Effektivität der Wartungsmaßnahmen und ermöglichen es Managern, datengestützte Entscheidungen zur kontinuierlichen Verbesserung zu treffen.

Konzeptioneller Rahmen für RL in MOPC | Komponenten des verstärkenden Lernens

Bei der Planung und Steuerung von Wartungsaufträgen definieren Komponenten des verstärkenden Lernens (RL), d. h. Umgebung, Zustand, Aktion, Belohnung und Lernmethode, wie ein RL-Agent mit der Fertigung interagiert, welche Entscheidungen er treffen kann und welche Leistungskennzahlen er optimieren kann. Daher müssen diese Komponenten sorgfältig konzipiert werden, um die Dynamik der Wartungswerkstatt widerzuspiegeln.



**Grundlegende
Komponenten des RL**

Im vorgeschlagenen RL-basierten MOPC-Rahmenwerk stellt die Umgebung eine spezielle Wartungswerkstatt und deren Betriebskontext dar, z. B. ankommende Züge, Personal- und Maschinenkapazitäten. Bei jedem Entscheidungsschritt codiert der Zustand den aktuellen Status der Werkstatt, z. B. welche Wartungsaufträge anstehen, die verbleibende Zeit bis zum Fälligkeitsdatum der einzelnen Anlagen, die Verfügbarkeit von Ressourcen und die Lagerbestände. In einer der Fallstudien zum Eisenbahnbereich wurden beispielsweise 12 Zustandsmerkmale definiert, darunter Gleisgeometrieparameter wie Überhöhung, Ausrichtung, Spurweite usw. sowie die Anzahl der festgestellten Mängel (Sresakoolchai und Kaewunruen 2023). Die RL-Aktionen entsprechen Planungsentscheidungen in der Werkstatt: Zuweisung eines Wartungsauftrags an einen bestimmten Arbeitsstand, Planung oder Umanplanung von Aufgaben, Bestellung von Teilen oder Weiterleitung von Aufgaben innerhalb der Fertigung. Nach jeder Aktion wird die Belohnung berechnet, um die Qualität dieser Entscheidung widerzuspiegeln, wobei in der Regel das Ziel besteht, Ausfallzeiten zu minimieren und die Anlagenverfügbarkeit zu erhöhen.



RL-Algorithmen

Die Wahl des RL-Lernalgorithmus hängt vom Umfang und der Komplexität des Problems ab. Bei einfachen Problemen kann tabellarisches Q-Learning verwendet werden, bei komplexen Problemen ist jedoch eine Funktionsapproximation erforderlich. Daher verwenden die meisten aktuellen Arbeiten Deep RL, d. h. wertbasierte oder Policy-Gradient-Methoden (siehe Tabelle 3), um große Zustandsräume zu bewältigen. Deep-RL-Methoden helfen dabei, kontinuierlich bewertete Zustandsdarstellungen effizienter zu lernen als tabellarische Methoden. Während des Trainings simuliert oder beobachtet der Agent wiederholt die Werkstattumgebung, um Zustands-Aktions-Belohnungs-Übergänge zu sammeln, wobei Techniken wie Experience Replay oder Greedy Exploration zum Einsatz kommen (Silva et al. 2023).

Quelle: Sresakoolchai und Kaewunruen (2023), Silva et al. (2023)

Konzeptioneller Rahmen für RL in MOPC | Implementierungsüberlegungen zur Umsetzung

In der Praxis bedeutet die Implementierung von RL für MOPC, das Problem der Workshop-Planung in eine RL-Umgebung zu übertragen, mithilfe moderner RL-Bibliotheken Richtlinien zu entwickeln und das Ergebnis dann mit dem Wartungsinformationssystem zu verknüpfen.



Anwendungsbereich

Die Anwendungsbereiche umfassen alle Werkstätten für die Instandhaltung öffentlicher Verkehrsmittel, die mit großen Betriebsabläufen zu tun haben. Im Eisenbahnsektor verwalten nationale Betreiber wie die Deutsche Bahn Flotten mit Tausenden von Fahrzeugen; beispielsweise werden täglich etwa 40.000 Zugfahrten auf einem 33.000 Kilometer langen Streckennetz durchgeführt („<https://Nexocode.Com/Blog/Posts/Multi-Agent-in-Action-Michael-Kupper-on-Putting-Railway-Back-on-the-Fast-Track/>“). Daher müssen Werkstätten täglich Hunderte von Inspektionen/Reparaturen planen. Die Probleme sind also groß, der Handlungsspielraum wächst mit der Anzahl der Aufgaben und Ressourcen, und der Zustandsraum kann alle aktiven Aufträge, den Zustand der Anlagen und die Verfügbarkeit der Ressourcen umfassen.



Zustände

Darüber hinaus ist für die Umsetzung entscheidend, wie Zustände dargestellt werden. In Wartungswerkstätten umfasst der Zustand sowohl kontinuierliche Variablen, z. B. die verbleibende Nutzungsdauer von Komponenten, Lagerbestände usw., als auch diskrete Variablen, z. B. welche Aufträge aktiv sind, ob eine Maschine oder ein Werkzeug frei oder belegt ist und ob das entsprechende Personal verfügbar ist oder nicht. Daher ist häufig eine Mischung aus kontinuierlichem und diskretem Zustandsraum erforderlich.



RL-Softwaretools

In Bezug auf Softwaretools können Plattformen für maschinelles Lernen oder verstärktes Lernen, z. B. TensorFlow, PyTorch usw., verwendet und auch mit Simulationswerkzeugen oder sogar mit digitalen Zwillingen kombiniert werden. Die Kombination mit digitalen Zwillingen ist besonders nützlich, da eine der Studien gezeigt hat, dass die Integration von RL in einen digitalen Zwilling die Wartungsaktivitäten um 21 % und die auftretenden Fehler um 68 % reduzieren kann (Sresakoolchai und Kaewunruen 2023).




Bestehende Systeme

Schließlich benötigt der RL-Agent Datenfeeds aus Informationssystemen, z. B. SAP ISI, die bereits in Wartungswerkstätten implementiert sind. Sobald RL Planungsentscheidungen getroffen hat, gibt es die Ergebnisse an diese Systeme zurück. In der Praxis würde das trainierte RL-Modell im Hintergrund eines Planungstools laufen und Entscheidungen würden an der Schnittstelle des Wartungsinformationssystems angeboten werden.

Konzeptioneller Rahmen für RL in MOPC | Verstärkender Lern-Feedback-Loop

Feedback-Schleife des verstärkenden Lernens



Wichtige Erkenntnisse

- Die Rückkopplungsschleife des verstärkenden Lernens wurde formuliert, um einen Überblick darüber zu geben, wie ein RL-Agent mit der Umgebung der Wartungswerkstatt interagiert, um die Planungsentscheidungen kontinuierlich zu verbessern.
- In einer RL-Formulierung wird die Wartungswerkstatt als Umgebung betrachtet, die Planungs- oder Dispositionsentscheidungen sind die Aktionen und der Status des Systems, z. B. aktuelle Aufträge, Zeitpläne und Ressourcenverfügbarkeit, bilden den Zustand.
- Der Entscheidungsagent beobachtet den Zustand und wählt Wartungsplanungsmaßnahmen aus, wie z. B. die Zuweisung eines Auftrags zu einer Maschine oder die Neuordnung von Aufgaben in jedem Schritt.
- Nach jeder Aktion wechselt die Umgebung in einen neuen Zustand, z. B. einen aktualisierten Zeitplan und Ressourcenstatus, und gibt ein Belohnungssignal aus, das das Ergebnis widerspiegelt, z. B. eine positive Belohnung für die Verkürzung der Durchlaufzeit oder die Verbesserung der Anlagenverfügbarkeit.

