

Schlussbericht

Künstliche Intelligenz für Energietechnologien und Anwendungen in der Produktion (KI4ETA)

Gemeinsamer Schlussbericht

Förderbereich: Energieeffizienz in Industrie und Gewerbe, Handel und Dienstleistungen (GHD)
Förderkennzeichen: 03EN2053 A - L

Verbundpartner:

A	Technische Universität Darmstadt
B	Deutsches Forschungszentrum für Künstliche Intelligenz GmbH
C	atlan-tec Systems GmbH
D	Robert Bosch GmbH
E	EJOT SE & Co. KG
F	ENTEKA AG
G	etalytics GmbH
H	Evonik Resource Efficiency GmbH
I	GreenDelta GmbH
J	ÖKOTEC Energiemanagement GmbH
K	Software AG
L	TÜV Technische Überwachung Hessen GmbH

Laufzeit: 01.06.2021 – 30.11.2024

Darmstadt, den 30.04.2025

ptj projektträger
jülich

Gefördert durch:



Bundesministerium
für Wirtschaft
und Klimaschutz

aufgrund eines Beschlusses
des Deutschen Bundestages

Projektleitung:

Prof. Dr.-Ing. Matthias Weigold

Technische Universität Darmstadt

Leiter des Instituts für Produktionsmanagement, Technologie und Werkzeugmaschinen (PTW)

Otto-Berndt-Str. 2

64287 Darmstadt

Tel.: +49 (0) 6151 16 20080

Fax: +49 (0) 6151 16 20087

E-mail: m.weigold@ptw.tu-darmstadt.de

Autorinnen und Autoren:**PTW TU Darmstadt**

Borys Ioshchikhes, Benedikt Grosch, Heiko Ranzau, Daniel Fuhrländer-Völker, Jessica Jürgensen, Johannes Sossenheimer, Magnus von Elling, Andreas Clement, Tobias Lademann, Jan Zangenberg, Robin Zink, Matthias Weigold

IMS TU Darmstadt

Thomas Franzelin, Sarah Schwarz

Deutsches Forschungszentrum für Künstliche Intelligenz GmbH

Leonhard Kunz, Philipp Richard, Al-Harith Farhad, Snehal Walunj, Ali Nazeri, Satyam Dudhagara

atlan-tec Systems GmbH

Roland Maier, Andreas Krüger

Robert Bosch GmbH

Michael Walther

EJOT SE & Co. KG

Dennis Kekec

ENTEKA AG

Nils Roloff

etalytics GmbH

Niklas Panten, Tim Dorau

Evonik Resource Efficiency GmbH

Christoph Wincierz

GreenDelta GmbH

Andreas Ciroth, Jonas Hoffmann

ÖKOTEC Energiemanagement GmbH

Arne Grein

Software AG

Gerald Ristow

TÜV Technische Überwachung Hessen GmbH

Lars Komrowski

CuroCon GmbH

Michael Wißbach, Andreas Ekhardt

Mader GmbH & Co. KG

Marina Griesinger

Förderhinweis: Gefördert vom Bundesministerium für Wirtschaft und Klimaschutz aufgrund eines Beschlusses des Deutschen Bundestags. Die Verantwortung für den Inhalt dieser Veröffentlichung liegt bei den Autorinnen und Autoren.

Inhaltsverzeichnis

1.	Kurzdarstellung des Forschungsprojekts	1
1.1.	Aufgabenstellung	1
1.2.	Voraussetzungen des Vorhabens	3
1.3.	Planung und Ablauf des Forschungsvorhabens	5
1.4.	Wissenschaftlicher und technischer Stand zu Vorhabensbeginn.....	9
1.5.	Zusammenarbeit der Partner	16
2.	Wissenschaftlich-technische Forschungsergebnisse	23
2.1.	Teilprojekt 1: Smarte Energiemanagementplattform	23
2.2.	Teilprojekt 2: Vernetzung & Sicherheit.....	38
2.3.	Teilprojekt 3: Energetische Transparenzschaffung & Monitoring	59
2.4.	Teilprojekt 4: Datenbasierte Modellerstellung, -parametrierung & Auswertung	88
2.5.	Teilprojekt 5: Ganzheitliche Betriebsstrategieoptimierung.....	115
2.6.	Teilprojekt 6: Sektorenkopplung	150
2.7.	Teilprojekt 7: Anwendung, Bewertung & Übertragbarkeit	169
3.	Voraussichtlicher Nutzen der Arbeitsergebnisse	195
3.1.	Teilprojekt 1: Smarte Energiemanagementplattform	195
3.2.	Teilprojekt 2: Vernetzung & Sicherheit.....	196
3.3.	Teilprojekt 3: Energetische Transparenzschaffung & Monitoring	197
3.4.	Teilprojekt 4: Datenbasierte Modellerstellung, -parametrierung & Auswertung	197
3.5.	Teilprojekt 5: Ganzheitliche Betriebsstrategieoptimierung.....	198
3.6.	Teilprojekt 6: Sektorenkopplung	200
3.7.	Teilprojekt 7: Anwendung, Bewertung & Übertragbarkeit	201
4.	Veröffentlichungen und Teilnahme an Tagungen, Messen o.Ä.	203
4.1.	Wissenschaftliche Veröffentlichungen	203
4.2.	Teilnahme an Tagungen, Messen o.Ä.	205
4.3.	Dissertationen	206
5.	Abkürzungsverzeichnis	207
6.	Literaturverzeichnis	209

1. Kurzdarstellung des Forschungsprojekts

1.1. Aufgabenstellung

Die Bundesregierung strebt in ihrem Klimaschutzplan 2050 eine Senkung der Treibhausgasemissionen der deutschen Industrie um etwa 50 % im Vergleich zu 1990 bis zum Jahr 2030 an [1]. Ein wichtiger Baustein, um dieses Ziel zu erreichen ist eine Steigerung der Energieeffizienz in den Betrieben. In vielen Unternehmen werden die Steigerung der Energieeffizienz und das Senken von Energiekosten jedoch bisher als Randthema behandelt und die mit dieser Aufgabe betrauten Energiemanager der Unternehmen sind oft auf sich allein gestellt [2]. Hinzu kommt, dass Energiesysteme hochkomplex sind und ihre Beherrschung bzw. ihre Optimierung hin zu einer höheren Energieeffizienz vielseitiges und breites Know-how benötigt, das oftmals nur durch interdisziplinäre Teams bereitgestellt werden kann. Eine extern beauftragte Energieberatung kann hier Abhilfe verschaffen, ist aber, verglichen mit den identifizierten Einsparpotenzialen, für viele kleine und mittelständische Unternehmen oft zu teuer [3].

