

# Konzepte und Methoden für prädiktive Instandhaltung in der Intralogistik

## Concepts and methods for predictive maintenance in intralogistics

**Michael Schadler**  
**Norbert Hafner**  
**Christian Landschützer**

*Institut für Technische Logistik (ITL)  
Fakultät für Maschinenbau und Wirtschaftswissenschaften  
Technische Universität Graz*

**P**rädiktive Instandhaltung auf Basis sogenannter digitaler Zwillinge gilt als eine zentrale Innovation der Industrie 4.0. Sie wurde als Schlüsselthema erkannt und wird als Voraussetzung für zukünftigen Erfolg gesehen, da mit ihrer Hilfe Instandhaltungsmaßnahmen und die dazugehörigen Entscheidungen im komplexen industriellen Umfeld zielgerichteter und aktiver getroffen werden können. Die Intralogistik, die wesentlich zum wirtschaftlichen Erfolg von Unternehmen beiträgt, ist aufgrund der strategischen Bedeutung aber auch der dringlichen Notwendigkeit in Hinblick auf die Sicherstellung der technischen Verfügbarkeit besonders gefordert, die Möglichkeiten der Digitalisierung möglichst rasch zu antizipieren. Dieser Beitrag möchte die bestehenden Ansätze und Methoden des Instandhaltungsmanagement aufgreifen und eine Brücke hin zu den Möglichkeiten und Visionen der Industrie 4.0 schlagen, wodurch ein Konzept für eine integrierte (ganzheitliche), wissensbasierte Instandhaltung in der Intralogistik entstehen soll.

*[Schlüsselwörter: Intralogistik, Digitaler Zwilling, Prädiktive Instandhaltung, Industrie 4.0, Wissensbasierte Instandhaltung]*

**P**redictive maintenance based on so-called digital twins is regarded as a central innovation in industry 4.0. It has been recognised as a key issue for the industry and is seen as a prerequisite for future success, since it can help to make the planning of maintenance measures and the associated decisions in the complex industrial environment more targeted and active. Intralogistics, which contributes significantly to the economic success of companies, is particularly required to anticipate the possibilities of digitization as soon as possible due to the strategic importance and the urgent need to ensure technical availability. This contribution takes up the existing approaches and methods of maintenance management and tries to link it with the possibilities and visions of industry 4.0, thereby creating a concept for integrated (holistic), knowledge-based maintenance in intralogistics.

*[Keywords: Intralogistics, Digital Twin, Predictive Maintenance, Industry 4.0, Knowledge Based Maintenance]*

## 1 EINLEITUNG

Die Logistik von heute zeichnet sich durch ihre global vernetzten Liefer- und Wertschöpfungsketten aus, sie ist hochgradig flexibel, sowie komplex und bildet dadurch das Rückgrat moderner Produktions- und Bereitstellungskonzepte [AHK16, WB09]. Die Intralogistik ist ein zentraler und unverzichtbarer Bestandteil vieler Lieferketten [Arn06], sie kann dabei gleichzeitig jedoch ebenso einen Flaschenhals darstellen [KKW08]. Durch die vielschichtigen Abhängigkeiten und weiter zunehmende Vernetzung steigt die Wahrscheinlichkeit, dass außerplanmäßige Ausfälle negative Auswirkungen haben [KKB07]. Um dies zu verhindern sind Anlagenbetreiber gefordert, ihre Prozesse zielgerichtet zu gestalten, sodass die vom Kunden erwarteten logistischen Dienstleistungen sichergestellt sind [AHK16]. In Kombination mit den hohen Kosten für die Beschaffung und den Betrieb erwachsen über den gesamten Lebenszyklus hohe Ansprüche an die intralogistischen Systeme hinsichtlich Verfügbarkeit und Zuverlässigkeit [KKB07]. Es bedarf somit sowohl hochverfügbarer Technik, als auch entsprechender Wartungs- und Servicekonzepte, um vor unangenehmen Systemausfällen verschont zu bleiben [Wel06]. Daher nimmt die Bedeutung der Instandhaltung von intralogistischen Systemen für den Erfolg eines Unternehmens stets zu [KKB07]. Die richtige Wahl der optimalen Instandhaltungsstrategie spielt für den reibungsfreien Betrieb intralogistischer Anlagen eine zentrale Rolle [AHK16].

## 2 PROBLEMSTELLUNG UND ZIEL

### 2.1 INSTANDHALTUNG IN DER INTRALOGISTIK

Obwohl die Zuverlässigkeit und Verfügbarkeit von intralogistischen Anlagen ein zentrales Thema sind, steht deren Wartung und Instandhaltung nur sehr sporadisch im Mittelpunkt des Interesses [WB11]. Die Gründe hierfür sind vielfältig und wurden bereits in Teilen des Sonderforschungsprojekt „SFB 696“ (Forderungsgerechte Auslegung von Intralogistiksystemen) identifiziert. Zum einen

liegt die Schwierigkeit mitunter bereits in der Planungsphase der Anlagen, denn obwohl es gute Planungstechniken und –methoden gibt, sind diese oftmals mit großen Unsicherheiten verbunden, die mit den langen Planungshorizonten begründet werden können [WB11]. Die Ambivalenz zwischen bedarfsorientierter Systemauslegung und den sehr volatilen Marktentwicklungen, deren zukünftige Anforderungen ebenso erfüllt werden müssen, führen zu einer Überdimensionierung intralogistischer Anlagen mit dem Ziel keine kurz- und mittelfristigen Systemmodifizierungen zur Leistungssteigerung machen zu müssen und um Systemausfälle, zumindest während der Gewährleistungsfrist, zu verhindern [WB11]. Auch aktuelle Forschungsberichte zeigen, dass die Überdimensionierung von Standardkomponenten noch immer aktuell ist, und bspw. die elektrischen Antriebssysteme weit unterhalb ihrer Nennwirkungsgrade betrieben werden. [Stö19]

Zum anderen konnten sich bisher, im Gegensatz zu anderen Branchen, ausgeklügeltere Konzepte und Managementstrategien der Instandhaltung wie bspw. Reliability Centered Maintenance (RCM), Total Productive Maintenance (TPM), Lean Maintenance (LM) oder Risk Based Maintenance (RBM) bei Intralogistiksystemen nicht branchenweit durchsetzen.



Abbildung 1. Einteilung der Instandhaltung nach [DIN EN 13306]

Von den, im Anhang der Norm [DIN EN 13306] definierten Instandhaltungsstrategien (siehe Abbildung 1.), werden in der Intralogistik noch immer jene mit korrektiven, als auch jene mit vorausbestimmten präventiven Maßnahmen eingesetzt [KKW08, WB11, Dul08]. Während erstere nur reaktiv agieren, also eine Anlage erst nach dem Eintritt eines Fehlers bzw. Schadens gewartet und wieder instandgesetzt wird („run-to-failure“), erfolgt die präventive Instandhaltung („preventive maintenance“) zumeist auf Basis vordefinierter zeitbasierter Wartungsintervalle. Eine zustandsorientierte Wartung ist nur in sehr seltenen Fällen bspw. bei besonders kritischen Bauteilen vorhanden,

da sie vorrangig eine repetitive manuelle Inspektion der Komponenten bedingt, um den aktuellen Zustand zu evaluieren. Eine automatisierte Zustandsüberwachung („condition monitoring - CM“) gibt es nur selten, sie erscheint aber allgemein sehr erstrebenswert, um den manuellen Aufwand zu minimieren und gleichzeitig ebenso eine kontinuierliche Überwachung relevanter Anlagenparameter bzw. der Anlagenleistung zu ermöglichen. Diese Art der Zustandsüberwachung ist aber eine Grundvoraussetzung für eine prädiaktive („predictive maintenance“), wie auch für eine nutzungsabhängige Instandhaltung („utilization-based maintenance“).