Erkenntnisse aus dem verstärkenden Lernen in der Wartungsauftragsplanung und -steuerung

In Bezug auf die auf verstärktem Lernen basierende Wartungsauftragsplanung und -steuerung im öffentlichen Verkehrssektor bietet dieser Bericht einen umfassenden Überblick und konzeptionelle Überlegungen. Zunächst haben wir eine systematische deskriptive Analyse durchgeführt, die die Landschaft der RL-Anwendungen in der Wartung von öffentlichen Verkehrssystemen, d. h. in den Bereichen Schiene, Luftfahrt und Automobil, kartiert hat. Die bibliometrische Analyse ergab einen wachsenden Trend zur Einführung von RL in den letzten sechs Jahren. Anhand von Keyword-Ko-Occurrence und Clusteranalyse wurde die Literatur in fünf Themenbereiche kategorisiert, die die Forschungslandschaft widerspiegeln: Deep RL für die Wartungsplanung, RL und Modelltraining, Wartungsoptimierung und Entscheidungsfindung, Datenmodelle für die Systemsteuerung und vorausschauende Wartung sowie Algorithmen für die Zuweisung von Wartungsressourcen. Eine Taxonomie modellfreier RL-Techniken verdeutlicht darüber hinaus, dass Deep-Reinforcement-Learning-Methoden aufgrund ihrer Fähigkeit, komplexe, dynamische Umgebungen ohne explizite Modellierung zu bewältigen, zunehmend an Bedeutung gewinnen.

Aufbauend auf diesen Erkenntnissen wurde in der Arbeit ein konzeptioneller RL-basierter MOPC-Rahmen vorgeschlagen, der in Wartungswerkstätten für den öffentlichen Nahverkehr implementiert werden kann. Der Rahmen ist in drei Kerndimensionen gegliedert: MOPC-Funktionen, RL-Komponenten und Implementierungsaspekte. Er bietet einen klaren Fahrplan für die systematische Integration von RL in Wartungswerkstätten und deckt alle wesentlichen Planungs- und Steuerungsaufgaben wie Materialschätzung, Kapazitätsplanung, Auftragsplanung und Überwachung in der Fertigung ab. Wichtig ist, dass das Framework die dynamische Interaktion zwischen dem RL-Agenten und der Werkstattumgebung betont. Dies wird durch eine detaillierte RL-Feedbackschleife operationalisiert, in der der Agent den Echtzeitstatus der Wartungsvorgänge (z. B. Auftragsstatus, Ressourcenverfügbarkeit) beobachtet, Planungs- oder Dispositionsmaßnahmen durchführt und Belohnungssignale auf der Grundlage wichtiger Leistungskennzahlen wie Vorlaufzeitverkürzung und Ressourcenauslastung erhält.

Im Laufe der Zeit lernt der RL-Agent, mit gängigen Einschränkungen in der Fertigung umzugehen, wie z. B. Ressourcenkapazitäten, Maschinenverfügbarkeit und Schichtmodelle, und verbessert so die Planungseffizienz unter diesen Einschränkungen. Studien haben gezeigt, dass RL-basierte Wartungsrichtlinien in komplexen Planungsszenarien tatsächlich besser abschneiden als herkömmliche Heuristiken und einen höheren Durchsatz und eine bessere Ressourcenauslastung erzielen. Studien berichten, dass RL-Algorithmen im Kontext der Flugzeugwartungsplanung effizientere Wartungsrichtlinien mit besserer Leistung als Heuristiken gefunden haben (Andrade et al. 2021; Mattila und Virtanen 2011). Ein wesentlicher Vorteil des RL-Ansatzes ist seine Fähigkeit, dynamische Veränderungen zu bewältigen: Einmal trainiert, kann sich ein RL-Agent an Veränderungen anpassen, ohne dass eine vollständige Neuoptimierung von Grund auf erforderlich ist, da er seine Entscheidungen mit jedem neuen Zustand kontinuierlich verfeinert. Wenn beispielsweise ein wichtiges Gerät ausfällt, kann der RL-Agent ausstehende Aufträge auf alternative Maschinen umplanen oder Aufgaben neu ordnen, um Ausfallzeiten zu minimieren, und so den Wartungsprozess effektiv neu planen, damit er im Zeitplan bleibt. Ebenso kann der Agent lernen, eine Reparatur mit hoher Priorität in den Zeitplan einzufügen, ohne andere laufende Aufgaben zu beeinträchtigen.

3.	Konzeptionelles Modell von AI-MOPC für die Eisenbahninstandhaltungswerkstatt	50
4.	Erkenntnisse aus dem konzeptionellen Rahmen	52
IV.	Verstärkendes Lernen in der Wartungsauftragsplanung und -steuerung	54
1.	Suchstrategie für die Datenerfassung	56
2.	Deskriptive Analyse der gesammelten Artikel	57
a)	Publikationstrends in diesem Bereich	57
b)	Analyse auf Grundlage der identifizierten Cluster	58
4.	In diesem Forschungsbereich verwendete Modelle des verstärkenden Lernens	62
5.	Konzeptioneller Rahmen für verstärktes Lernen in der Wartungsauftragsplanung und -steuerung	63
a)	Hauptfunktionen von Wartungsauftragsplanung und -steuerung	64
b)	Komponenten des verstärkenden Lernens	66
c)	Implementierungsüberlegungen zur Umsetzung	67
d)	Verstärkender Lern-Feedback-Loop	68
6.	Erkenntnisse aus dem verstärkenden Lernen in der Wartungsauftragsplanung und -steuerung	69
V.	Schlussfolgerung und Ausblick	70
	Literaturverzeichnis	74
	Weitere Studienberichte des Lehrstuhls für Produktionswirtschaft	83

Zusammenfassend lässt sich sagen, dass diese systematische Literaturrecherche einen umfassenden Überblick über künstliche Intelligenz und maschinelles Lernen in der Wartungsplanung und -steuerung im öffentlichen Nahverkehr gegeben hat. Die systematische Recherche hat mehrere wichtige Erkenntnisse, neue Trends und Anwendungsmöglichkeiten von KI für die Wartungsplanung und -steuerung im öffentlichen Nahverkehr aufgezeigt. Erstens zeigt die deskriptive Analyse, dass das Forschungsvolumen in diesem Bereich in den letzten zehn Jahren stetig gewachsen ist, was auf ein zunehmendes Interesse an diesem Forschungsgebiet hindeutet. Wir haben festgestellt, dass sich ein großer Teil der Studien auf KI in prädiktiven und zustandsorientierten Instandhaltungsansätzen konzentriert, um Ausfälle von Anlagen vorherzusagen bzw. deren Zustand zu überwachen. Die Instandhaltungsplanung und -terminierung sind das dominierende Thema in diesen Arbeiten, was dem allgemeinen Bestreben entspricht, Ausfallzeiten zu minimieren und Ausfälle durch bessere Erkenntnisse zu vermeiden.