Ziel des Forschungsprojektes KI4ETA ist, einen disruptiven Beitrag auf dem Weg zur CO₂ freien Produktion der Zukunft zu leisten. Dafür muss die Energieeffizienzlücke in der Industrie geschlossen werden. Diese beschreibt die Differenz zwischen technischem und bisher realisiertem Potenzial. Im Projekt KI4ETA wird dafür ein integrierter, plattformbasierter Ansatz, auf der Basis von künstlicher Intelligenz (KI) verfolgt. Das Resultat ist die vollständig digital vernetzte, energieeffiziente und -flexible Fabrik. Die Anlagen der Fabrik sind mit der Energiemanagementplattform verbunden und werden von dieser gesteuert. Gleichzeitig kommuniziert die Energiemanagementplattform beispielsweise mit dem Energieversorger, um die optimale Nutzung verfügbarer Ressourcen zu ermöglichen.

Zwei Zielgruppen sind besonders relevant, um Technologien für Energieeffizienz und -flexibilität in die Industrie zu tragen: Energiemanager bzw. Energieberater sowie Produktions- und Infrastrukturverantwortliche in den Unternehmen. Erstere müssen in die Lage versetzt werden, Potenziale auch in komplexen Systemen zu erkennen und zu bewerten. Währenddessen müssen letztere klar die positiven wirtschaftlichen und energetischen Auswirkungen erkennen und das resultierende System betreiben können. Dafür wird der vollständige Prozess von der Transparenzschaffung und Datenerfassung (Wahrnehmung) bis hin zur Steuerung von Anlagen aus Produktion und Versorgungstechnik (Aktionen) betrachtet und mithilfe von Methoden der künstlichen Intelligenz optimiert, deren Einsatz sich bereits in anderen hoch komplexen Systemen bewährt hat. Dieser ganzheitliche Ansatz ist notwendig, um die Potenziale der KI vollständig auszuschöpfen, deren Aufgabe nach Russel und Norvig entsprechend definiert ist:

„Die Aufgabe der Künstlichen Intelligenz ist das Agentenprogramm zu entwerfen, das die Agentenfunktion implementiert – die Zuordnung von Wahrnehmungen zu Aktionen.“ [4]

Um komplexe industrielle Energiesysteme analysieren und optimieren zu können, nutzen Energiemanager und Energieberatungen verschiedene Energiemanagementsysteme. Fokus der zu entwickelnden Werkzeuge ist deswegen eine einfach zu installierende und zu bedienende, zentrale Energiemanagementplattform. Hier werden erhobene Maschinen-, Gebäude- und Energiedaten erstmalig zusammen zentral gebündelt und verarbeitet. Die daraus entstehende Flut an Energie- und Prozessdaten gilt es zu beherrschen und zielführend auszuwerten. Hierbei soll die Plattform durch integrierte, intelligente Datenverarbeitung unterstützen.

Vor allem ältere Maschinen bieten allerdings keine direkte Möglichkeit zur Datenanbindung und zur Erhebung von Energiedaten. Dies stellt Energiemanagementbeauftragte und Berater vor die Herausforderung, diese Maschinen erst zum Datenaustausch zu befähigen, um Einsparpotentiale ermitteln zu können. Einfach zu installierende, dezentrale, smarte Sensoren und Kommunikationstechnik können hier gezielt unterstützen und Potenziale zur Energieoptimierung sichtbar machen.

Aber auch bei modernen Maschinen, welche über die notwendigen Kommunikationsschnittstellen verfügen und sich somit leichter an Plattformen zur Auswertung anschließen lassen, werden kaum kontinuierliche Energiedatenanalysen hinsichtlich Effizienzsteigerungspotenzialen vorgenommen. Hierfür können die im Projekt zu entwickelnden automatisierten und intuitiven Services und Assistenzsysteme eingesetzt werden, die in die Energiemanagementplattform integriert werden, sodass Energiemanagementbeauftragte die Vielzahl an Herausforderungen und technischen Hürden bei der Identifikation und Umsetzung von Effizienzpotenzialen überwinden können.

Durch den ganzheitlichen Ansatz in KI4ETA sollen die folgenden Ziele erreicht werden:

- Eine smarte Energiemanagementplattform ermöglicht die Datenaufnahme und -verwaltung, sowie die einfache Ausführung der entwickelten Anwendungen.
- Energetische Effizienzmaßnahmen werden automatisiert über datenbasierte Programme auf der smarten Energiemanagementplattform und durch KI auf intelligenten Geräten identifiziert. Ein Beispiel für ein intelligentes Gerät ist der Roboter zum Aufspüren von Druckluftleckagen. Die KI ersetzt komplexe, händische Analysen des Energiesystems und erleichtert dadurch die Arbeit von Energiemanagern und -beratern.
- KI-gestützte Assistenzsysteme und selbstlernende Monitoringalgorithmen erlauben eine Kostensenkung der energetischen Transparenzschaffung, also dem Messen und Visualisieren von Energieströmen, auf Maschinenebene von über 50 %.
- Über ein Prognose-Framework können Energiemanager und -berater ohne Machine Learning Kenntnisse automatisiert eine elektrische Lastprognose mit minimiertem Fehler erstellen. Mit Hilfe dieser Prognose können Verfahren entwickelt werden, um Lastspitzen zu vermeiden und Stromkosten zu senken.
- Durch die zentrale und dezentrale KI-gestützte Betriebsoptimierung des Fabrikbetriebs werden die energiebezogenen Kosten um 20 % im Vergleich zur Regelung mit klassischen stetigen und unstetigen Reglern, wie PID oder Hysterese-Reglern, gesenkt.
- Ein hybrider Energiespeicher und ein neuartiges, bidirektionales Ladesystem für elektrisch betriebene Fahrzeuge werden mithilfe von KI-Ansätzen optimiert, sodass Ihr Energieverbrauch minimiert und der energieeffiziente und -flexible Betrieb der Fabrik unterstützt wird.
- Während der Betriebsregelung durch die KI-Regler ist die Betriebssicherheit und -zuverlässigkeit jederzeit garantiert. Bestehende Qualitätsanforderungen an Produkte und Produktionsprozesse werden eingehalten.
- Durch generische Lösungsformulierung ist die Übertragbarkeit in andere Industrieunternehmen gewährleistet, sodass sich die entwickelten Lösungen besonders gut für den Einsatz durch Energieberatungen eignen.
- Durch Anwendungsfälle in der ETA-Fabrik und im Industrieumfeld, bei Partnern wie Bosch und EJOT, wird sichergestellt, dass industriennahe Lösungen entwickelt werden, die nach Projektende in Produkte übertragen und angewendet werden können.