## 2.2 TRIEBFEDER DIGITALISIERUNG

Die große Herausforderung liegt bei prädiaktiver Instandhaltung jedoch nicht rein in der Implementierung einer Zustandsüberwachung. Vielmehr stellt die zuverlässige Prognose des zukünftigen Zustands des gesamten Systems, der Teilsysteme oder einzelner Komponenten, eine große Herausforderung dar. Gerade diese Aufgabe wird seit geraumer Zeit durch die Möglichkeiten der Datenwissenschaften aufgegriffen. „Predictive maintenance“ (auch „smart maintenance“, „maintenance 4.0“, „data-driven maintenance“, etc.) wird als mögliches Anwendungsgebiet der Künstlichen Intelligenz allgemein und vielseitig diskutiert. Das Versprechen der Visionen rund um „Predictive Maintenance“ lautet, dass mit Hilfe der Algorithmen des maschinellen Lernens und gestützt durch Daten, die mittels Technologien der Industrie 4.0 in Echtzeit an den Anlagen gesammelt wurden, vertiefte Kenntnisse und Schlüssel über den Zustand und die Notwendigkeit von Instandhaltungsmaßnahmen gezogen werden können. In einer noch weiter gedachten Vision, sollen die Anlagen ebenso Handlungsempfehlungen bzw. gar -anweisungen geben können.

Im Hinblick auf die derzeit vorherrschenden Instandhaltungsstrategien erscheinen die Instandhaltungsansätze der Digitalisierung als idealer zukünftiger Zustand. Diese Auffassung wird durch eine Umfrage der Bundesvereinigung Logistik (BVL) im Jahr 2018 unter 272 Logistikexperten bestätigt. Unter den Befragten wird die prädiaktive Instandhaltung mit 21% als sehr relevant, mit 32% als relevant und mit 27% als mittelfristig relevant eingestuft [SB18b]. Gleichzeitig bewerteten lediglich 11% desselben Personenkreises die Anpassungsfähigkeit ihrer Unternehmen, mit prädiaktiver Instandhaltung umzugehen zu können, mit „sehr groß“ und nur weitere 33% mit „mittelmäßig“ [SB18a]. In einer anderen Studie einer Unternehmensberatung geben 45,9% der Befragten an, über die Potentiale zu diskutieren, wohingegen nur 21,6% einzelne Projekte oder Piloten (13,5%) umgesetzt haben. 16,2% der Befragten haben gar keine Aktivitäten gesetzt [DBG18]. Obwohl der Nutzen prädiaktiver bzw. nutzungsabhängiger Instandhaltung in der Intralogistik offensichtlich erkannt wurde und in einzelnen Fällen sogar punktuell an einer Implementierung gearbeitet wird, fehlt es an Res-

sourcen und an Fachkenntnissen diese umzusetzen. Darüber hinaus ist eine ganzheitliche Herangehensweise unter der Berücksichtigung bekannter Konzepte des Instandhaltungsmanagements insbesondere in Kombination mit den Möglichkeiten der Digitalisierung sowohl in der Praxis als auch in der Wissenschaft aktuell nicht erkennbar.

Ziel dieses Beitrags ist es daher, sowohl die bekannten Instandhaltungsstrategien als auch die Ansätze der Instandhaltung durch Digitalisierung aufzuzeigen, sodass eine ganzheitliche Methode für die zukünftige Instandhaltung intralogistischer Anlagen abgeleitet werden kann.

### 3 FORTGESCHRITTENE INSTANDHALTUNGSSTRATEGIEN

#### 3.1 ZUSTANDSORIENTIERTE INSTANDHALTUNG

Wie in Abbildung 1. zu erkennen ist, unterscheidet die [DIN EN 13306] zwischen der reinen zustandsorientierten und der prädiktiven Instandhaltung. So ist die zustandsorientierte Instandhaltung definiert als „präventive Instandhaltung, die die Beurteilung des physischen Zustands, Analysen und die möglichen, daraus resultierenden Instandhaltungsmaßnahmen beinhaltet. Die Zustandsbeurteilung kann planmäßig, auf Anforderung oder kontinuierlich durch Bedienerüberwachung und/oder Inspektion und/oder Prüfverfahren und/oder Zustandsüberwachung der Systemparameter usw. erfolgen“ [DIN EN 13306].

Beispiele für Techniken des Condition Monitorings im industriellen Umfeld sind Schwingungsmessungen, Thermographie, tribologische Analysen, Überwachung und Kontrolle von Prozessparametern, Ultraschall, etc. [Mob02]. Insbesondere die in der Norm zuletzt erwähnte zustandsorientierte Instandhaltung mittels kontinuierlicher Zustandsüberwachung besitzt die Möglichkeit Anomalien durch kurzfristige Änderungen in der Charakteristik von Messsignalen zu erkennen. Sie entwickelte sich durch das Aufkommen leistungsfähigerer Sensoren im englischsprachigen Raum zuerst zur „On-Condition Maintenance“ und später zur sogenannten „Condition Based Maintenance (CBM)“ bzw. „CBM<sup>+</sup>“ weiter [Ste10]. Anwendung fand diese hauptsächlich im Bereich der Schwerindustrie und des Militärs. Heutige CMB-Systeme basieren hauptsächlich auf der Open System Architecture for Condition-Based Maintenance (OSA-CBM), die in Anlehnung an das OSI-Modell, als Referenzmodell spezifiziert wurde.

Parallel zu CBM entwickelte sich auch das Reliability Centered Maintenance (RCM) als Managementansatz innerhalb der Luftfahrtindustrie, das hauptsächlich auf den Methoden der Failure Mode and Effects Analysis (FMEA) bzw. Failure Mode and Effects and Criticality Analysis (FMECA) beruht und durch die erstmalige Definition sechs verschiedener Ausfallverteilungen bekannt wurde. In seinem systematischen Vorgehen greift RCM auch auf CBM zurück.

#### 3.1.1 FORSCHUNG ZUM CONDITION- UND LOAD MONITORING IN DER TECHNISCHEN LOGISTIK

Die Zustandsüberwachung in der Technischen Logistik wurde bereits in Forschungs- und Entwicklungsprojekten betrachtet und verschiedene Aspekte genauer beleuchtet. An dieser Stelle soll auf zwei wissenschaftliche Forschungsvorhaben hingewiesen werden, deren Erkenntnisse eine solide Ausgangsbasis bilden.

Das Logistics Condition Monitoring Technologies Laboratory (Log CoMo-Tec Lab) an der Technischen Universität Dortmund, ermöglicht es an unterschiedlichen Intralogistiksystemen verschiedenen Messtechniken bzw. Messverfahren wie bspw. Schwingungsmessungen, Drehmoment- oder Leistungsmessungen durchzuführen und dadurch unter Laborbedingungen eine Wissensbasis zur Zustandsüberwachung aufzubauen [AHK16, WB11].