Zweitens zeigt unsere Clusteranalyse hinsichtlich der verwendeten KI-Techniken, dass keine einzelne Methode den Bereich dominiert, sondern dass eine Vielzahl von Ansätzen ausprobiert und oft kombiniert werden. Reinforcement Learning hat Aufmerksamkeit für die Formulierung von Wartung als sequentielles Entscheidungsproblem gewonnen und ist insbesondere in Wartungsplanungsszenarien vielversprechend. Deep Learning wurde aufgrund seiner Fähigkeit, komplexe Muster in Sensordaten zu modellieren, für viele vorausschauende Wartungsaufgaben eingesetzt. Klassische Methoden des maschinellen Lernens (wie SVMs, Random Forests und Bayes'sche Modelle) werden für die Fehlerdiagnose, die Vorhersage der Restlebensdauer und die Wartungsplanung verwendet. Darüber hinaus verwenden eine Reihe von Artikeln hybride Ansätze, beispielsweise die Kombination physikalischer Modelle mit KI zur Unterstützung von Wartungsarbeiten.

Aus der Analyse der Anwendungsbereiche haben wir schließlich festgestellt, dass KI-gesteuerte Wartung in den Bereichen Luftfahrt, Eisenbahn und Automobil erhebliche Vorteile bietet, darunter eine verbesserte Fehlerprognose, eine optimierte Wartungsplanung, reduzierte Ausfallzeiten und eine verbesserte Entscheidungsunterstützung für die Wartung. Die Analyse der Anwendungsbereiche zeigt, dass es zwar gemeinsame Themen im Bereich der Wartung gibt, jeder Sektor jedoch auch seine eigenen Prioritäten hat. In der Luftfahrt drehen sich KI-Anwendungen häufig um hochpräzise Prognosen für kritische Komponenten und die Optimierung von Flottenwartungsplänen, um unplanmäßige Flugausfälle zu vermeiden. Der Luftfahrtsektor hat auch erklärbare KI untersucht, um das Vertrauen in automatisierte Entscheidungshilfen für die Wartungsplanung aufrechtzuerhalten. Im Eisenbahnsektor konzentrieren sich die meisten Arbeiten auf sensorbasierte Zustandsüberwachung und Fehlererkennung sowie auf Planungsmodelle, die Wartungstermine rund um den Zugbetrieb planen. Im Automobilsektor liegt der Schwerpunkt auf der Nutzung von Fahrzeugdaten zur Implementierung vorausschauender Wartungsmaßnahmen, mit denen die Betriebskosten gesenkt werden können.

V. Schlussfolgerung und Ausblick


Trotz der Fortschritte in diesem Forschungsbereich gibt es kein spezielles System für die Wartungsplanung und -steuerung. Der Großteil der Forschung konzentriert sich auf einzelne Aspekte, wie z. B. die Vorhersage der RUL, Fehlerdiagnosen, Entscheidungshilfesysteme für Reparatur und Austausch usw. In der Praxis umfasst die Wartungsplanung und -steuerung jedoch eine komplexe Koordination vieler Aktivitäten (z. B. Inspektion, Ermittlung des Material- und Komponentenbedarfs, Ressourcenzuweisung sowie Personal- und Aufgabenplanung usw.). Daher sind die Autoren der Ansicht, dass ganzheitlichere Lösungen erforderlich sind, die Instandhaltungsaktivitäten und Fertigungsbeschränkungen integrieren und über die Vorhersage einzelner Komponenten hinaus zur Optimierung der Instandhaltung auf Systemebene führen. Ein solches System zur Instandhaltungsplanung und -steuerung könnte Instandhaltungsmanager bei der End-to-End-Planung (von der Erkennung eines Bedarfs bis zur Planung und Durchführung der Instandhaltung) unterstützen und in realen Instandhaltungsanlagen validiert werden.

Aufbauend auf diesen Erkenntnissen aus der Literaturrecherche haben wir einen konzeptionellen Rahmen für ein künstliche Intelligenz-basiertes System zur Wartungsauftragsplanung und -steuerung (AI-MOPC) für den Eisenbahnsektor vorgeschlagen, wobei der Schwerpunkt auf der Anwendung in Zugwartungswerkstätten liegt. Das vorgeschlagene AI-MOPC ist in vier Schichten gegliedert: Datenmodelle, KI-Algorithmen, Entscheidungsmodule sowie Integration und Benutzeroberfläche. Das Modell bietet eine umfassende Wartungsplanung sowie eine Steuerung in der Fertigung, indem es nicht nur potenzielle Ausfälle prognostiziert, sondern auch die Ressourcenzuweisung und die Ausführungsreihenfolge auf der Grundlage des tatsächlichen Status der Werkstatt dynamisch anpasst. Dieser Rahmen bietet eine grundlegende Strategie für den Eisenbahnsektor zur Modernisierung seiner Wartungsplanungsverfahren durch den Einsatz von KI. Zusammenfassend lässt sich sagen, dass das AI-MOPC-Framework einen Fahrplan für intelligente Echtzeit-Wartungssysteme bietet, die Ineffizienzen erheblich reduzieren, die Planung verbessern und letztendlich eine zeitnahe, kostengünstige Wartungsplanung und -steuerung für Züge unterstützen können. Insgesamt ermöglicht das vorgeschlagene AI-MOPC-Framework nicht nur eine intelligente Planung, sondern erleichtert auch die Ausführung, Überwachung und kontinuierliche Verbesserung der Zugwartungsarbeiten. Durch seine mehrschichtige Architektur würde das AI-MOPC-Modell den Einsatz in Eisenbahnwartungswerkstätten erleichtern und könnte auch auf andere Bereiche des öffentlichen Verkehrs wie Luftfahrt und Busse angepasst werden.

Darüber hinaus wurde in dieser Arbeit ein konzeptionelles RL-basiertes MOPC-Framework vorgeschlagen, das in Wartungswerkstätten des öffentlichen Nahverkehrs implementiert werden kann. Das Framework ist in drei Kerndimensionen gegliedert: MOPC-Funktionen, RL-Komponenten und Implementierungsaspekte. Es bietet einen klaren Fahrplan für die systematische Integration von RL in Wartungswerkstätten und deckt alle wesentlichen Planungs- und Steuerungsaufgaben wie Materialschätzung, Kapazitätsplanung, Auftragsplanung und Überwachung in der Fertigung ab. Wichtig ist, dass das Framework die dynamische Interaktion zwischen dem RL-Agenten und der Werkstattumgebung betont. Dies wird durch eine detaillierte RL-Feedbackschleife operationalisiert, in der der Agent den Echtzeitstatus der Wartungsvorgänge (z. B. Auftragsstatus, Ressourcenverfügbarkeit) beobachtet, Planungs- oder Dispositionsmaßnahmen durchführt und Belohnungssignale auf der Grundlage von Leistungskennzahlen wie Vorlaufzeitverkürzung und Ressourcenauslastung erhält. Im Laufe der Zeit lernt der Agent, Planungsentscheidungen zu optimieren, sich an die Einschränkungen in der Fertigung anzupassen und die Gesamteffizienz der Anlage zu verbessern.

V. Schlussfolgerung und Ausblick

Als zukünftige Arbeit kann das vorgeschlagene AI-MOPC-Framework vom Konzept zur praktischen Umsetzung erweitert werden. Um die Wirksamkeit des vorgeschlagenen Modells zu validieren, sind Tests in realen Zugwartungswerkstätten unerlässlich. Zu diesem Zweck wäre eine designwissenschaftliche Forschungsmethodik gut geeignet, da sie die Verfeinerung der Datenanforderungen, die Berücksichtigung von Systemintegrationsanforderungen und die iterative Verbesserung des Modells auf der Grundlage von Rückmeldungen der Stakeholder ermöglicht.