1.2. Voraussetzungen des Vorhabens

Die KI gilt gemeinhin als zukünftige Schlüsseltechnologie und birgt als solche ein erhebliches volkswirtschaftliches Potenzial. In Sektoren wie beispielsweise dem autonomen Fahren oder der Werbebranche ist KI bereits heute präsent und wird erfolgreich in der Praxis eingesetzt. Auch für das produzierende Gewerbe werden erhebliche volkswirtschaftliche Potenziale vermutet. Nach einer Studie des VDI/VDE wird geschätzt, dass durch den Einsatz von KI im verarbeitenden Gewerbe in den kommenden fünf Jahren eine zusätzliche Bruttowertschöpfung von ca. 31,8 Mrd. Euro möglich ist, was einem Drittel des gesamten prognostizierten Wachstums in diesem Sektor entspricht [5].


Als wichtige Anwendungsmöglichkeiten von KI mit großem technologischem Potenzial werden die Gebiete *Intelligente Sensorik*, *Robotic Process Automation*, *Predictive Analytics* und *Knowledge Management* eingestuft. Der Bereich des ML sowie die Aktionsplanung und Optimierung sind als wichtige Querschnittstechnologien der KI für alle Anwendungen relevant und sollten somit ebenfalls im Rahmen von weiterer Forschung im Fokus stehen [6]. Die Mehrheit der produzierenden Unternehmen rechnet mit einem verstärkten Einsatz von Technologien der KI in den kommenden Jahren. Aktuell beträgt dieser nur rund 25 % bei Großunternehmen und weniger als 15 % bei KMUs, so dass im produzierenden Gewerbe noch viele unerschlossene Potenziale zu vermuten sind.

Während verschiedene Hemmnisse, wie beispielsweise die geringe Verfügbarkeit von qualifizierten Mitarbeitern im Bereich Data Analytics, den Einsatz der neuen Technologien behindern [7], konnte die erfolgreiche Anwendbarkeit von KI für Energiesysteme im verarbeitenden Gewerbe in vielen wissenschaftlichen Arbeiten bereits gezeigt werden.

Durch den Einsatz von intelligenten Systemen kann beispielsweise eine Verminderung von Ausschuss und damit verbundenen Kosten erreicht werden. Im Bereich der Halbleiterindustrie war es möglich durch Orchestrierung von Teilprozessen die Ertragseinbußen um 30 % zu reduzieren [8]. Die Nutzung von ML in großen Rechenzentren führte zu einer Reduzierung des Energieverbrauchs für die Kühlung von bis zu 40 %, was etwa die 3,5-fache Rechenleistung bei gleicher Energiemenge bedeutet [9]. Über das sogenannte Condition Monitoring ist es möglich, durch verminderte Maschinenausfälle eine Produktionssteigerung von bis zu 20 % zu erzielen, während die Instandhaltungskosten um bis zu 10 % gesenkt werden können [8].s

Bei der Nutzung einer großen Anzahl von intelligenten Maschinen und Anlagen, also von Informations- und Kommunikationstechnik (IKT), stellt sich die Frage, ob der Energieverbrauch der IT-Maßnahmen größer ist als die durch ihren Einsatz ermöglichten Einsparungen. Ersten Aussagen zufolge ist das Gegenteil der Fall: Die Global e-Sustainability Initiative schätzt, dass durch Arbeiten in der IT-Branche diese derzeit das 1,5-Fache ihres eigenen CO₂-Fußabdrucks in anderen Bereichen verringert und dass der Reduktionsfaktor bis 2030 auf fast das Zehnfache ansteigen könnte [10]. Laut einer empirischen Umfrage des Instituts für transformative Nachhaltigkeitsforschung erwarten 83,5 % der befragten chinesischen Firmen hohe oder sehr hohe Einsparungen beim Energieverbrauch durch die Digitalisierung der Industrie. Das Potenzial für Materialeinsparungen durch Digitalisierung wird von 88,1 % der chinesischen Teilnehmer als noch größer eingeschätzt [11].

Energetische Einsparpotenziale der in diesem Projekt zu untersuchenden Innovationen ergeben sich durch die digitale Vernetzung, die Energietransparenz und -optimierung, die intuitive und automatisierte Anwendbarkeit und schließlich zusammengefasst durch die daraus resultierende Energieeffizienz. Diese lässt sich wie folgt quantifizieren:



Quelle: Statistisches Bundesamt 2017, Umweltnutzung und Wirtschaft - Tabellen zu den Umweltökonomischen Gesamtrechnungen

Abbildung 1.1: Anteile der Sektoren am Primärenergieverbrauch des verarbeitenden Gewerbes im Jahr 2015 [12].

Die Primärenergienutzung innerhalb des verarbeitenden Gewerbes beträgt knapp 4000 PJ und verteilt sich auf verschiedene Produktionssektoren (siehe Abbildung 1.1). Die wichtigsten Sektoren sind dabei die Chemieindustrie mit rund 36 % gefolgt von der Metallherstellung mit einem Anteil von 17 % sowie die Herstellung von Kokerei- und Mineralölerzeugnisse mit 11 %, der Glasherstellung mit 7 % und der Papierindustrie mit 6 % am Energieverbrauch im verarbeitenden Gewerbe.

Bezüglich der chemischen Industrie beträgt das technische Einsparpotenzial nach [13] ca. 24,4 PJ. Hierbei sind laut [14] allein 15 % durch den Einsatz von Energiemanagementsystemen und Optimierungsverfahren zu erreichen.

Für den Bereich der Papier- und Zellstoffindustrie wird ein erhebliches Energieeinsparpotenzial bis 2035 prognostiziert. Die Studien in [15] zeigen auf, dass dieses 34 TJ/a Kraftstoffeinsparungen und 12 TJ/a Stromeinsparungen entspricht. Ebenfalls zeigten die Ergebnisse, dass die größten Einsparpotenziale bei der Wärmerückgewinnung und Kopplung der verschiedenen Energieträger liegt. Weiterhin ist in [16] gezeigt, dass mit dem Einsatz von genetischen Algorithmen und mathematischer Optimierung ca. 9 % des Energieverbrauchs einer Papiermühle eingespart werden können. Ebenfalls durch mathematische Optimierung können 16 % in der Glasindustrie [17] eingespart werden.

Das maximale technische Energieeinsparpotenzial in der Metallindustrie ist laut [18] auf bis zu 19 % abzuschätzen. Exemplarisch wird in [19] anhand eines Warmwalzbandprozesses die Energieeinsparung durch Energierückgewinnung am Hochofen und zusätzlicher linearer/nichtlinearer Programmierung bezüglich der Beladung gezeigt, dass bis zu 5,69 % Energieeinsparung erreichbar sind.

Typische Energieeinsparungen durch die Betriebsstrategieoptimierung durch mathematische Verfahren liegen im Bereich zwischen 5 % und 25 % [9] [20] [21] [22]. Da die zu erarbeitenden Verfahren der Simulation, Prognose und Optimierung als Querschnittstechnologien über alle Branchen und Anwendungsfälle hinweg angewendet werden können, lassen sich bei einer mittleren Effizienzsteigerung von nur 5 % ca. 200 PJ an Primärenergie jedes Jahr einsparen. Dies entspricht zum Vergleich dem Energieinhalt von über 13 Mio. Tonnen Braunkohle, was wiederum eine Einsparung von über 400 Mio. Tonnen CO₂ bedeuten würde.