Das Forschungsprojekt „Zustandsüberwachung Intralogistiksysteme – ZIL“ (BMW / IGF-Nr. 489ZN) des Karlsruher Instituts für Technologie und des Fraunhofer LBF identifizierte zusammen mit Herstellern von Intralogistiksystemen hochbeanspruchte Bauteile, kritische Konstruktionsmerkmale und häufig ausfallende Komponenten. Für ausgewählte Systeme wurden mathematische und physikalische Modelle erstellt und in einem Simulationsmodell implementiert, um sowohl das korrekte, als auch das fehlerhafte Verhalten abbilden zu können. Darauf aufbauend wurden für ausgewählte Schädigungsfälle Erkennungsalgorithmen zur Implementierung in energieautarken Sensoren entwickelt. Auf Basis der erzielten Erkenntnisse des Forschungsprojektes können anhand von Messdaten verschiedene Schadensfälle und Unregelmäßigkeiten an Systemen der Intralogistik erkannt werden, was an einer prototypischen Umsetzung exemplarisch gezeigt wurde. [BBK+16]

#### 3.2 PRÄDIKTIVE INSTANDHALTUNG

Die voraussagende Instandhaltung wird in der [DIN EN 13306] als „zustandsorientierte Instandhaltung, die nach einer Vorhersage, abgeleitet von wiederholter Analyse oder bekannten Eigenschaften und Bestimmung von wichtigen Parametern, welche den Abbau des Objekts kennzeichnen, durchgeführt wird.“ Dementsprechend liegt der Fokus der prädiktiven Instandhaltung neben der Diagnose zusätzlich auf der Prognose zukünftiger Zustände der Betrachtungseinheit um die notwendigen Instandhaltungsmaßnahmen genauer festlegen zu können [GMZ16]. Dieser Ansatz führte dazu, dass das ursprünglich aus der Medizin stammende Konzept des „Prognostic and Health Managements (PHM)“ Einzug in die Instandhaltung technischer Anlagen nahm. PHM kann als Evolutionsstufe von CBM angesehen werden, baut es doch wesentlich auf dessen Techniken als Grundlage für die nachgeschalteten Prognosemodelle zur Vorhersage der Zuverlässigkeit, sowie der Restnutzungsdauer („Remaining useful life - RUL“) auf [LWZ+14]. Diese bezeichnet die verbleibende Zeitspanne

bis zu jenem Punkt, an dem die geforderte Funktion nicht mehr erfüllt werden kann und somit dem Ausfall nach [DIN EN 13306] entspricht. Wie in [GMZ16] aufgezeigt, finden sich in der Literatur viele verschiedene Werkzeuge und Methoden für die Fehlerprognose. Die Methoden unterscheiden sich entsprechend der untersuchten Anwendungsfälle während die gewählten Werkzeuge vom vorhandenen Wissen und den verfügbaren Daten abhängen. In [SSB+15] findet sich eine gute Übersicht und Klassifizierung der prognostischen Ansätze des PHM. Grundsätzlich nutzen die drei verschiedenen Herangehensweisen entweder physikalische, datengetriebene oder hybride Modelle (siehe Abbildung 2.).

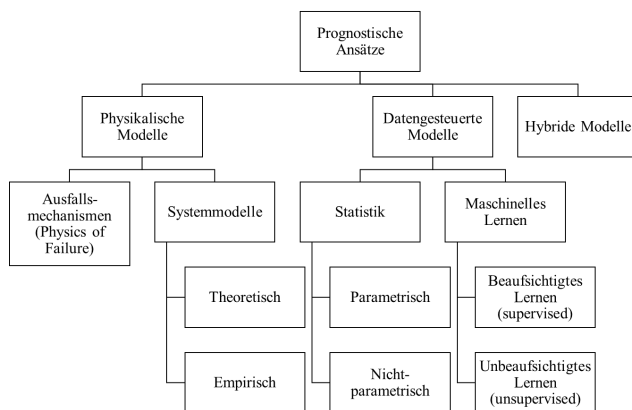


Abbildung 2. Systematik der Prognostischen Ansätze nach [SSB+15]

### 3.2.1 PHYSIKALISCHE MODELLE

Ein im klassischen Maschinenbau üblicher Ansatz ist die Zuhilfenahme von Modellen, die das dynamische Systemverhalten und die entsprechenden Charakteristiken der Ausfallmechanismen z.B. für Materialermüdung, Verschleiß oder Korrosion durch deterministisches Gesetzmäßigkeiten oder stochastische Prozesse nachbilden. Bekanntermaßen sind diese physikalischen Modelle sehr präzise und ihre Ergebnisse durch die zugrundeliegende Physik leicht interpretierbar. Jedoch sind sie oftmals sehr komplex und aufwändig zu erstellen und aufgrund ihrer Spezifität mitunter nicht auf andere Szenarien übertragbar. [GMZ16]

### 3.2.2 DATENGESTEUERTE MODELLE

Die aus den Datenwissenschaften bekannten datengesteuerten Modelle zur „Remaining-useful-life“-Prognose werden besonders gerne als „Black-Box“-Ansätze herangezogen, da Systemmodelle bzw. systemspezifisches Wissen nur eingeschränkt vorhanden sein müssen [SSB+15]. Es werden hierbei charakteristische Merkmale hauptsächlich aus aussagekräftigen Datenquellen, bspw. eines Zustandsüberwachungssystems, extrahiert, um das genaue Systemverhalten widerzuspiegeln. Die relevanten Parameter und die genutzten Datenmodelle fließen in statistische

Auswertungen und/oder trainieren Algorithmen des maschinellen Lernens, welche dann die Prognose zukünftiger Zustände ermöglichen [GMZ16]. Zu den entscheidenden Vorteilen der datengesteuerten Modelle zählt vor allem, dass sie auch für Systeme mit komplexem Verhalten, die man nur schwierig durch physikalische bzw. mathematische Modelle beschreiben kann, geeignet sind. Sie sind jedoch stark von den vorhandenen historischen und aktuellen Daten, sowie dem Wissen über den typischen Betriebszustand abhängig. Darin liegen auch die Nachteile datengestützter Modelle. Oft sind die notwendigen Datensätze für verschiedene Ausfallsszenarien nicht vorhanden und/oder nur sehr zeit- und kostenintensiv zu ermitteln. Hierfür können die bekannten Verfahren und Simulationen wie bspw. „Hardware-in-the-loop (HIL)“ oder Lebensdauerprüfungen wie bspw. „Highly-Accelerated-life-test (HALT)“ zur Ermittlung von Grenzwerten und des Systemverhaltens genutzt werden [SSB+15].

### 3.2.3 MASCHINELLES LERNEN BEI DATENGESTÜTZTEN MODELLEN

Datengesteuerte Modelle nutzen unterschiedliche Werkzeuge wie bspw. neuronale Netzwerke, probabilistische Methoden (Bayessche Netze, Hidden-Markov Modelle, etc.), stochastische Modelle, Zustands-Raum Modelle, Kalman-Filter, Sequentielle Monte-Carlo Simulationen, Regressionen, Klassifikationen und/oder Kombinationen der genannten [GMZ16, LWZ+14]. Die Methoden des Maschinellen Lernens sind vielfältig und die jeweiligen Algorithmen eignen sich jeweils nur für spezifische Zielsetzungen. Eine Systematik der Methoden findet sich in [MR10], die zwischen zwei grundlegenden Arten unterscheidet. Diese sind zum einen die sogenannten verifikationsorientierten Methoden, zur Verifizierung von Hypothesen und zum anderen die sogenannten entdeckungsorientierten Methoden, die sich zur Identifizierung von Regeln, Trends und Mustern in Datensätzen eignen (siehe Abbildung 3.).

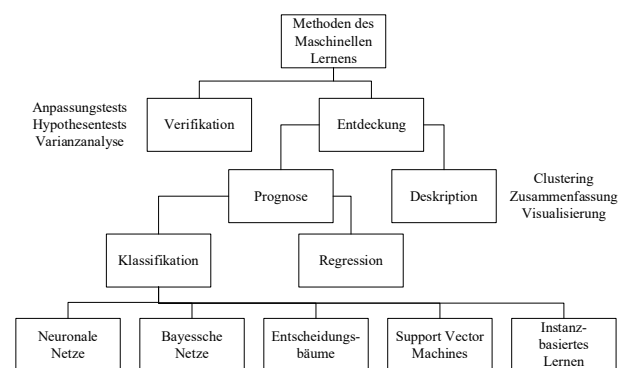


Abbildung 3. Systematik der Methoden maschinellen Lernens nach [MR10]

Innerhalb der entdeckungsorientierten Methoden, kann des Weiteren hinsichtlich Klassifikation bzw. Regres-

sion unterschieden werden. Während erstere eine Einteilung in Zustände wie bspw. normales oder abnormales Verhalten treffen können, eignen sich die Verfahren der Regression zur Nennung konkreter Zahlenwerte [NKB+18]. Die verschiedenen Algorithmen des maschinellen Lernens haben jeweils ihre eigenen Vor- und Nachteile und müssen je nach Anwendungsfall (Anomalie-Erkennung, Fehlerisolierung, Zustandsabschätzung, Lebensdauerprognose, etc.) und unter den gegebenen Voraussetzungen hinsichtlich Datenverfügbarkeit bzw. Systemwissen entsprechend ausgewählt werden [SSB+15].