3.	Konzeptionelles Modell von AI-MOPC für die Eisenbahninstandhaltungswerkstatt	50
4.	Erkenntnisse aus dem konzeptionellen Rahmen	52
IV.	Verstärkendes Lernen in der Wartungsauftragsplanung und -steuerung	54
1.	Suchstrategie für die Datenerfassung	56
2.	Deskriptive Analyse der gesammelten Artikel	57
a)	Publikationstrends in diesem Bereich	57
b)	Analyse auf Grundlage der identifizierten Cluster	58
4.	In diesem Forschungsbereich verwendete Modelle des verstärkenden Lernens	62
5.	Konzeptioneller Rahmen für verstärktes Lernen in der Wartungsauftragsplanung und -steuerung	63
a)	Hauptfunktionen von Wartungsauftragsplanung und -steuerung	64
b)	Komponenten des verstärkenden Lernens	66
c)	Implementierungsüberlegungen zur Umsetzung	67
d)	Verstärkender Lern-Feedback-Loop	68
6.	Erkenntnisse aus dem verstärkenden Lernen in der Wartungsauftragsplanung und -steuerung	69
V.	Schlussfolgerung und Ausblick	70
	Literaturverzeichnis	74
	Weitere Studienberichte des Lehrstuhls für Produktionswirtschaft	83

- Aeddula, Omsri, Martin Frank, Ryan Ruvald, Christian Johansson Askling, Johan Wall und Tobias Larsson. 2024. „KI-gesteuerte vorausschauende Wartung für autonome Fahrzeuge zur Entwicklung von Produkt-Service-Systemen.“ *Procedia CIRP* 128:84–89.
- Albakay, Naji, Michael Hempel und Hamid Sharif. 2019. „Big Data Analytics for Proactively Optimizing Rolling Stock Maintenance.“ In , 58523:V001T06A005. American Society of Mechanical Engineers.
- Alzorgan, H, A Razi, AJ Moshayedi und IEEE. 2023. „Invited Paper: Aktuator-Trajektorienplanung für UAVs mit Überkopfmanipulator unter Verwendung von verstärktem Lernen.“ In *Clemson University*. <https://doi.org/10.1109/PIMRC56721.2023.10293891>.
- Andrade, Pedro, Catarina Silva, Bernardete Ribeiro und Bruno F Santos. 2021. „Aircraft Maintenance Check Scheduling Using Reinforcement Learning.“ *Aerospace* 8 (4): 113.
- Bukhsh, Zaharah Allah, Aaqib Saeed, Irina Stipanovic und Andre G Doree. 2019. „Vorausschauende Wartung mithilfe baumbasierter Klassifizierungstechniken: Ein Fallbeispiel aus dem Bereich Eisenbahnweichen.“ *Transportation Research Part C: Emerging Technologies* 101:35–54.
- Cavus, M., D. Dissanayake und M. Bell. 2025. „Elektrofahrzeuge der nächsten Generation: KI-gesteuerte Ansätze für vorausschauende Wartung und Batteriemanagement.“ *ENERGIES* 18 (5).
- Chaudhuri, A, und SK Ghosh. 2024. „Vorausschauende Wartung von Fahrzeugflotten durch hybride, auf Deep Learning basierende Ensemble-Methoden für industrielle IoT-Datensätze.“ *LOGIC JOURNAL OF THE IGPL* 32 (4): 671–87.
- Chen, Chong, Ying Liu, Xianfang Sun, Carla Di Cairano-Gilfedder und Scott Titmus. 2021. „Ein integrierter Deep-Learning-basierter Ansatz für die Vorhersage von Fahrzeugwartungen mit GIS-Daten.“ *Reliability Engineering & System Safety* 216:107919.
- Chen, FJ, BW Wang, M Ni, ZC Gong und K Jiao. 2024. „Online-Energiemanagementstrategie für Ammoniak-Wasserstoff-Hybrid-Elektrofahrzeuge unter Nutzung von Deep Reinforcement Learning.“ *ENERGY* 301.
- Colangelo, Eduardo, Christian Fries, Theresa-Franziska Hinrichsen, Ádám Szaller und Gábor Nick. 2022. „Reifegradmodell für KI in intelligenten Produktionsplanungs- und Steuerungssystemen.“ *Procedia CIRP* 107:493–98.
- Coleman, Chris, S Damofaran und Ed Deuel. 2017. „Predictive Maintenance and the Smart Factory.“ *Deloitte Consulting LLP*.
- Consilvio, Alice, Giulia Vignola, Paula López Arévalo, Federico Gallo, Marco Borinato und Carlo Crovetto. 2024. „Ein datengesteuertes Priorisierungssystem zur Minderung der Auswirkungen von Wartungsarbeiten auf Fahrgäste während des U-Bahn-Betriebs.“ *European Transport Research Review* 16 (1): 6.
- Costa, André, João Miranda, Duarte Dias, Nuno Dinis, Luís Romero und Pedro Miguel Faria. 2025. „Intelligente Wartungslösungen: AR- und VR-gestützter digitaler Zwilling auf Basis von FIWARE.“ *Sensors (Basel, Schweiz)* 25 (3): 845.
- Dang, Huong N., KC Chang, Genshe Chen, Hua-mei Chen, Simon Khan, Milvio Franco und Erik Blasch. 2024. „Verbesserung der Transparenz der zustandsorientierten Instandhaltung durch kausale Erklärungen: Eine Fallstudie zur Flugzeugwartungsplanung.“ In , 222–29. IEEE.

- Dai, XQ und ZL Liang. 2025. „Parallel Inspection Route Optimization With Priorities for 5G Base Station Networks” (Parallele Optimierung von Inspektionsrouten mit Prioritäten für 5G-Basisstationsnetze). IEEE TRANSACTIONS ON AUTOMATION SCIENCE AND ENGINEERING 22:10860–70.
- Dangut, Maren David, Zakwan Skaf und Ian K Jennions. 2022. „Handhabung unausgewogener Daten für die vorausschauende Wartung von Flugzeugen unter Verwendung des BACHE-Algorithmus.“ Applied Soft Computing 123:108924.
- Davari, Narjes, Bruno Veloso, Rita P Ribeiro, Pedro Mota Pereira und João Gama. 2021. „Vorausschauende Wartung auf Basis von Anomalieerkennung unter Verwendung von Deep Learning für Luftproduktionsanlagen in der Eisenbahnindustrie.“ In , 1–10. IEEE.
- Demidova, LA. 2020. „Konfigurationen rekurrenter neuronaler Netze in der vorausschauenden Wartung.“ In , 714:012005. IOP Publishing.
- Ding, RJ, FF Gao und XM Shen. 2020. „3D-UAV-Trajektorien- und Frequenzbandzuweisung für energieeffiziente und faire Kommunikation: Ein Ansatz mit tiefem verstärkendem Lernen.“ IEEE TRANSACTIONS ON WIRELESS COMMUNICATIONS 19 (12): 7796–7809.
- Famurewa, Stephen Mayowa, Liangwei Zhang und Matthias Asplund. 2017. „Wartungsanalysen zur Unterstützung von Entscheidungen im Bereich der Eisenbahninfrastruktur.“ Journal of Quality in Maintenance Engineering 23 (3): 310–25.
- Ferdous, Raihana, Giorgio Spagnolo, Alessandro Borselli, Lucio Rota und Alessio Ferrari. 2024. „Identifizierung von Wartungsbedarf mit maschinellem Lernen: Eine Fallstudie im Eisenbahnbereich.“ In , 22–25. IEEE.
- Figetakis, E., Y. Bello, A. Refaey, L. Lei, M. Moussa und IEEE. 2023. „Implicit Sensing in Traffic Optimization: Advanced Deep Reinforcement Learning Techniques.“ In University of Guelph, 1042–47.
- Gao, Shulin, Thorsten Szugs und Ralf Ahlbrink. 2018. „Verwendung kombinierter Datenquellen aus der Eisenbahnspektion zur Charakterisierung der Rollkontaktmüdung.“ In .
- Gerum, Pedro Cesar Lopes, Ayca Altay und Melike Baykal-Gürsoy. 2019. „Datengesteuerte vorausschauende Wartungsplanungsrichtlinien für Eisenbahnen.“ Transportation Research Part C: Emerging Technologies 107:137–54.
- Giobergia, Flavio, Elena Baralis, Maria Camuglia, Tania Cerquitelli, Marco Mellia, Alessandra Neri, Davide Tricarico und Alessia Tuninetti. 2018a. „Mining Sensor Data for Predictive Maintenance in the Automotive Industry.“ In , 351–60. IEEE.
- Giordano, D., F. Giobergia, E. Pastor, A. La Macchia, T. Cerquitelli, E. Baralis, M. Mellia und D. Tricarico. 2022. „Datengesteuerte Strategien für die vorausschauende Wartung: Erkenntnisse aus einem Anwendungsfall in der Automobilindustrie.“ COMPUTERS IN INDUSTRY 134 (Januar). <https://doi.org/10.1016/j.compind.2021.103554>.
- Giordano, Danilo, Flavio Giobergia, Eliana Pastor, Antonio La Macchia, Tania Cerquitelli, Elena Baralis, Marco Mellia und Davide Tricarico. 2022. „Datengesteuerte Strategien für die vorausschauende Wartung: Erkenntnisse aus einem Anwendungsfall in der Automobilindustrie.“ Computers in Industry 134:103554.
- Gong, LL, A Sharma, MA Bhuiya, H Awad und MZ Youssef. 2023. „Eine adaptive Fehlerdiagnose für Elektrofahrzeuge: Eine Methodik zur Signalverarbeitung mit künstlicher Intelligenz.“ IEEE CANADIAN JOURNAL OF ELECTRICAL AND COMPUTER ENGINEERING 46 (3): 196–206. <https://doi.org/10.1109/ICJECE.2023.3264852>.