1.3. Planung und Ablauf des Forschungsvorhabens

Um sicherzustellen, dass die im Projekt entwickelten Lösungen möglichst schnell in die Industrie übertragen werden können, finden die Entwicklungen nicht nur in der ETA-Fabrik statt. Die einzelnen Anwendungen werden in den Teilprojekten 1 – 6 zusätzlich bei den Industriepartnern EJOT, Bosch – in einem Werk der Bosch Rexroth AG – und CuroCon entwickelt und in Teilprojekt 7 zu verschiedenen prototypischen Anwendungsfällen zusammengeführt. Dabei wirken Applikationen auf Edge Devices zusammen mit Anwendungen in der Cloud auf der Energiemanagementplattform wie im Weiteren beschrieben.

EJOT: Transparenzschaffung und Condition Monitoring auf dem Edge Device




Abbildung 1.2: Anwendungsfall Condition Monitoring bei EJOT.

Das Ziel des, in Abbildung 1.2 dargestellten, Anwendungsfalls bei EJOT ist, mit Hilfe von Energie- und Maschinendaten schon während des Produktionsprozesses Rückschlüsse auf die Bauteilqualität des Bauteils ziehen zu können. So kann Ausschuss verhindert und damit indirekt Energie eingespart werden. Dazu wird im EJOT Werk Tambach eine Umformmaschine mit einem Edge Device ausgerüstet. Das Edge Device erfasst hochfrequente Zustandsdaten der Maschine. Zusätzlich werden über eine virtuelle Energiemessstelle hochfrequente Energiedaten aus Datenpunkten der Maschine erzeugt. Die Rohdaten werden in der Datenvorverarbeitung aufbereitet und für Condition Monitoring im Anwendungsfall Quality und Process Monitoring genutzt. Damit ist es möglich im Prozess bereits eine Rückmeldung an die Maschine zu geben und z. B. direkt bei der Produktion fehlerhafte Bauteile auszusortieren. Somit muss nicht die ganze Charge vernichtet werden und der Energieverbrauch pro korrektem Bauteil sinkt.

Das Condition Monitoring System ist außerdem mit der zentralen Plattform verbunden, auf der mit den Energie- und Zustandsdaten Energiekennzahlen berechnet werden, automatisch Vorschläge für Energieeinsparungen erstellt und mit den Daten Simulationsmodelle der Produktionsanlagen parametrisiert werden. Die angelernten Modelle zur Werkzeugüberwachung sind digitale Zwillinge der Maschine und können über Transfer Learning auf weitere, ähnliche Maschinen übertragen werden.

Bosch: Betriebsoptimierung der Produktion




Abbildung 1.3: Anwendungsfall Betriebsoptimierung bei Bosch.

Wie in Abbildung 1.3 dargestellt, wird bei Bosch im Werk Schweinfurt (Bosch Rexroth AG) ebenfalls Edge Technik, hier an einer Linearschleifmaschine, eingesetzt. Das Ziel ist den Energieverbrauch der gesamten Produktionsstraße zu senken. Die Datenaufnahme ist identisch mit dem vorherigen Anwendungsfall. In diesem Fall werden die Daten jedoch benutzt, um Prognosemodelle der Anlage anzulernen. Die Energieprognosewerte werden dann für die Energieoptimierung genutzt. Außerdem werden die Prognosemodelle regelmäßig mit der Managementplattform ausgetauscht und durch, auf der Energiemanagementplattform gespeicherte Informationen aus anderen Produktionsanlagen geupdatet und damit verbessert. Von der Managementplattform erhält die Optimierung außerdem die Zielfunktion, die z.B. aktuelle Energiepreise und Produktionspläne enthält sowie Sollwerte weiterer Maschinen. Somit kann auf der Edge die optimale Entscheidung mit möglichst vielen verfügbaren Informationen getroffen werden. Ein wesentlicher Teil der Zielfunktion wird die herstellbare bzw. erreichbare Werkstückqualität sein. Die oben beschriebene neuartige Funktionalität und eine Betriebsstrategie „Energie und Produktqualität“ kann mit Hilfe eines KI-Ansatzes für eine langfristige Schicht-, Produktions- und Energieplanung genutzt werden.

CuroCon: Betriebsoptimierung der Versorgungstechnik auf der Plattform

Abbildung 1.4: Anwendungsfall Betriebsoptimierung bei CuroCon.

Durch die Entwicklung der Werkzeuge und die abschließende Betrachtung der vollständigen Anwendung bei den Industriepartnern wird sichergestellt, dass die im Projekt entwickelten Lösungen schnell Einsatz in der Industrie finden können. Neben der Validierung der Anwendung im Feld entstehen so zusätzlich vorzeigbare Demonstratoren, die eine Verbreitung in andere Firmen erleichtern.




Abbildung 1.5: Übersicht der Projektstruktur.

Im ersten Teilprojekt wird eine smarte Energiemanagementplattform entwickelt, um anfallende Daten aufzunehmen und den Anwender durch intelligente Funktionen bei der Datenakquise und -weiterverarbeitung zu unterstützen. Um die Datenaufnahme zu ermöglichen, wird eine IKT-Infrastruktur zur Datenerfassung benötigt, die für Fabrikbetreiber mit möglichst geringem Aufwand für Einrichtung und Verwaltung verbunden ist. Die Vernetzung unterschiedlicher Geräte wird in Teilprojekt zwei, Vernetzung & Sicherheit, bearbeitet. Beispielsweise soll sichergestellt werden, dass neue Geräte und Sensorik schnell und kostengünstig eingebunden werden können. Zusätzlich wird im zweiten Teilprojekt sichergestellt, dass die entwickelten Steuerungsalgorithmen aus den nachfolgenden Teilprojekten die Sicherheitsanforderungen erfüllen. Es dürfen beispielsweise keine Entscheidungen getroffen werden, die ein System in einen unsicheren Zustand versetzen würden. Außerdem muss die IT-Sicherheit gewährleistet sein.