### 3.2.4 HYBRIDE MODELLE

Da der alleinige Einsatz physikalischer, als auch datengestützter Modelle Nachteile mit sich bringt, sollte im Sinne einer holistischen Herangehensweise die hybriden Modelle, als dritte Möglichkeit genauer in Betracht gezogen werden.

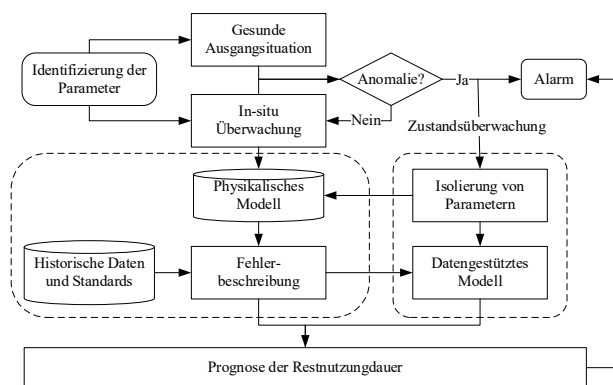


Abbildung 4. Hybrider Prognoseansatz nach [PSK+16]

Diese vereinen in serieller und/oder paralleler Weise die beiden Modelle (siehe Abbildung 4.) und bieten damit die Vorteile einerseits weniger von Datensätzen abhängig zu sein und andererseits auch noch nicht bekannte Fehlerzustände erkennen zu können. Zur Anwendung hybrider Modelle müssen zuerst die zu überwachenden Parameter identifiziert werden, welche sowohl externe Umwelteinflüsse, als auch die internen Belastungen durch den Betrieb umfassen. Diese dienen zum einen der Definition des gesunden Systemzustandes, als auch als Referenz um Abweichungen der Merkmale bei in-situ Messungen erkennen zu können. Werden Anomalien entdeckt, so ist es die Aufgabe ausgewählter Algorithmen des maschinellen Lernens, jene Merkmale zu bestimmen, die wesentlichen Einfluss auf den abnormen Systemzustand haben. Mit Hilfe der physikalischen Modelle kann nun versucht werden, die Abnutzung des Anlagenzustands unter den gegebenen Betriebszuständen und Einflüssen zu beurteilen und zu priorisieren. Der Prozess der Fehlerbeschreibung dient der Definition von Fehlerkriterien für die potentiellen Ausfallsmechanismen, basierend auf den physikalischen Modellen, historischen Daten, Anlagenspezifikationen oder anderen vorhandenen Standards. Die Modellierung der Abnutzung versteht sich als Prozess des Lernen bzw. der Vorhersage des Verhaltens

der Modellparameter, welche stark mit dem Versagen korrelieren. Die vorhandene Restnutzungsdauer wird schlussendlich dadurch prognostiziert, in dem bestimmt wird, ob und wann die vorhergesagten Parameter die Fehlerkriterien aus der Fehlerbeschreibung erfüllen. [KHF+16]

### 3.2.5 NUTZUNGSABHÄNGIGE INSTANDHALTUNG

Einen der prädiktiven Instandhaltung sehr ähnlichen Ansatz verfolgt die nutzungsabhängige Instandhaltung, welche mit allgemeiner Gültigkeit von [Wen13] für die Technische Logistik entwickelt wurde. Ausgangspunkt der Überlegungen bildet bei der nutzungsabhängigen Instandhaltung die Kenngröße „Abnutzungsvorrat“ von Betrachtungseinheiten (z.B. ein System, Gerät, Bauelement, Teil, etc.) wie sie in [DIN 31051] definiert ist. Der Begriff Abnutzungsvorrat bezeichnet „einen Vorrat der möglichen Funktionserfüllungen unter festgelegten Bedingungen, der einer Einheit aufgrund der Herstellung, Instandsetzung oder Verbesserung innewohnt“ [DIN 31051].

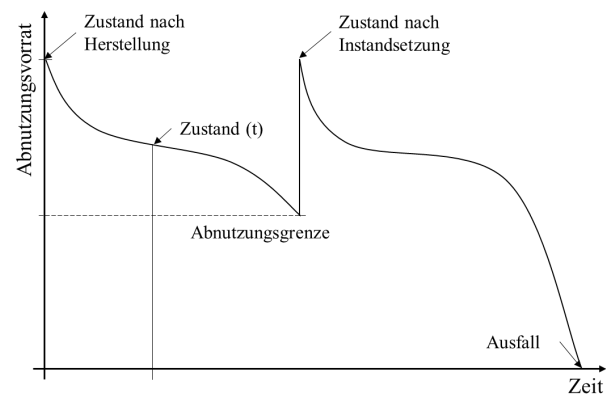


Abbildung 5. Beispielhafter Verlauf einer Abbaukurve des Abnutzungsvorrates nach [Mat19]

Alle Betrachtungseinheiten unterliegen während der Nutzung je nach Belastungen und Beanspruchungen unterschiedlichen Abnutzungsarten, die den Vorrat im zeitlichen Verlauf verringern. Der Verlauf des Abnutzungsvorrates kann beschrieben werden, wenn das genaue Nutzungsprofil bekannt ist. Die Abnutzungsgrenze wird durch einen festgelegten Mindestwert definiert und markiert das Ende der Funktionsfähigkeit einer Betrachtungseinheit. Da für die nutzungsabhängige Instandhaltung der direkte Zusammenhang zwischen der Nutzung und Abnutzung von Bauteilen intralogistischer Systeme notwendig ist, diese Informationen jedoch oft nicht in vollem Umfang bekannt sind, steht ein Prognosemodell als Werkzeug zur Verfügung, um die restliche Nutzungsdauer abschätzen zu können. [WB09]

Zur Erstellung eines Prognosemodell nach [WB09], wie es in Abbildung 6. dargestellt ist, müssen insgesamt sechs Prozessschritte ausgearbeitet werden. Zunächst müssen die kritischen Bauteile durch entsprechende Strukturierung und Priorisierung des zu untersuchenden Intralogistiksystems ermittelt werden. Die Charakteristika der betreffenden Betrachtungseinheiten werden im zweiten

Schritt genauer spezifiziert. Der dritte Schritt kann als zentraler Bestandteil gesehen werden, da das Nutzungsprofil der ausgewählten Komponenten, basierend auf Daten der Anlagensteuerungen, ERP-, WMS- und anderer Systeme, erstellt wird.