- Gugaratshan, Guga, Dakota Barthlow, Dan Lingenfelter und Balaje Thumati. 2023. „Maschinell lernbasierte Ram-Analyse unter Verwendung multivariater Sensordaten.“ In , 1–6. IEEE.
- Hadi, B, A Khosravi und P Sarhadi. 2024. „Adaptive Formation Motion Planning and Control of Autonomous Underwater Vehicles Using Deep Reinforcement Learning.“ IEEE JOURNAL OF OCEANIC ENGINEERING 49 (1): 311–28.
- Hao, SG, J Zheng, J Yang, ZW Ni, QX Zhang und L Zhang. 2022. „Ein Multi-Agent-Netzwerk für die Zusammenarbeit auf Basis von Deep Reinforcement Learning für die Wartung von Kraftfahrzeugen.“ In Beijing Institute of Technology, herausgegeben von J Zhou, S Adepu, C Alcaraz, L Batina, E Casalicchio, S Chattopadhyay, C Jin, et al., 13285:84–103.
- Hermawan, Ade Pitra, Dong-Seong Kim und Jae-Min Lee. 2020. „Vorausschauende Wartung von Flugzeugtriebwerken mithilfe von Deep-Learning-Techniken.“ In , 1296–98. IEEE.
- Hinostroza, MA, Anastasios M Lekkas, Christian de Jonge, Svein Ivar Sagatun, Bjørnar Luteberget und Aksel Transeth. 2024. „Vorläufige experimentelle Ergebnisse eines zeitbasierten Planungssystems für die autonome Inspektion mit UGV.“ In , 87837:V05BT06A068. American Society of Mechanical Engineers.
- Hodkiewicz, Melinda, Caitlin Woods, Matt Selway und Markus Stumptner. 2024. „Iof-Maint – Modular Maintenance Ontology.“ arXiv Preprint arXiv:2404.05224.
- Hu, Can und Xiang Liu. 2016. „Modellierung der Verschlechterung der Gleisgeometrie mithilfe der Support-Vektor-Maschinen-Technik.“ In , 49675:V001T01A011. American Society of Mechanical Engineers.
- Huang, Shichun, Tao Wang, Yong Tang, Yiwen Hu, Gu Xin und Dianle Zhou. 2023. „Distributed and Scalable Cooperative Formation of Unmanned Ground Vehicles Using Deep Reinforcement Learning.“ Aerospace 10 (2): 96.
- Jafari, S, und YC Byun. 2022. „Vorhersage des Batteriezustands mithilfe des Digital-Twin-Frameworks auf Basis des Batteriemanagementsystems.“ IEEE ACCESS 10:124685–96. <https://doi.org/10.1109/ACCESS.2022.3225093>.
- Jakobsson, E., E. Frisk, M. Krysander und R. Pettersson. 2020. „Automatisierte Nutzungskennzeichnung von Bergbaufahrzeugen zur Lebensdauerprognose.“ 21. IFAC-Weltkongress 53 (2): 11950–55. <https://doi.org/10.1016/j.ifacol.2020.12.719>.
- Jevinger, Å, C Zhao und JA Persson. o. J. „Künstliche Intelligenz zur Verbesserung des öffentlichen Nahverkehrs: Eine Mapping-Studie. Public Transp 16, 99–158 (2024).“
- Ji, Yonghyeok, Seongyong Jeong, Yeongjin Cho, Howon Seo, Jaesung Bang, Jihwan Kim und Hyeongcheol Lee. 2021a. „Eine Studie zur Erkennung von Anomalien beim Ein- und Auskuppeln des Motors mithilfe von maschinellem Lernen für Hybrid-Elektrofahrzeuge mit Getriebe-Elektroantrieb.“ Angewandte Wissenschaften 11 (21): 10187.
- Jiang, KR, ZB Tian, T Wen, KJ Song, S Hillmansen und WY Ochieng. 2025. „Kollaborative Optimierungsstrategie für das Energie- und Wärmemanagementsystem von Wasserstoff-Brennstoffzellenzügen auf Basis von Deep Reinforcement Learning.“ APPLIED ENERGY 393 (September).
- Kabashkin, Igor. 2024. „Das Eisbergmodell für die integrierte Flugzeugzustandsüberwachung auf Basis von KI, Blockchain und Datenanalyse.“ Electronics 13 (19): 3822.