In den Teilprojekten eins und zwei wird die Infrastruktur für die Datenaufnahme und -verarbeitung geschaffen und Geräte für intelligente Optimierung der Energieeffizienz befähigt. Darauf aufbauend können in den Teilprojekten drei bis fünf Maßnahmen zur energetischen Transparenzschaffung und intelligente Regelsysteme für die Fabrik entwickelt werden. Im dritten Teilprojekt wird ein Vorgehen zur energetischen Transparenzschaffung und zum Monitoring entwickelt. Dies ermöglicht es einem Fabrikbetreiber zu entscheiden, an welchen Stellen sinnvollerweise Messungen durchgeführt werden, um möglichst großen Nutzen zu generieren. Außerdem werden Auswertungen der Daten erleichtert. Im Teilprojekt vier werden, basierend auf den so erfassten Daten, Modelle erstellt, welche die Daten aufbereiten und erste Maßnahmenvorschläge für Energieeffizienz generieren. Auf Grundlage der so geschaffenen datenbasierten Modelle werden im Teilprojekt fünf Strategien und Algorithmen für die Betriebsoptimierung der Fabrik im Hinblick auf Energieeffizienz und -flexibilität entwickelt. Da die Fabrik in verschiedener Hinsicht in Netze eingebunden und mit weiteren Sektoren gekoppelt ist, werden einige Aspekte der Sektorenkopplung im sechsten Teilprojekt aufgegriffen. Dazu gehören die Anbindung an Strom- und Wärmenetze sowie die Nutzung von Energiekapazität aus dem Bereich der E-Mobilität zur Steigerung der Energieflexibilität.

Da die unterschiedlichen Teilprojekte in KI4ETA stark aufeinander aufbauen, werden im siebten Teilprojekt konkrete, übergreifende Anwendungsfälle in der Industrie und in der Forschungsfabrik umgesetzt. Dabei werden die entwickelten Algorithmen und Methoden im Hinblick auf die potenziellen Energieeinsparungen und die möglichen Flexibilisierungspotenziale sowie die Eignung für den industriellen Einsatz untersucht. So soll sichergestellt werden, dass die entwickelten Lösungen anwendungsnah und in der Industrie umsetzbar sind. Zusätzlich wird betrachtet, ob und wie sich Lösungen auf andere Industriebranchen übertragen lassen.

1.4. Wissenschaftlicher und technischer Stand zu Vorhabensbeginn

1.4.1. Dateninfrastruktur und Managementplattformen für das Energiemanagement

Mit dem Komplexitätsgrad industrieller Energiesysteme wachsen auch die Herausforderungen, die Anlagen und Systeme hinsichtlich der konkurrierenden Zielgrößen: Wirtschaftlichkeit, Versorgungssicherheit und Umweltfreundlichkeit optimal auszulegen und zu betreiben. Vor diesem Hintergrund und durch staatliche Regulierungen (Energieaudit-Pflicht nach EDL-G) sowie Fördermöglichkeiten (u.a. Spitzenausgleich nach StromStG, Besondere Ausgleichsregelung nach § 63 ff EEG 2017) gewinnen Energiemanagementsysteme an Popularität. Sie ermöglichen es, die Energieflüsse in der Produktion transparent aufzuzeigen, Energieverschwendungen zu eliminieren und somit langfristig die Energiekosten zu senken.

Während die Erfassung von energiebezogenen Messwerten, die Berechnung von Kennzahlen und Visualisierung der Daten bereits durch einige kommerzielle Softwaresysteme angeboten wird, wird der Anwender bei der Auswertung und Optimierung der Energiesysteme bisher weitgehend allein gelassen. Dabei wird für die Optimierung der Struktur, der Auslegung und des Betriebsverhaltens von komplexen industriellen Energiesystemen ein hohes Maß an interdisziplinärem Wissen benötigt. Selten vereinen Energieteams jedoch alle erforderlichen Kompetenzen aus den Bereichen der Produktions-, Gebäude-, Energie- und Regelungstechnik sowie Energiewirtschaft. Infolgedessen bleiben Potenziale zur Optimierung der Energiekosten aufgrund mangelnder Transparenz bzw. zu hoher Kosten für die Identifikation und der Komplexität realer energetischer Systeme häufig ungenutzt.

Bestehende Plattformen bieten unzureichende Möglichkeiten, innovative Methoden aus dem Bereich der KI in das Energiemanagement zu integrieren. Bisherige Prognoselösungen setzen meist auf einfache statistische Verfahren und erlauben nicht die Integration komplexer Data Analytics Pipelines. In der Regel sind die Plattformen im Funktionsumfang geschlossen und können nicht durch eigene Lösungen erweitert werden. Dies hemmt die Entwicklung innovativer Methoden, die sich nicht einfach integrieren lassen. Häufig ist die benötigte Qualität der eingehenden Daten nicht gegeben, sodass diese nicht unmittelbar mit ML-Verfahren genutzt werden können. Bestehende Plattformen bieten hierfür auch keine Funktionalitäten, um die Datenqualität zu überwachen und zu verbessern. Hinzu kommt, dass die Integration von unterschiedlichen Datenquellen als manueller Prozess sehr zeitaufwendig und fehleranfällig ist. Datenpunkte sind deshalb häufig falsch parametrisiert und schlecht dokumentiert. Es bestehen also signifikante Potenziale, die Handhabung von Daten in Energiemanagementsystem-Plattformen zu verbessern und innovative KI-basierte Verfahren zu integrieren. Wesentliche Treiber zur Entwicklung robuster und breit anwendbarer Technologien sind dabei Open Source Softwarekomponenten und offene Schnittstellen, sodass die Funktionsweise nachvollzogen und flexibel erweitert werden kann.

1.4.2. Einsatz von KI-Methoden für die energetische Optimierung von Querschnittstechnologien in der Produktion

Querschnittstechnologien sind diejenigen Technologien, die nicht nur für einen Anwendungsfall genutzt werden, sondern technologieübergreifende Anwendungsgebiete haben. Bspw. werden Lüfter in vielen Bereichen wie der Industrie, der Computertechnik und im privaten Haushalt zur Kühlung verwendet. Durch die Förderung der Querschnittstechnologien vom BMWi und dem Bundesamt für Wirtschaft und Ausfuhrkontrolle (BAFA) (2012-2015) konnten Unternehmen Fördergelder nutzen, um Entwicklungen von Querschnittstechnologien voranzutreiben und dadurch Energie einzusparen. Insgesamt wurden 73 Millionen Euro zur Verfügung gestellt und 360 GWh/Jahr elektrische und 45 GWh/Jahr thermische Energie eingespart. Bis Ende 2020 geht man davon aus, 0,79 Millionen Tonnen CO₂ einzusparen [23].

Querschnittstechnologien und Energiewandler stellen einen der größten Energieverbraucher in der Industrie dar. Gleichzeitig bietet sich durch die Optimierung dieser Systeme die Möglichkeit ungenutztes Energiesparpotenzial gewinnbringend zu nutzen [24]. Als bedeutender Kostenfaktor sei an dieser Stelle betont auf die Betriebskosten verwiesen. Um eine generelle Energieeffizienzsteigerung zu erzielen, ist daher ein optimierter Betrieb essenziell. Dies könnte über eine automatisierte Betriebsführung mithilfe von künstlicher Intelligenz geschehen. Mit Intelligenz ist damit die Fähigkeit eines Systems zur Observation, Analyse und Adaptierung an sich ändernde Umstände gemeint [25]. Theoretische Ansätze zur optimierten Steuerung und Design verschiedener Assistenzsysteme wie Steuerung und Regelung von Pumpsystemen [26] [27] [28] [29] [30], intelligente Managementsysteme [31] [32] oder künstlicher Intelligenz in erneuerbaren Energiesystemen [33] existieren bereits, eine Verifikation der Ergebnisse durch Praxisbeispiele fehlt jedoch häufig.