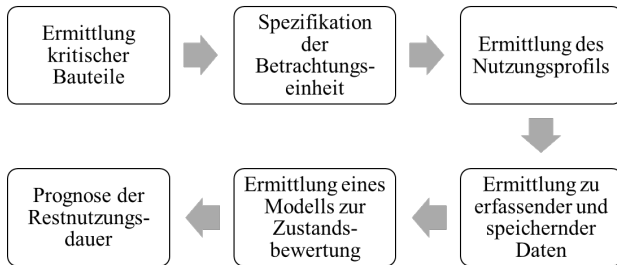


Abbildung 6. Vorgehen zur Entwicklung von Prognosemodellen nach [WB09]

Im vierten Schritt werden die zu erfassenden zusätzlichen Daten ermittelt, wobei auch hier besonderes Augenmerk auf jene relevanten Daten gelegt werden soll, die abnutzungsfördernde Faktoren darstellen. Im vorletzten Schritt wird das Modell zur Vorhersage des zeitlichen Verlaufs entwickelt. Das Modell sollte dabei jedoch nicht starr sein, sondern mit den weiter gewonnenen Daten und Erkenntnissen fortlaufend angepasst werden. Schlussendlich wird im letzten Schritt eine Prognose der Restnutzungsdauer vorgenommen. [WB09]

Den Ablauf zur Erstellung der Prognose, der selbst wieder in mehrere Schritte unterteilt werden kann, zeigt Abbildung 7. Es wird zunächst über ein Zustandsüberwachungssystem der aktuelle Zustand erfasst. Aus den kontinuierlichen Daten lässt sich anschließend der aktuelle Ist-Zustand mittels geeigneter Datenanalysen ermitteln. Dieser wird mit dem Soll-Zustand, welcher historische Informationen interner und externer Einflussfaktoren berücksichtigt, verglichen. Unter Berücksichtigung zukünftiger Nutzung wird eine Prognose zur Restnutzungsdauer der Betrachtungseinheit erstellt und in der Planung der Instandhaltungsmaßnahmen berücksichtigt. [WB09]

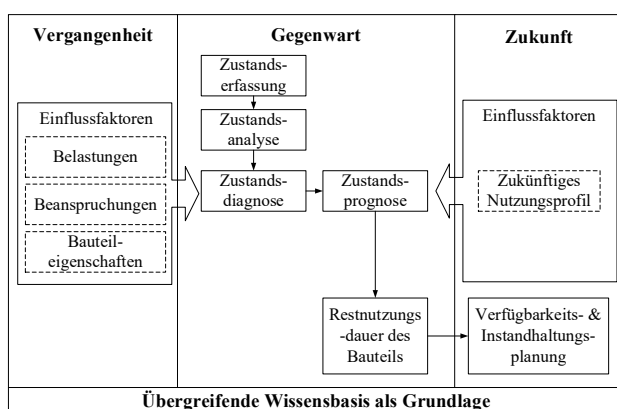


Abbildung 7. Ablauf einer Prognose nach [WB09, AHK16]

## 4 INSTANDHALTUNG IM KONTEXT DER INDUSTRIE 4.0

In [AHK16] wird der Forschungsbedarf genannt, die Konzepte prädiktiver bzw. nutzungsabhängiger Instandhaltung in IT-gestützte Systeme zu integrieren, um nicht nur die bereits vorhandene Wissensbasis für Intralogistiksysteme nutzbar machen zu können, sondern darüber hinaus im Umfeld der Industrie 4.0 ein umfangreiches Wissensnetzwerk für Anlagenhersteller bzw. -betreiber aufzubauen. Hierfür finden sich in der Literatur ebenso bereits Konzepte und auch Technologien des Industrial Internet of Things, die dazu geeignet sind eine breite Implementierung voranzutreiben.

### 4.1 DER DIGITALE ZWILLING

Der Begriff des „Digitalen Zwilling“ taucht als Konzept vermehrt im Kontext der Industrie 4.0 auf. Oftmals dient der Begriff als Schlagwort, denn es existiert in der Literatur keine einheitliche Definition. Dennoch handelt es sich speziell für die beschriebenen Aufgaben fortgeschrittener Instandhaltungsstrategien um ein erfolgsversprechendes Konzept. Erstmalige Erwähnung fand der digitale Zwilling bei Dr. Grieves an der University of Michigan [GV16]. Er führte den Begriff ursprünglich als konzeptionelles Ideal des Product Lifecycle Managements ein. Der grundlegende Gedanke war, dass jedes System aus einem realen und einem virtuellen System besteht und dass durch Informationsaustausch zwischen beiden eine Repräsentation über den gesamten Lebenszyklus möglich ist. Der Begriff wurde ebenso von der NASA aufgegriffen, welche bereits seit dem Apollo-Programm reale Zwillinge für ihre Raumfähren verwendete. In einem Strategiepapier definierte sie den digitalen Zwilling erstmals als eine „integrierte multi-physikalische, hochskalierende probabilistische Simulation, welche die geeignetsten verfügbaren physikalischen Modelle, aktuelle Sensordaten und historische Flottendaten verwendet, um ein oder mehrere echte Flugsysteme zu spiegeln. Die relevanten Daten werden über den gesamten Lebenszyklus kontinuierlich gesammelt und in Echtzeit an den digitalen Zwilling übertragen“ [SCD+10]. Der digitale Zwilling kann aber nicht nur den aktuellen, sondern auch historische und alternative Zustände des Systems für eine genauere Analyse darstellen. Durch Kombination aller Informationen prognostiziert der digitale Zwilling kontinuierlich den Zustand des Systems, sowie die verbleibende Nutzungsdauer. Er kann unbekannte Probleme aufdecken, bevor sie kritisch werden [GS12].

Wie aus der Literaturanalyse über Digitale Zwillinge in [NFM17] hervorgeht, fand der Begriff des Digitalen Zwillinges sukzessive Einzug in andere Bereiche wie bspw. der Produktion und Fertigung in Zusammenhang mit Industrie 4.0. In diesem Kontext nimmt der digitale Zwilling in der Literatur verschiedene Rollen ein:

- Als ein Modell des Systems, auf dem verschiedenen Typen von Simulationen aufbauen.

- Als Instrument um die Instandhaltungsaktivitäten durch Diagnose und Prognose innerhalb des Lebenszyklus zu unterstützen.

[KW18] definiert den digitalen Zwilling eines realen Objekts zusammenfassend als die Summe aller logisch zusammenhängenden Daten, d.h. Engineering- und Betriebsdaten, die durch ein semantisches Datenmodell repräsentiert werden. Während konstruktive Daten einmal generiert und bei Bedarf aktualisiert werden, z.B. CAD-Modelle, spezifische Simulationsmodelle oder Materialspezifikationen, werden Betriebsdaten in Echtzeit erfasst und verarbeitet. Nach dieser Definition kann der digitale Zwilling ebenso historische und Echtzeit-Zustände des physikalischen Objekts darstellen. Darüber hinaus können Simulationen verschiedener Disziplinen durchgeführt werden, indem bestehende Modelle verwendet bzw. neue Modelle generiert werden, die nicht nur eine virtuelle Darstellung des physischen Objekts in Echtzeit, sondern auch eine prognostische Bewertung ermöglichen. [KW18, NFM17]

Aus diesen Definitionen schlussfolgernd, ist der digitale Zwilling im Kontext dieses Beitrags, als eine virtuelle Repräsentation intralogistischer Systeme zu sehen, die sich eines Informationssystems zur Nutzung verschiedener Datensätze bedient und in der Folge die Anwendung hybrider Modellsätze der prädiktiven Instandhaltung möglich macht.

#### 4.2 CYBER-PHYSICAL-LOGISTICS-SYSTEMS

Ein System, das die Erfassung physikalischer Prozesse, die informationstechnische Verarbeitung von Daten in Simulationen und eine anschließende Rückkoppelung zum steuernden Eingriff in intralogistische Systeme ermöglicht, ist das Konzept des Cyber-Physischen-Systems (CPS).