- Kabashkin, Igor, und Vitaly Susanin. 2024. „Entscheidungsmodell für das Lebenszyklusmanagement von Flugzeugkomponenten.“ *Mathematik* (2227-7390) 12 (22).
- Kaewunruen, S., J. Sresakoolchai und G. M. Zhu. 2021. „Maschinelles Lernen zur Überwachung von Schienenwelligkeit für die Instandhaltung von Eisenbahnschienen.“ *STRUCTURAL MONITORING AND MAINTENANCE, AN INTERNATIONAL JOURNAL* 8 (2): 151–66. <https://doi.org/10.12989/smm.2021.8.2.151>.
- Kavousi-Fard, Abdollah, Morteza Dabbaghjamesh, Tao Jin, Wencong Su und Mahmoud Roustaei. 2020a. „Ein evolutionäres, auf Deep Learning basierendes Modell zur Erkennung von Anomalien für die Fahrzeugsicherheit.“ *IEEE Transactions on Intelligent Transportation Systems* 22 (7): 4478–86.
- Khan, Md Al-Masrur, Md Rashed Jaowad Khan, Abul Tooshil, Niloy Sikder, MA Parvez Mahmud, Abbas Z Kouzani und Abdullah-Al Nahid. 2020. „A Systematic Review on Reinforcement Learning-Based Robotics within the Last Decade.“ *IEEE Access* 8:176598–623.
- Khan, S., M. Farnsworth, R. McWilliam und J. Erkoyuncu. 2020. „On the Requirements of Digital Twin-Driven Autonomous Maintenance.“ *ANNUAL REVIEWS IN CONTROL* 50:13–28.
- Khouzani, Amir Hossein Eslami, Amir Golroo und Morteza Bagheri. 2017. „Railway Maintenance Management Using a Stochastic Geometrical Degradation Model.“ *Journal of Transportation Engineering, Teil A: Systeme* 143 (1): 04016002.
- Kim, Beomjun, Jeong Won Kang, Chul-Su Kim, Oh Kuen Kwon und Jeonghwan Gwak. 2024. „Hybrid-Transformator zur Erkennung von Anomalien in HLK-Systemen von Eisenbahnen durch Feature-Ensemble aus räumlich-zeitlichen Daten mit mehrkanaligen GADF-Bildern.“ *Journal of Electrical Engineering & Technology* 19 (4): 2803–15.
- Kong, XF, J Yang, WH Chen und J Pan. 2024. „Joint Multimission Selective Maintenance and Inventory Optimization for Multicomponent Systems Considering Stochastic Dependency.“ *IEEE TRANSACTIONS ON RELIABILITY* 73 (4): 1967–81.
- Kuan, CW, WH Chen, YC Lin und IEEE. 2020. „Pothole Detection and Avoidance via Deep Learning on Edge Devices.“ In *National Taipei University of Technology*.
- Lasisi, A, und N Attoh-Okine. 2019. „Maschinelles Lernen-Ensembles und Vorhersage von Schienenfehlern: Mehrschichtige Stapelungsmethodik.“ *ASCE-ASME JOURNAL OF RISK AND UNCERTAINTY IN ENGINEERING SYSTEMS PART A-CIVIL ENGINEERING* 5 (4). <https://doi.org/10.1061/AJRUA6.0001024>.
- Lee, Juseong und Mihaela Mitici. 2023. „Deep Reinforcement Learning for Predictive Aircraft Maintenance Using Probabilistic Remaining-Useful-Life Prognostics.“ *Reliability Engineering & System Safety* 230:108908.
- Li, Hongfei, Dhaivat Parikh, Qing He, Buyue Qian, Zhiguo Li, Dongping Fang und Arun Hampapur. 2014. „Verbesserung der Geschwindigkeit im Schienennetz: Ein maschineller Lernansatz für die vorausschauende Instandhaltung.“ *Transportation Research Part C: Emerging Technologies* 45:17–26.
- Lin, Y, L Chu, JC Hu, YJ Zhang, ZR Hou und IEEE. 2022. „Eine intelligente Energiemanagementstrategie für Plug-in-Hybrid-Elektrofahrzeuge, inspiriert von der Monte-Carlo-Baumsuche.“ In *Jilin University*, 811–16.
- Liu, LJ, und J Yang. 2023. „Dynamischer Betrieb und Wartung eines Schwarmes unbemannter Luftfahrzeuge für die kontinuierliche Notfallkommunikation.“ *COMPUTERS & INDUSTRIAL ENGINEERING* 184.

- Liu, Min, Jianbo Lai und Weiming Shen. 2014. „Eine Methode zur Umwandlung von technischen Stücklisten in Wartungsstücklisten.“ Robotik und computerintegrierte Fertigung 30 (2): 142–49.
- Liu, Haichao, Xiaona Song und Fagui Zhang. 2021. „Fehlerdiagnose bei Fahrzeugen mit neuen Energien auf Basis verbesserter maschineller Lernverfahren.“ Soft Computing 25 (18): 12091–106.
- Liu, Y, MY Yang und ZG Guo. 2022. „Reinforcement Learning Based Optimal Decision Making towards Product Lifecycle Sustainability.“ INTERNATIONAL JOURNAL OF COMPUTER INTEGRATED MANUFACTURING 35 (10–11): 1269–96.
- Lu, Kenneth, Margarita Hiett, Ernest Vincent Cross, Michael Reposo, Aron Kain und Erik Davis. 2024. „Hybrid-AI Approach to Health Monitoring of Vehicle Control System.“ In , 1–5. IEEE.
- Massaro, Alessandro, Sergio Selicato und Angelo Galiano. 2020. „Vorausschauende Wartung von Busflotten durch intelligente elektronische Steuertafeln mit künstlicher Intelligenz.“ IoT 1 (2): 12.
- Massaro, Alessandro, Sergio Selicato und Angelo Galiano. 2020. „Vorausschauende Wartung von Busflotten durch intelligente elektronische Steuertafeln mit künstlicher Intelligenz.“ IoT 1 (2): 12.
- Mattila, Ville und Kai Virtanen. 2011. „Scheduling Fighter Aircraft Maintenance with Reinforcement Learning.“ In , 2535–46. IEEE.
- Mohammadi, Reza und Qing He. 2022. „Ein Ansatz mit tiefem Verstärkungslernen für die Planung der Erneuerung und Wartung von Schienen.“ Reliability Engineering & System Safety 225:108615.
- Mohan, T Roosefert, J Preetha Roselyn, R Annie Uthra, D Devaraj und K Umachandran. 2021. „Intelligenter, auf maschinellem Lernen basierender Ansatz zur produktiven Gesamtinstandhaltung für null Ausfallzeiten in Industriemaschinen.“ Computers & Industrial Engineering 157:107267.
- Nuvvula, Ramakrishna SS, Polamarasetty P Kumar, Alighazi Siddiqui, S Thamizharasan, Chai Ching Tan, Raaid Alubady und Baseem Khan. 2024. „Optimierung des Betriebs von Elektrofahrzeugflotten mit prädiktiver Analytik: Ein auf erneuerbare Energien ausgerichteter Ansatz.“ In , 309–11. IEEE.
- Ogunfowora, Oluwaseyi und Homayoun Najjaran. 2023. „Reinforcement and Deep Reinforcement Learning-Based Solutions for Machine Maintenance Planning, Scheduling Policies, and Optimization.“ Journal of Manufacturing Systems 70:244–63.
- Öhlinger, Florian, Lisa Greimel, Robert Glawar und Wilfried Sihn. 2022. „Ein Ansatz für die KI-basierte Prognose von Wartungsaufträgen für die MRO-Planung.“ IFAC-PapersOnLine 55 (10): 2312–17.
- Oh, Sung Hyun und Jeong Gon Kim. 2023. „LSTM-basierte PdM-Plattform für SCU-Prüfgeräte in Automobilen.“ In , 363–65. IEEE.
- Patil, SA, NP Sable, PN Mahalle und GR Shinde. 2023. „Intelligente Mechanismen für PdM in Automobilmaschinen: Eine umfassende Analyse unter Verwendung von ML/DL.“ JOURNAL OF ELECTRICAL SYSTEMS 19 (2): 116–30.
- Pebrianti, Dwi, Zulhakim Khalani und Luhur Bayuaji. 2024. „Predictive Maintenance in Aerospace Industry Using Convolutional Neural Network“ (Vorausschauende Wartung in der Luft- und Raumfahrtindustrie mithilfe konvolutioneller neuronaler Netze). In: IEEE, 157–62.