Eine wichtige Querschnittstechnologie im industriellen Kontext stellen elektrische Energiespeicher dar. In Form von stationären, aber auch als mobile Speicher, können diese in Fabriken verschiedene Dienstleistungen bereitstellen und das Gesamtenergiesystem somit unterstützen und verbessern. Mobile Energiespeicher sind dabei z.B. über intelligente Ladeinfrastruktur angebundene, elektrifizierte Fahrzeuge. Im Rahmen von Vorgängerprojekten wurden bereits ein stationäres hybrides Speichersystem, bestehend aus Schwungmassenspeicher und Lithium-Ionen-Batterie, sowie eine unidirektionale, intelligente Ladeinfrastruktur konzipiert, aufgebaut und getestet. Es wurde gezeigt, dass mit diesen zur Netzfrequenzstabilisation beigetragen und zusätzlich Primärregelleistung erbracht werden kann [34]. Abhängig von verschiedenen Betriebsstrategien können mit den elektrischen Speichern außerdem weitere ökologische und ökonomische Ziele verfolgt werden [35] [36]. Ansätze der künstlichen Intelligenz bieten sich an, um klassische Optimierungsansätze für die Betriebsstrategieermittlung zu ergänzen. Die benötigten Daten hierfür können an den vorhandenen Systemen gesammelt werden. Wird die Ladeinfrastruktur im Projekt wie geplant für das bidirektionale Laden befähigt, so unterscheiden sich die stationären und mobilen Speicher in ihrer grundsätzlichen Funktion nicht mehr und es kann im Rahmen der Modellierung und Simulation ein hohes Maß an Synergien gehoben werden.

Eine weitere Querschnittstechnologie stellt die Bereitstellung von Druckluft dar. Der Einsatz von analysierenden Messsystemen zur Energieeffizienzoptimierung im unternehmerischen Kontext ist bereits heute für Druckluftsysteme in Form von festen Messstationen verfügbar. Mit diesen Stationen lässt sich ermitteln, dass eine Leckage im Netz vorhanden ist, allerdings nicht wo sich diese befindet. Zum Auffinden der Leckage bieten sich Roboter an. Für verschiedene Einsatzzwecke besonders im Bereich des „risk assessment“ werden Leckagedrohnen eingesetzt, um Gasaustritte, Abweichungen der Schichtdicke, Druckluftleckagen oder thermische Quellen zu identifizieren [37] [38]. Unternehmen wie

Siemens verwenden dabei Unmanned Aerial Vehicles (UAVs), die angepasst an den jeweiligen Verwendungszweck mit bildgebender Messtechnik ausgestattet sind [39]. Verwendung findet diese Technologie bisher vermehrt im Außenbereich und nicht in komplexen Produktionen oder Industriehallen. Dies ist beispielsweise darauf zurückzuführen, dass es in der Produktion gefährliche Bereiche geben kann, in denen viel Wärme abgestrahlt wird, die ein UAV zum Absturz bringen könnte. Außerdem sind in der Produktion oftmals vertikale Rohrleitungen verlegt und es herrscht Kranbetrieb. Das Umfeld ist daher sehr komplex und die Navigation für UAVs eine große Herausforderung. Im Sinne der einfachen Umsetzbarkeit erscheint ein bodengebundenes Gerät daher besser geeignet. Damit kann das Prinzip der Leckagedetektion durch autonome Systeme auch auf weitere Einsatzfelder oder Systemabschnitte übertragen werden. Optimierungsansatz ist die Entwicklung und Verbesserung unterschiedlicher Analysesoftware direkt in den Messsystemen, die Daten nicht nur aufzeichnet, sondern automatisiert optimiert. So kann eine autonome Betriebsführung und Risikoüberwachung Kosten senken und die Energieeinsparung steigern.

1.4.3. IKT-Infrastruktur als Basis der vernetzten energieintelligenten Fabrik

Die Basis für die Fabrik im Internet der Dinge (Internet of Things, kurz IoT) bildet der Einsatz von IKT und passender Kommunikationssoftwarelösungen zur informationstechnischen Vernetzung von Maschinen untereinander und mit zentralen und dezentralen Steuerungs- und Auswertungssystemen. Ein Beispiel für eine für diese Vernetzung eingesetzte Lösung sind IoT-Gateways. Ein IoT-Gateway ist eine Software, die ältere und neue Geräte in der Feldebene sicher und zuverlässig mit dem Internet verbinden und somit eine Datenverarbeitung in der Cloud ermöglichen kann. IoT-Gateways werden meist auf Industrie-PCs direkt an der Maschine, sogenannten Edge Devices, implementiert. Hersteller bieten unter dem Namen IoT-Gateway häufig ein Edge Device mit installierter IoT-Gateway Software an, was zu einer Vermischung der Begriffe führt. Da die Installation von IoT-Gateways auch auf anderen Plattformen wie Raspberry Pis, normalen PCs oder in der Cloud möglich ist, wird zur Unterscheidung von Software und Hardware im Antrag der Begriff Daten-Gateway für die Software, Edge Device für die Hardware und IoT-Gateway für ein auf einem Edge Device installiertes Daten-Gateway verwendet.

Die vom IoT-Gateway erfassten Daten werden gebündelt via Ende-zu-Ende-Verschlüsselung von der Feldebene direkt zur IoT-Plattform ohne Entschlüsselung im IoT-Gateway transportiert. Weitere Aspekte des IoT-Gateways sind neben der Interoperabilität die Konzentration auf einen fließenden Datenstrom und die lokale Datenverarbeitung. Die Vorteile liegen hierbei zum einen in der Erhöhung der IT-Sicherheit und die Reduzierung des Energiebedarfs. Beispielsweise konnte Bosch Rexroth beim Einsatz von IoT-Gateways Ölventile genauer überwachen und verbesserte dadurch das Wartungsintervall. Dies spart Zeit, Geld und schützt die Umwelt [40]. Neben Intel und Bosch Rexroth bieten auch Siemens und Hilscher IoT-Gateways in unterschiedlichen Ausführungen an.




Abbildung 1.6: Vernetzung von Sensoren und Maschinen mit Gateways.