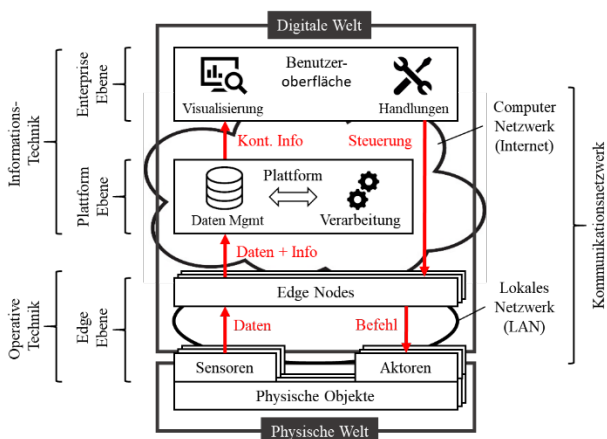


Abbildung 8. Aufbau eines Cyber-Physischen-Systems für die Intralogistik nach [MEH+19]

Wie in Abbildung 8. ersichtlich, werden die gesammelten Daten des physischen Objektes mittels „Edge-Computings“ vorverarbeitet und über Netzwerke mit geeigneten

Kommunikationsprotokollen wie bspw. „OPC UA over TSN“ an IoT-Plattformen zur Speicherung und Verarbeitung in Simulationsmodellen oder mittels anderer Algorithmen gesendet. Ein Human-Machine-Interface (HMI) ermöglicht die gezielte Visualisierung von Zuständen für den Anlagennutzer, ebenso wie eine eingreifende Steuerung des Systems. Eine Ansammlung von logistischen Elementen, welche die Kriterien von CPS erfüllen und miteinander bzw. mit Menschen interagieren, werden nach [VLH+13] auch als cyber-physisches Logiksystem bezeichnet. Diese Definition ist analog zu den Cyber-Physischen-Produktionssystemen (CPPS) zu sehen, deren Entstehung in der Literatur der Produktionstechnik bereits einen Paradigmenwechsel von deskriptiver zu prädiktiver und sogar zu präskriptiver Instandhaltung ausgelöst hat [NKB+18].

#### 5 KNOWLEDGE-BASED MAINTENANCE IN DER INTRALOGISTIK

In [Paw13] wird die wissensbasierte Instandhaltung beschrieben, welche davon ausgeht, dass eine atomistische Betrachtung relevanter Systemkomponenten zur vorausschauenden Bestimmung notwendiger Instandhaltungsmaßnahmen und deren zugehörige Zeitpunkte nicht ausreicht, da Maßnahmen an einzelnen Subkomponenten immer eine Auswirkung auf das gesamte Systemverhalten haben [Paw13, NKB+18]. Es bedarf vielmehr einer holistischen Betrachtung die in einem systemorientierten Ansatz die Ergebniswirkung auf das Gesamtsystem berücksichtigt. Der wissensbasierte Ansatz umfasst daher drei Einflussbereiche der Instandhaltung und ihrer Zusammenhänge, wie Abbildung 9. dargestellt [Paw13].

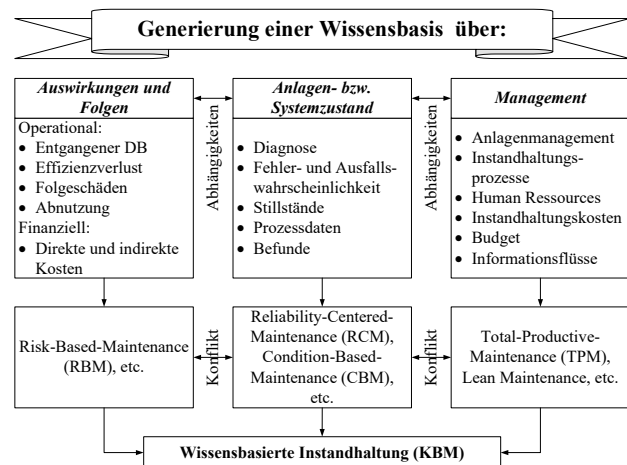


Abbildung 9. Grundlegendes Modell und Datenbasis für die wissensbasierte Instandhaltung nach [Meh02] in [Paw13, AGN19]

Das Konzept der Knowledge-Based-Maintenance (KBM) wird in [AGN19] aufgegriffen und in den Kontext von Cyber-Physischen-Produktionssystemen (CPPS) gesetzt, wobei sich KBM dabei als Teil von „Knowledge Based Systems - KBS“ und den zugehörigen Ansätzen zur

Wissensmodellierung und –repräsentation versteht. Das Hauptziel ist es, auf die Logik der Beziehungen zwischen den verschiedenen Instandhaltungsansätzen, sowie auf die unterschiedlichen Arten und die Homogenität von Wissensbeständen einzugehen und als funktionale Einheit die Wertschöpfungskette durch Generierung, Nutzung und Erhalt des relevanten Wissens der Instandhaltung zu unterstützen. KBM im Kontext von CPPS kann in vier Typen untergliedert werden, welche je nach Reife- und Komplexitätsgrad eine bestimmte Fragestellung beantworten können. Die deskriptive Instandhaltung (Typ I) beantwortet die Frage „Was ist passiert?“, durch das zur Verfügung stellen von Informationen vergangener Instandhaltungsmaßnah-

men. Die diagnostische Instandhaltung (Typ II) beantwortet die Frage „Warum ist es passiert?“, durch die Analyse von Ursache-Wirkungsbeziehungen und dem Schlussfolgern aus den Details historischer Instandhaltungsdaten. Die prädiktive Instandhaltung (Typ III) beantwortet die Frage „Was wird wann passieren?“, durch das Lernen aus historischen und echtzeitbasierten Informationen, sowie dem Prognostizieren zukünftiger Ereignisse. Der Wissenszuwachs wird mittels der bereits beschriebenen Algorithmen des maschinellen Lernens erreicht. Die präskriptive Instandhaltung (Typ IV) beantwortet die Frage „Wie kann das Auftreten spezifischer Ereignisse kontrolliert werden?“, durch das Einbinden eines Entscheidungsunterstützungssystems (Decision Support System - DSS) [Mat19].

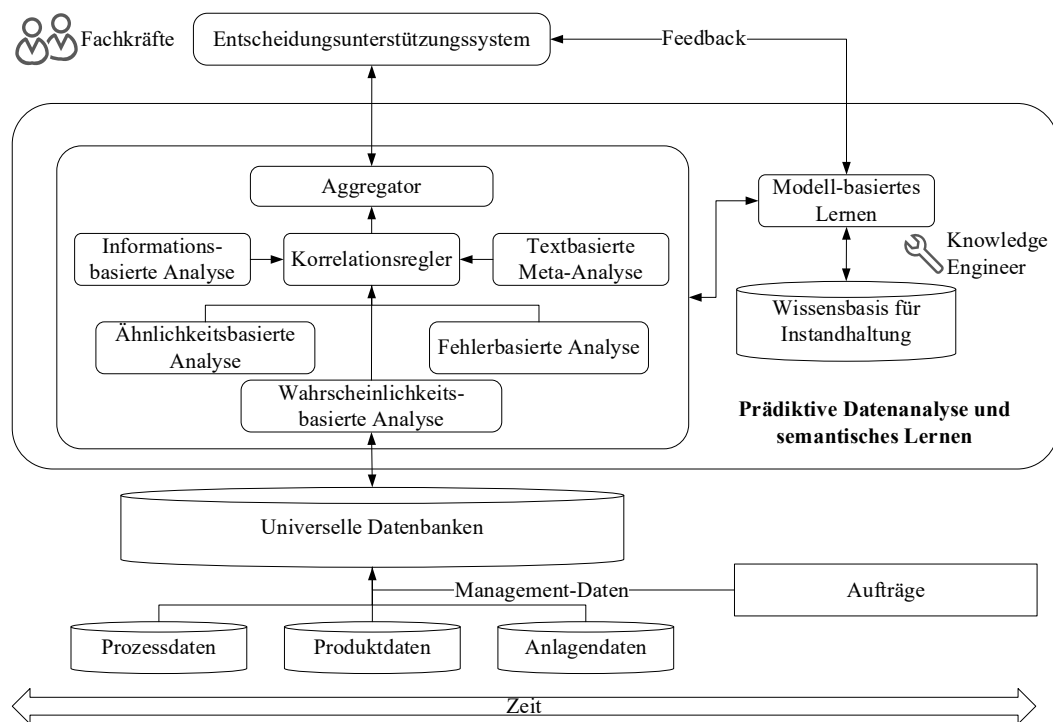


Abbildung 10. Architektur des sogenannten „Prescriptive Maintenance Models - PriMa“ nach [Mat19, AGN19, NAS+18]