- Prabhakaran, Priyanka, Subbaiyan Anandakumar, Bhaskaran E Priyanka und Prabu Velusamy. 2022. „Modellentwicklung synchronisiert mit Data Mining für die Instandhaltungsstrategie von Schienenfahrzeugen.“ *Advances in Mechanical Engineering* 14 (8): 16878132221117124.
- Putra, Hafid Galih Pratama, Suhono Harso Supangkat, I Gusti Bagus Baskara Nugraha, Fadhil Hidayat und PT Kereta. 2021. „Entwurf eines maschinellen Lernmodells für die vorausschauende Wartung von Schienenfahrzeugen.“ In , 1–5. IEEE.
- Rahim, FHA, NM Noor, H Abdullah und B Annanurov. 2020. „Kostenminimierung kritischer Flugzeugkomponenten für Planungs- und Wartungsanforderungen.“ *INTERNATIONAL JOURNAL OF INTEGRATED ENGINEERING* 12 (7): 40–53. <https://doi.org/10.30880/ijie.2020.12.07.005>.
- Razzaghi, Pouria, Amin Tabrizian, Wei Guo, Shulu Chen, Abenezer Taye, Ellis Thompson, Alexis Bregeon, Ali Baheri und Peng Wei. 2024. „Eine Untersuchung zum verstärkenden Lernen in Luftfahrtanwendungen.“ *Engineering Applications of Artificial Intelligence* 136:108911.
- Ribeiro, Jorge, Pedro Andrade, Manuel Carvalho, Catarina Silva, Bernardete Ribeiro und Licínio Roque. 2022. „Spielerische Sonden für die Designinteraktion mit maschinellem Lernen: Ein Werkzeug für die zustandsbasierte Wartungsplanung und Visualisierung von Flugzeugen.“ *Mathematik* 10 (9): 1604.
- Rokhforoz, Pegah und Olga Fink. 2021. „Hierarchische vorausschauende Wartungsplanung für Züge unter Verwendung eines preisbasierten Ansatzes.“ *Computers & Industrial Engineering* 159:107475.
- Saba, I., AH Alobaidi, S. Alghamdi und M. Tariq. 2025. „Digital Twin und TD3-gestützte Optimierung des xEV-Energiemanagements in Vehicle-to-Grid-Netzwerken.“ *IEEE ACCESS* 13:92495–506.
- Samanta, A, und S Williamson. 2023. „Maschinell lernbasierte Techniken zur Vorhersage der verbleibenden Nutzungsdauer für Lithium-Ionen-Batteriemanagementsysteme: Eine umfassende Übersicht.“ *IEEE JOURNAL OF INDUSTRY APPLICATIONS* 12 (4): 563–74. <https://doi.org/10.1541/ieejia.22004793>.
- Sanz, Elma, Joaquim Blesa und Vicenç Puig. 2021. „BiDrac Industry 4.0 Framework: Anwendung auf einen Prozess in einer Autolackiererei.“ *Control Engineering Practice* 109:104757.
- Shang, YW, WC Wu, JW Liao, JB Guo, J Su, W Liu und Y Huang. 2020. „Stochastic Maintenance Schedules of Active Distribution Networks Based on Monte-Carlo Tree Search“ (Stochastische Wartungspläne für aktive Verteilungsnetze auf Basis der Monte-Carlo-Baumsuche). *IEEE TRANSACTIONS ON POWER SYSTEMS* 35 (5): 3940–52.
- Shuvo, Salman Sadiq und Yasin Yilmaz. 2020. „Predictive Maintenance for Increasing EV Charging Load in Distribution Power System.“ In , 1–6. IEEE.
- Shyalika, Chathurangi, Thushari Silva und Asoka Karunananda. 2020. „Reinforcement Learning in Dynamic Task Scheduling: A Review.“ *SN Computer Science* 1 (6): 306.
- Silva, Catarina, Pedro Andrade, Bernardete Ribeiro und Bruno F. Santos. 2023. „Adaptives Reinforcement Learning für die Aufgabenplanung in der Flugzeugwartung.“ *Scientific Reports* 13 (1): 16605.
- Soori, Mohsen, Fooad Karimi Ghaleh Jough, Roza Dastres und Behrooz Arezoo. 2024. „KI-basierte Entscheidungsunterstützungssysteme in der Industrie 4.0, eine Übersicht.“ *Journal of Economy and Technology*.

- Sresakoolchai, J., und S. Kaewunruen. 2023. „Verbesserung der Effizienz der Instandhaltung von Eisenbahninfrastrukturen durch tiefes Reinforcement Learning in Verbindung mit digitalen Zwillingen auf der Grundlage von Gleisgeometrie und Bauteilfehlern.“ SCIENTIFIC REPORTS 13 (1).
- Sresakoolchai, J., C. Ngamkhanong und S. Kaewunruen. 2025. „Hybride Lernstrategien: Integration von überwachten und verstärkenden Techniken für das Verschleißmanagement von Eisenbahnradern mit begrenzten Messdaten.“ FRONTIERS IN BUILT ENVIRONMENT 11
- Stewart, Michael, Melinda Hodkiewicz, Wei Liu und Tim French. 2024. „MWO2KG und Echidna: Aufbau und Erforschung von Wissensgraphen aus Wartungsdaten.“ Proceedings of the Institution of Mechanical Engineers, Teil O: Journal of Risk and Reliability 238 (5): 920–32.
- Sun, YF, L Zhang, O Ma und AIAA. 2020. „Robotergestütztes 3D-Scannen von Flugzeugen.“ In University System of Ohio.
- Tham, CK, WH Liu, R Chattopadhyay und IEEE. 2023. „Vorgeschriebene Wartung von Lastkraftwagen mithilfe von Deep Reinforcement Learning.“ In National University of Singapore.
- Tseremoglou, Iordanis, Paul J van Kessel und Bruno F Santos. 2023. „A Comparative Study of Optimization Models for Condition-Based Maintenance Scheduling of an Aircraft Fleet.“ Aerospace 10 (2): 120.
- Tseremoglou, Iordanis und Bruno F Santos. 2024. „Zustandsbasierte Wartungsplanung für eine Flugzeugflotte unter teilweiser Beobachtbarkeit: Ein Ansatz mit tiefem Verstärkungslernen.“ Reliability Engineering & System Safety 241:109582.
- Van Eck, Nees und Ludo Waltman. 2010. „Software-Übersicht: VOSviewer, ein Computerprogramm für bibliometrisches Mapping.“ Scientometrics 84 (2): 523–38.
- Van Eck, Nees Jan. „VOSviewer-Handbuch.“ (2009).
- Vashishth, Tarun Kumar, Vikas Sharma, Kewal Krishan Sharma, Bhupendra Kumar, Sachin Chaudhary und Rajneesh Panwar. 2025. „Digital Twins Solutions for Smart Logistics and Transportation.“ In Digital Twins for Smart Cities and Villages, 353–76. Elsevier.
- Vos, K., Z. Peng, E. Lee und W. Wang. 2023. „Optimierung der Verfügbarkeit von Flugzeugflotten: Ein Ansatz mit verstärktem Lernen.“ The Aeronautical Journal 127 (1318): 2204–18.
- Wang, BX, L Liu, J Wang und IEEE. 2023. „Task Offloading Optimization Based on Actor-Critic Algorithm in Vehicle Edge Computing.“ In , 687–92.
- Wang, H., Z. W. Han, X. F. Wang, Y. B. Wu und Z. G. Liu. 2024. „Kontrastives lernbasiertes Bayes-adaptives Meta-Verstärkungslernen für die aktive Stromabnehmersteuerung in Hochgeschwindigkeitsbahnen.“ IEEE TRANSACTIONS ON TRANSPORTATION ELECTRIFICATION 10 (1): 2045–56.
- Wang, L., HB Liang, GT Mao, DM Zhao, Q. Liu, YT Yao und H. Zhang. 2024. „Ressourcenallokation für dynamische Platoon-Digital-Twin-Netzwerke: Eine Multi-Agent-Deep-Reinforcement-Learning-Methode.“ IEEE TRANSACTIONS ON VEHICULAR TECHNOLOGY 73 (10): 15609–20.
- Wang, Yu, Tangbin Xia, Yuhui Xu, Guojin Si, Dong Wang, Ershun Pan und Lifeng Xi. 2024. „Qualitätsorientierte Produktions- und Wartungsplanung für Mehrmaschinen-Fertigungssysteme unter variablen Betriebsbedingungen.“ Reliability Engineering & System Safety 250:110264.
- Wesendrup, K., & Hellingrath, B. (2023). ML2-fähige zustandsbasierte Bedarfs-, Produktions-, Bestands- und Wartungsplanung. IFAC-PapersOnLine, 56(2), 6600-6605.