Ein weiterer wichtiger Punkt, der die Interoperabilität vorantreibt, ist die Kommunikationssammlung Open Platform Communications Unified Architecture (OPC UA). Dies ist eine Sammlung von Standards für den Datenaustausch und die Kommunikation von Geräten [41]. Die IoT-Gateways von Bosch Rexroth, Siemens und Hilscher verfügen über die notwendigen OPC UA Protokolle [42] [43] [44]. Die Vorteile des OPC UA Standards ergeben sich durch die hersteller- und plattformunabhängige industrielle Kommunikation, eine gute Skalierbarkeit, eine hohe Sicherheit und eine serviceorientierte Architektur (SOA). Diese Vorteile sind wesentliche Voraussetzungen, um die Industrie 4.0 voranzutreiben [45]. OPC UA kann darüber hinaus gezielt um weitere Technologien erweitert werden. Ein Beispiel ist die OPC UA over Time-Sensitive Networking (OPC UA over TSN) Technologie. TSN bezeichnet dabei die hochfrequente Übertragung von Daten in Echtzeit zwischen einer Maschine und einem Edge Device [46]. Geräteübergreifende Edge Devices realisieren mit Daten-Gateways die Datenübertragung im IoT und verarbeiten zusätzlich zur reinen Weiterleitung die vorliegenden Sensor- und Aktordaten direkt an der Applikation, was man als Edge Computing bezeichnet. Edge Computing reduziert die Datenflüsse zwischen dem Edge Device und der Cloud und damit auch die Netzwerkbelastung [47]. Edge Computing zeichnet sich somit durch die dezentrale Verarbeitung der Daten am Rand des Netzwerkes aus. Die Daten der Maschine werden hochfrequent mittels TSN abgefragt und im Edge Device verarbeitet. Die gesammelten Daten können dann mit geringer Netzwerkbelastung an die Cloud übertragen werden.

1.4.4. IT-Security und funktionale Sicherheit in Industrie 4.0

Mit der zunehmenden Vernetzung von Anlagen in Produktionsumgebungen steigt auch die Zahl potenzieller Ansatzpunkte für Angriffe auf die IKT-Infrastruktur eines Unternehmens. Zusätzliche Ansatzpunkte entstehen beispielsweise durch die dezentrale Einbindung von IoT-Geräten mit geringer Rechenleistung sowie die Anbindung an Energiemanagementplattformen und -marktplätze [48]. Daraus ergeben sich verschiedene Bedrohungsszenarien, die von der Verletzung von Datenschutzrechten über Industriespionage, mögliche Produktionsausfälle bis hin zur Beschädigung von Produktionsanlagen

und kritischen Infrastrukturbestandteilen reichen [49]. Bei der Einbindung von Fabriken in die Regelung von Energienetzen mittels Demand-Side-Management sind Angriffe auf einzelne Fabriken zudem eine potenzielle Bedrohung für die entsprechenden Energienetze und andere angeschlossene Energieverbraucher, weshalb die IT-Sicherheit derartig vernetzter Systeme zusätzlich an Bedeutung gewinnt [50].

Um die Risiken durch Angriffe auf die IKT-Infrastruktur zu minimieren, bedienen sich Unternehmen unterschiedlicher Sicherheitsstrategien. Zur Festlegung der Anforderungen an Information Security Management Systeme (ISMS, engl. für „Managementsystem für Informationssicherheit“) und deren Einhaltung existieren verschiedene standardisierte Ansätze [49]. Der am weitesten verbreitete Standard ist die internationale Norm ISO 27001, welche den IT-Grundschutz beschreibt [51]. Auf nationaler Ebene stehen zudem die IT-Grundschutz-Kompendien des Bundesamtes für Sicherheit in der Informationstechnik (BSI) zur Verfügung, die kompatibel zum ISO-Standard 27001 sind [52]. Ergänzt werden diese durch themenspezifische Kompendien, etwa für die Industrie und kritische Infrastrukturen [53]. Weitere Empfehlungen für vernetzte Produktionsprozesse gibt zum Beispiel der Verband Deutscher Maschinen- und Anlagenbau (VDMA) in seinem Leitfaden zur IT-Sicherheit im Zeitalter der Industrie 4.0 heraus [54].

Für eine umfassendere Übersicht bestehender IT-Sicherheitsstandards und Handlungsempfehlungen sei auf die einschlägige Literatur verwiesen. Einen Überblick in tabellarischer Form gibt beispielweise die Europäische Agentur für Netz- und Informationssicherheit (ENISA) [49].

Der IT-Sicherheit steht die funktionale Sicherheit gegenüber, bei welcher die korrekte Funktion sicherheitsbezogener Systeme zur Risikoreduzierung im Vordergrund steht, um damit den Menschen vor der Maschine zu schützen. Die erforderliche Risikominderung lässt sich quantifizieren, indem ein System einer von vier definierten Sicherheitsanforderungsstufen (Safety Integrity Level SIL 1 bis 4) zugeordnet wird, welche unterschiedliche Ausprägungen von Maßnahmen erfordern. [55]

In der horizontalen Normenreihe IEC 61508 sind verschiedene Aspekte der funktionalen Sicherheit für elektrische, elektronische oder programmierbare elektronische Systeme beschrieben, welche als Grundlage für normative Festlegungen spezifischer Produktbereiche dienen (z.B. Luftfahrt, Prozessindustrie, Automobil- und Bahntechnik). In naher Zukunft sollen in dieser Norm auch neue Anforderungen an Künstliche Intelligenz formuliert werden.

Da sich funktionale und IT-Sicherheitsmaßnahmen gegenseitig beeinflussen können, ist stets eine gründliche Abwägung der betroffenen Aspekte in der ganzheitlichen Risikobetrachtung notwendig. Im Rahmen des Projektes ist zu untersuchen, inwieweit bekannte Standards für IT-Security und funktionale Sicherheit konkret auf vernetzte Produktionsumgebungen anwendbar sind, in denen Lasten dynamisch und automatisiert verteilt werden.

1.4.5. KI-gestützte Transparenzschaffung und Energiemonitoring der Industrie

Steigende Energie- und Rohstoffpreise und ein zunehmender Wettbewerb lassen den rationellen Energieeinsatz wichtiger denn je werden. Um Energieflüsse in Unternehmen aufzuzeigen, bietet sich ein systematisches Energiemanagement an, mit dem u.a. die Energieeffizienz kontinuierlich verbessert werden kann [56]. Die DIN EN ISO 50001 zu Energiemanagementsystemen fordert Unternehmen zu einer kontinuierlichen Messung, Überwachung und Bewertung des Energieverbrauchs auf.

Eines der größten Hemmnisse bei der flächendeckenden energetischen Transparenzschaffung sind neben den Kosten für die Sensoren, vor allem das fehlende Wissen wie ein wirtschaftlicher oder energetischer Mehrwert aus den gewonnenen Energiedaten generiert werden kann [57] [58] [59]. Aus dieser Problemstellung leitet sich der Bedarf an intelligenten KI-gestützten Assistenzsystemen ab, welche u.a. die Energiedaten analysieren und Handlungsempfehlungen aufzeigen.