In [AGN19, NAS+18] wird ein Referenzmodell zur Implementierung von KBM im industriellen Umfeld vorgestellt. Das präskriptive Instandhaltungsmodell (Prescriptive Maintenance Models - PriMa), das in Abbildung 10. gezeigt wird, stellt eine Architektur dar, welche die verschiedenen Instandhaltungsstrategien, die Mehrdimensionalität von Instandhaltungsprozessen und die Multimodalität und Heterogenität von Instandhaltungsaufzeichnungen in Verbindung mit Produktionsplanungssystemen vereint. Das PriMa-Modell setzt sich aus folgenden drei Ebenen zusammen: erstens der Ebene des Datenmanagement, zweitens der Ebene der prädiktiven Datenanalyse und des semantischen Lernens und drittens einem Empfehlungssystem in Form eines interaktiven „Dashboards“. Die erste Ebene umfasst universelle Datenbanken, welche die kontinuierlichen Aufzeichnungen von betriebswirtschaftlichen- und operativen Daten aus drei Kategorien

(Maschinendaten, Prozessdaten und Produktdaten) aus den verschiedenen Informationssystemen wie bspw. SCADA, MES oder ERP bereitstellt. Durch die semantische Verknüpfung der verschiedenen Datensätze wird PriMa der Multimodalität von Instandhaltungsaufzeichnungen, Störungs- und Wartungsdokumentationen gerecht. In der zweiten Ebene kommen je nach Anwendungsfall und Zielsetzung die verschiedenen Verfahren des maschinellen Lernens bzw. Algorithmen der Wissensgenerierung zum Einsatz. Es wird dabei zwischen informationsbasierten, ähnlichkeitsbasierten, wahrscheinlichkeitsbasierten und fehlerbasierten Lernverfahren nach [KMD15] unterschieden. Die in der dritten Ebene getroffenen, informationsgestützten menschlichen Entscheidungen, können mittels verschiedener Methoden des semantischen Lernens wie bspw. Ontologien oder des fallbasierten Schließens (Case Based Reasoning - CBR) zusammen mit den Erkenntnissen



der prädiktiven Analyse eine stets aktuelle Wissensdatenbank für die Instandhaltung aufbauen. [AGN19, Mat19]

Ein entsprechendes Referenzmodell wie PriMa ist für cyber-physische Logistiksysteme derzeit nicht bekannt. Insofern besteht Forschungs- und Entwicklungsbedarf, ein auf PriMa aufbauendes oder ein, dieser Architektur ähnliches, Referenzmodell für Cyber-physische Logistiksysteme zu schaffen.

## 6 FAZIT UND AUSBLICK

Vor dem Hintergrund der Digitalisierung im Sinne der Industrie 4.0 wurde im vorliegenden Beitrag ein Bogen zwischen etablierten Instandhaltungsstrategien und den Konzepten vorausschauender, nutzungsabhängiger und der visionären präskriptiven Instandhaltung gespannt.

Obwohl die einfache korrektive bzw. präventive Instandhaltung in der Praxis dominieren, gibt es bereits wissenschaftliche Erkenntnisse zur erweiterten Zustandsüberwachung intralogistischer Systeme. Diese basieren hauptsächlich auf physikalischen Modellen, welche die Fehlermechanismen genau abbilden, sich jedoch aufgrund ihrer Komplexität auf einzelne betrachtete Anwendungsfälle beschränken. Datengesteuerte Modelle hingegen sind nicht auf die exakte Modellierung des Systemverhaltens angewiesen, sondern nutzen aussagekräftige Daten um charakteristische Merkmale, Muster und Trends zu erkennen. In vielen Unternehmen ist eine entsprechend große Datenbasis oftmals nicht vorhanden. Durch die Kombination physikalischer und datengesteuerter Modelle können die Vorteile beider Ansätze genutzt werden, um aussagekräftige Vorhersagen zur Restnutzungsdauer machen zu können. In der Literatur finden sich Machbarkeitsnachweise, die den Einsatz datengesteuerter und hybrider Modellansätze rechtfertigen. Es besteht in diesem Umfeld für die Wissenschaft und Praxis der technischen Logistik Handlungsbedarf, die Methoden umfänglich aufzugreifen und einzusetzen.

Zur Erstellung eines Prognosemodells bedarf es eines methodischen Vorgehens, das die kritischen Bauteile identifiziert, Nutzungsprofile berücksichtigt und die notwendigen Datensätze zur Modellierung der Zustandsbewertung ermittelt. Die Gesamtheit aller logisch zusammenhängenden Daten, die durch ein semantisches Datenmodell repräsentiert werden kann, bezeichnet man als digitalen Zwilling eines intralogistischen Systems. Dieses Konzept eignet sich um vorhandene statische Planungs-, Wartungs- bzw. Stördaten, sowie Betriebs- und Auftragsdaten in Echtzeit mit Hilfe cyber-physischer Systeme zu verbinden und dadurch die Anwendung hybrider Modellansätze der prädiktiven Instandhaltung zu ermöglichen.

Die Betrachtung einzelner Systemkomponenten zur Bestimmung notwendiger Instandhaltungsmaßnahmen al-

leine ist nach den Methoden der wissensbasierten Instandhaltung jedoch nicht ausreichend. Sie versucht daher eine ganzheitliche Betrachtung in einem systemorientierten Ansatz vorzunehmen und schließt die Einflüsse von Systemzuständen, Ansätze und Entscheidungen des Instandhaltungsmanagements, sowie Erkenntnisse über Auswirkungen auf das Gesamtsystem ein. Wissensbasierte Instandhaltung kann auch als Teil von Expertensystemen und den zugehörigen Ansätzen zur Wissensmodellierung und –repräsentation gesehen werden. In der Literatur der Produktionstechnik ist die wissensbasierte Instandhaltung für Cyber-Physische-Produktionssysteme bereits beschrieben. Es wird eine Referenzarchitektur als Unterstützung zur Implementierung präskriptiver Instandhaltungsstrategien vorgeschlagen, welche die Mehrdimensionalität von Instandhaltungsprozessen und die Heterogenität von Instandhaltungsdaten berücksichtigt. Durch den Einsatz datenwissenschaftlicher Methoden zur prädiktiven Analyse und des semantischen Lernens, unter Einbeziehung des Wissens der mit den Systemen arbeitenden Fachkräfte, wird eine Wissensdatenbank der Instandhaltung aufgebaut.

In der Technischen Logistik bedarf es eines vergleichbaren Ansatzes zur gesamtheitlichen Betrachtung. Es ist das Bestreben der Autoren, diese Lücke mit weiterer Forschungsarbeit zu schließen. Das Thema „Predictive Maintenance in der Intralogistik“ stellt einen neuen Forschungsschwerpunkt am Institut für Technische Logistik der Technischen Universität Graz dar, in dessen Rahmen sich ebenso das Dissertationsvorhaben des Erstautors bewegt. Es sollen hybride Modellansätze genauer beleuchtet und die beschriebenen Konzepte enger zusammengeführt werden, sodass basierend auf CPLS und digitalen Zwillingen die prädiktive und/oder präskriptive Instandhaltung intralogistischer Anlagen in einem holistischen Ansatz möglich wird.

## LITERATUR

- [AGN19] Ansari, F.; Glawar, R.; Nemeth, T.: PriMa: a prescriptive maintenance model for cyber-physical production systems. In *International Journal of Computer Integrated Manufacturing*, 2019, 32; S. 482–503.
- [AHK16] Austerjost, M.; Hegmanns, T.; Kuhn, A.: *Beitrag einer nutzungsabhängigen Instandhaltung zur Planung von Leistungsverfügbarkeit*, 2016.
- [Arn06] Arnold, D.: Einleitung des Herausgebers. In (Arnold, D. Hrsg.): *Intralogistik. Potentiale, Perspektiven, Prognosen*. Springer, Berlin, 2006; S. 1–4.
- [DIN 31051] DIN 31051:2012-09, *Grundlagen der Instandhaltung*.