- Woods, Caitlin, Matt Selway, Tyler Bikaun, Markus Stumptner und Melinda Hodkiewicz. 2024. „Eine Ontologie für Wartungsaktivitäten und ihre Anwendung auf die Datenqualität.“ Semantic Web 15 (2): 319–52
- Wu, JD, C Huang, HW He und HL Huang. 2024. „Confidence-Aware Reinforcement Learning for Energy Management of Electrified Vehicles.“ RENEWABLE & SUSTAINABLE ENERGY REVIEWS 191 (März).
- Yan, Min, Li Wang, Lianming Xu, Luyang Hou und Zhu Han. 2024. „Trade-Off zwischen der Nutzung erneuerbarer Energien und der Kommunikationsqualität für Basisstationen: Eine heterogene Multi-Agent-Safe-RL-Methode.“ IEEE Transactions on Green Communications and Networking.
- Ye, YG, B Zhu, P Huang und B Peng. 2022. „OORNet: Ein Deep-Learning-Modell für die On-Board-Zustandsüberwachung und Fehlerdiagnose von unrunnen Rädern von Hochgeschwindigkeitszügen.“ MEASUREMENT 199 (August). <https://doi.org/10.1016/j.measurement.2022.111268>.
- Zhang, Zhipeng, Kang Zhou und Xiang Liu. 2020. „Vorhersage von Schienenbrüchen mit einem maschinellen Lernansatz.“ In , 83587:V001T08A014. American Society of Mechanical Engineers.
- Zhao, Yu, Jun Liu, Xiaoming Liu, Keyu Yuan, Kezheng Ren und Mengqin Yang. 2022. „A Graph-Based Deep Reinforcement Learning Framework for Autonomous Power Dispatch on Power Systems with Changing Topologies.“ In , 1–5. IEEE.
- Zhou, XY, P Wu, HF Zhang, WH Guo und YC Liu. 2019. „Learn to Navigate: Cooperative Path Planning for Unmanned Surface Vehicles Using Deep Reinforcement Learning.“ IEEE ACCESS 7:165262–78.
- Zhou, Hang, Thiago Augusto Lopes Genez, Alexandra Brintrup und Ajith Kumar Parlikad. 2022. „Ein hybrider Lernalgorithmus zur Identifizierung konkurrierender Risiken in Flotten komplexer technischer Systeme.“ Reliability Engineering & System Safety 217:107992.
- Zou, Yingyong, Yongde Zhang und Hancheng Mao. 2021. „Fehlerdiagnose an Traktionsmotoren in Hochgeschwindigkeitszügen auf Basis von Deep Learning.“ Alexandria Engineering Journal 60 (1): 1209–19.

3.	Konzeptionelles Modell von AI-MOPC für die Eisenbahninstandhaltungswerkstatt	50
4.	Erkenntnisse aus dem konzeptionellen Rahmen	52
IV.	Verstärkendes Lernen in der Wartungsauftragsplanung und -steuerung	54
1.	Suchstrategie für die Datenerfassung	56
2.	Deskriptive Analyse der gesammelten Artikel	57
a)	Publikationstrends in diesem Bereich	57
b)	Analyse auf Grundlage der identifizierten Cluster	58
4.	In diesem Forschungsbereich verwendete Modelle des verstärkenden Lernens	62
5.	Konzeptioneller Rahmen für verstärktes Lernen in der Wartungsauftragsplanung und -steuerung	63
a)	Hauptfunktionen von Wartungsauftragsplanung und -steuerung	64
b)	Komponenten des verstärkenden Lernens	66
c)	Implementierungsüberlegungen zur Umsetzung	67
d)	Verstärkender Lern-Feedback-Loop	68
6.	Erkenntnisse aus dem verstärkenden Lernen in der Wartungsauftragsplanung und -steuerung	69
V.	Schlussfolgerung und Ausblick	70
	Literaturverzeichnis	74
	Weitere Studienberichte des Lehrstuhls für Produktionswirtschaft	83

Link zum Downloadbereich des Lehrstuhls: <https://www.b-tu.de/fg-produktionswirtschaft/downloads>

Lugert, A./Winkler, H.: **Die Wertstrommethode im Zeitalter von Industrie 4.0**, Studienreport des Lehrstuhls für Produktionswirtschaft, Band 1, Cottbus 2017.

Kaucher, Ch./Kunath, M./Winkler, H.: **Zukunft elektrochemischer Speicher für Hybridantriebe – Studienreport am Beispiel von Hybridrangierlokomotiven**, Studienreport des Lehrstuhls für Produktionswirtschaft, Band 2, Cottbus 2018.

Kunath, M./Winkler, H.: **Untersuchung des Status quo betrieblicher Entscheidungsunterstützungssysteme im Zuge der fortschreitenden Digitalisierung**, Studienreport des Lehrstuhls für Produktionswirtschaft, Band 3, Cottbus 2019.

Jeglinsky, V./Winkler, H.: **Untersuchung von Hindernissen zur Digitalisierung in der industriellen Produktion**, Studienreport des Lehrstuhls für Produktionswirtschaft, Band 4, Cottbus 2020.

Stockmann, C./Winkler, H.: **Robustheit in Produktionssystemen aus Sicht der industriellen Praxis**, Studienreport des Lehrstuhls für Produktionswirtschaft, Band 5, Cottbus 2020.

König, M./Winkler, H.: **Digitalisierung in der Montage mit dem Schwerpunkt des Einsatzes von Assistenzsystemen**, Studienreport des Lehrstuhls für Produktionswirtschaft, Band 6, Cottbus 2023.

Berneis, M./Winkler, H.: **Untersuchung von aktuellen Trends und Herausforderungen im Supply Chain Management in Deutschland**, Studienreport des Lehrstuhls für Produktionswirtschaft, Band 7, Cottbus 2023.

Hoffmann, S./Thomas, K./Winkler, H.: **Technologische Trends und Entwicklungen bei alternativen Energiesystemen**, Studienreport des Lehrstuhls für Produktionswirtschaft, Band 8, Cottbus 2023.

Schmid, S./Winkler, H.: **Produktionssteuerung im digitalen Zeitalter aus Sicht der industriellen Praxis**, Studienreport des Lehrstuhls für Produktionswirtschaft, Band 9, Cottbus 2023.

Hoffmann, S./Thomas, K./Winkler, H.: **Der Design Thinking Ansatz: Fallstudien zum Prototyping von Komponenten und Systemen der dezentralen Energietechnik**, Studienreport des Lehrstuhls für Produktionswirtschaft, Band 10, Cottbus 2025.