- [DIN EN 13306] DIN EN 13306:2018-02, Instandhaltung.
- [Dul08] Dullinger, K.-H.: Quo Vadis - Material Handling. Vanderlande Industries Ges, Mönchengladbach, 2008.
- [GMZ16] Gouriveau, R.; Medjaher, K.; Zerhouni, N.: From prognostics and health systems management to predictive maintenance 1. Monitoring and prognostics. Wiley, Hoboken, NJ, 2016.
- [GS12] Glaessgen, E.; Stargel, D.: The Digital Twin Paradigm for Future NASA and U.S. Air Force Vehicles. In (American Institute of Aeronautics and Astronautics Hrsg.): Structures, Structural Dynamics, and Materials and Co-located Conferences. 53rd AIAA/ASME/ASCE/AHS/ASC Structures, Structural Dynamics and Materials Conference. [s.n.], [S.l.], 2012; 22267B.
- [GV16] Grieves, M.; Vickers John: Origins of the Digital Twin Concept, 2016.
- [KHF+16] Kwon, D. et al.: IoT-Based Prognostics and Systems Health Management for Industrial Applications. In IEEE Access, 2016, 4; S. 3659–3670.
- [KKB07] Kuhn, A.; Kohlmann, B.; Bandow, G.: Wissensbasis für eine nutzungsabhängige Instandhaltung von Intralogistiksystemen. In (Crostack, H.-A. Hrsg.): Forderungsgerechte Auslegung von intralogistischen Systemen. Logistics on Demand ; 1. Kolloquium am 20. Februar 2007. Verl. Praxiswissen, Dortmund, 2007; S. 187–200.
- [KKW08] Kuhn, A.; Kohlmann, B.; Wenzel, S. D.: Zuverlässigkeit von Intralogistiksystemen. Überdimensionierung vs. nutzungsabhängige Instandhaltung. In (Seeliger, A. Hrsg.): AKIDA. 18./19. November 2008 ; [7.] Aachener Kolloquium für Instandhaltung, Diagnose und Anlagenüberwachung ; [Tagungsband. Zillekens, Stolberg, 2008.
- [KMD15] Kelleher, J. D.; MacNamee, B.; D'Arcy, A.: Fundamentals of machine learning for predictive data analytics. Algorithms, worked examples, and case studies. The MIT Press, Cambridge, Massachusetts, London, England, 2015.
- [KW18] Kunath, M.; Winkler, H.: Integrating the Digital Twin of the manufacturing system into a decision support system for improving the order management process. In Procedia CIRP, 2018, 72; S. 225–231.
- [LWZ+14] Lee, J. et al.: Prognostics and health management design for rotary machinery systems—Reviews, methodology and applications. In Mechanical Systems and Signal Processing, 2014, 42; S. 314–334.
- [Mat19] Matyas, K. Hrsg.: Instandhaltungslogistik. Qualität und Produktivität steigern. Hanser, München, 2019.
- [MEH+19] Mörth, O. et al.: Implementierung eines Cyber-Physischen Systems in der Intralogistik. IoT in Fördertechnologie. In (Landschützer, C. Hrsg.): Solution day - "update". Logistikwerkstatt Graz 2019, 22. Mai 2019, 2019.
- [Meh02] Mehldau, J.: Wissen basierte Instandhaltung. Quantifizierung von Verbesserungspotenzialen durch Optimierung der Instandhaltungsstrategien. Diplomarbeit, Harburg, 2002.
- [Mob02] Mobley, R. K.: An introduction to predictive maintenance. Butterworth-Heinemann, Amsterdam, New York, 2002.
- [MR10] Maimon, O. Z.; Rokach, L.: Data mining and knowledge discovery handbook. Springer, New York, 2010.
- [NAS+18] Nemeth, T. et al.: PriMa-X: A reference model for realizing prescriptive maintenance and assessing its maturity enhanced by machine learning. In Procedia CIRP, 2018, 72; S. 1039–1044.
- [NFM17] Negri, E.; Fumagalli, L.; Macchi, M.: A Review of the Roles of Digital Twin in CPS-based Production Systems. In Procedia Manufacturing, 2017, 11; S. 939–948.
- [NKB+18] Nemeth, T. et al.: Mittels Machine Learning und innovativen IoT-Technologien zur »Predictive Maintenance«. Prognose der Overall Equipment Effectiveness: Eine Case Study. In (Biedermann, H. Hrsg.): Predictive Maintenance. Realität und Vision 32. Instandhaltungsforum, 2018; S. 103–116.
- [Paw13] Pawellek, G.: Integrierte Instandhaltung und Ersatzteillogistik. Vorgehensweisen, Methoden, Tools. Springer, Berlin, Heidelberg, 2013.

- [PSK+16] Pecht, M. et al.: A fusion prognostics-based qualification test methodology for microelectronic products. In *Microelectronics Reliability*, 2016, 63; S. 320–324.
- [SCD+10] Shafto, M. et al.: *DRAFT Modeling, Simulation, Information Technology & Processing Roadmap*, 2010.
- [SSB+15] Sutharssan, T. et al.: Prognostic and health management for engineering systems: a review of the data-driven approach and algorithms. In *The Journal of Engineering*, 2015, 2015; S. 215–222.
- [Ste10] Stecki, J. S.: *The Rise and Fall of CBM*, Bukarest, 2010.
- [Stö19] Stöhr, T.: *Steigerung der Energieeffizienz von Stückgutstetigförderern durch optimierte Antriebssystemauswahl*, 2019.
- [VLH+13] Veigt, M. et al.: Entwicklung eines Cyber-Physischen Logistiksystems. In (Scholz-Reiter, B. Hrsg.): *Industrie Management 1/2013 - Vierte industrielle Revolution*. GITO mbH Verlag, 2013; S. 15–18.
- [WB09] Wenzel, S. D.; Bandow, G.: Prognosemodell für den Abnutzungsvorratsverlauf von Intralogistiksystemkomponenten. In (Bandow, G.; Holzmüller, H. H. Hrsg.): „Das ist gar kein Modell!“. *Unterschiedliche Modelle und Modellierungen in Betriebswirtschaftslehre und Ingenieurwissenschaften*. Gabler Verlag / Springer Fachmedien Wiesbaden GmbH Wiesbaden, Wiesbaden, 2009; S. 295–309.
- [WB11] Wenzel, S.; Bandow, G.: Condition monitoring in logistics—a new approach for maintenance. In (International Institute of Informatics and Systemics - IIIS Hrsg.): *ICEME 2011. 2nd International Conference on Engineering and Meta-Engineering*, 2011; S. 27–30.
- [Wel06] Welsch, V.: Das automatische Lager und seine intralogistischen Aufgaben. In (Arnold, D. Hrsg.): *Intralogistik. Potentiale, Perspektiven, Prognosen*. Springer, Berlin, 2006; 168-.
- [Wen13] Wenzel, S. D.: *Nutzungsabhängige Instandhaltung intralogistischer Systeme*. Zugl.: Dortmund, Techn. Univ., Diss., 2013. Verl. Praxiswissen, Dortmund, 2013.

---

**Dipl.-Ing. Michael Schadler, BSc.**, Universitätsassistent am Institut für Technische Logistik  
Tel: +43 316 873-7332, E-Mail: [schadler@tugraz.at](mailto:schadler@tugraz.at)

**Ass.Prof. Dipl.-Ing. Dr.techn. Norbert Hafner**, stellv. Institutsleiter am Institut für Technische Logistik  
Tel: +43 316 873-7329, E-Mail: [norbert.hafner@tugraz.at](mailto:norbert.hafner@tugraz.at)

**Assoc.Prof. Dipl.-Ing. Dr.techn. Christian Landschützer**, stellv. Institutsleiter am Institut für Technische Logistik  
Tel: +43 316 873-7325, E-Mail: [landschuetzer@tugraz.at](mailto:landschuetzer@tugraz.at)

Adresse: Institut für Technische Logistik, Technische Universität Graz, Inffeldgasse 25E, 8010 Graz, Österreich