Aus den Vorgaben der ISO 50001 stellt sich die oft gestellte Frage, welche Verbraucher mit Leistungsmessgeräten ausgestattet werden sollen und wie man diese priorisiert. Bestehende Ansätze zur Priorisierung wenden das Pareto-Prinzip oder ABC-Analysen des Energieverbrauchs an [60], lassen aber keine Abschätzung von energetischen oder wirtschaftlichen Einspar- und Optimierungspotenzialen zu. Daher werden aktuell Investitionsentscheidungen in Energiemessstellen meist ohne eine Abschätzung des wirtschaftlichen oder energetischen Nutzens getroffen. Ebenfalls gibt es keine Assistenzsysteme, die dem Nutzer bei der energetischen Grob- oder Feinanalyse umfangreich unterstützen bzw. diese automatisiert durchführen.

Eine Möglichkeit die Kosten des Energiemonitorings signifikant zu reduzieren, besteht in der Nutzung von „virtuellen Messstellen“, deren Einsatz u.a. von Energieauditoren empfohlen wird [61]. Bisher wurde zwischen einfachen, faktorisierten und zustandsbasierten virtuellen Messstellen unterschieden [62]. Da hier jedoch nur einfache Zusammenhänge über gemittelte Energieverbräuche verwendet werden, können bisherige virtuelle Energiemessstellen lediglich für konstante Kleinverbraucher verwendet werden [62] [63]. Basierend auf einer temporären, mobilen Messung sollen im Rahmen des KI4ETA-Projekts automatisch hochgenaue virtuelle Messstellen generiert werden. Hierbei wird eine neue Messstelle rechnerisch erzeugt, entweder indem der elektrische Lastgang über eine vorher erzeugte Korrelation mit maschineninternen Daten prognostiziert wird, oder indem die gemessene Leistung einer übergeordneten Messstelle auf die darunterliegenden Verbraucher aufgeschlüsselt wird. Über Algorithmen des maschinellen Lernens lässt sich dieses sensorreduzierte Messstellenkonzept auf komplexere Zusammenhänge und Anwendungsfälle erweitern. Unter gewissen Voraussetzungen und einer ausreichend guten Datenverfügbarkeit sind sowohl bestehende Ansätze der Energiedisaggregation, wie auch des zustandsbasierten Energiemonitorings zielführend in ein Messstellenkonzept integrierbar. Vorarbeiten zum zustandsbasierten Energiemonitoring, welche Zustandsdaten der Maschinensteuerung zur Lastabschätzung nutzen [64], erfolgten bereits im PHI-Factory Projekt.

Neben der Steigerung der energetischen Transparenz fordert die ISO 50001 von Organisationen die Berechnung und Überwachung von Energieleistungskennzahlen (EnPIs) [56]. Da es jedoch keine einheitliche und zusammenhängende Methodik gibt, fallen die derzeitigen Lösungsversuche der Unternehmen, deren Berater und auch die Anforderungen der Zertifizierungsstellen sehr unterschiedlich aus [65]. Unter anderem wurde eine vielversprechende Methodik zur Aufstellung von Energiekennzahlen im Auftrag des Bundesumweltministeriums erstellt [65]. Aktuell gibt es keine Assistenzsysteme, die automatisiert Messdaten auswerten und vergleichbare EnPIs berechnen.

1.4.6. Lastprognose im industriellen Kontext

Planungs- und Vorhersageansätze, welche bereits im unternehmerischen Entscheidungsfindungsprozess weit verbreitet sind [66], gewinnen zunehmend an Bedeutung in der Industrie. Auf Basis der durch das Energiemanagement erfassten Daten können Lastprognosen erstellt werden, welche einen wesentlichen Input für zahlreiche Optimierungsmaßnahmen darstellen. Lastprognosen stellen dabei systematische Verfahren dar, welche eine Aussage über den aktuellen oder den zukünftigen Energiebedarf treffen [67].

Im Folgenden wird unter Lastprognose die Vorhersage des zukünftigen Energiebedarfs verstanden. Im Allgemeinen können Lastprognosen mittels modellbasierter Ansätze, welche sowohl physikalische als auch statistische Modelle umfassen, oder mittels datenbasierter Ansätze erstellt werden. Die Vor- und Nachteile dieser Verfahren wurden ausgiebig untersucht [68] [69]. Im Hinblick auf Lastprognose gibt es keine grundlegend überlegene Methode. Der Ansatz muss vielmehr an das spezifische Problem und die Datenverfügbarkeit angepasst werden [70]. Vor dem Hintergrund der Zunahme an installierten Messstellen im industriellen Kontext [71], welche enorme Datenmengen generieren, als auch der rasanten Entwicklung der Informationswissenschaft in Form von hochentwickelten Datenanalysen, ist die Anwendung von datenbasierten Ansätzen vielversprechend. Zur Durchführung solcher datenbasierter Ansätze kommen häufig sogenannte Pipelines zum Einsatz. Innerhalb einer Pipeline werden sequenziell verschiedene Verarbeitungsschritte durchgeführt, um diese anschließend zusammen bei Anpassung von Modellparametern validieren zu können.

Heutzutage wird die Vorhersage von elektrischen Lasten hauptsächlich auf der Angebotsseite des Energiesektors durchgeführt. Anwendungsgebiete sind der Energieeinkauf und die Finanzplanung sowie der Betrieb und die Instandhaltung. Hierbei werden Lastprognosen zur Verbesserung der Informationsbasis und zur Unterstützung des Entscheidungsprozesses eingesetzt [70] [72]. Im Gebäudesektor werden thermische Lastprognosen bereits als essenzielle Grundlage für verschiedene Aufgaben des Gebäudeenergiemanagements, wie z.B. Fehlererkennung und -diagnose, Demand Side Management oder Steuerungsoptimierung eingesetzt [73] [74]. Obwohl Lastprognosen Entscheidungsunterstützung für Steuerungssysteme und Maßnahmen zur Senkung der Energiekosten, wie z.B. Spitzenlastmanagement, optimaler Energieeinkauf oder Demand Response Anwendungen ermöglichen, werden diese Potenziale in der Fertigungsindustrie zurzeit nur unzureichend genutzt.

In der Literatur wird zwischen vier Vorhersagehorizonten unterschieden. Die langfristige Lastprognose hat einen Zeithorizont von mehr als drei Jahren, während der mittelfristige Zeithorizont bis zu drei Jahren beträgt. Die kurzfristige Lastprognose wird für Prognosen bis zu zwei Wochen verwendet, wohingegen die sehr kurzfristigen Prognosen bis zu einem Tag betragen [70]. Im Rahmen von KI4ETA sind die kurzfristige und sehr kurzfristige Prognose von Relevanz.

1.4.7. Steuerung von Fabrikssystemen über Künstliche Intelligenz

Algorithmenbasierte Ansätze zur Fabriksteuerung werden in der Forschung bereits seit längerer Zeit mit großem Interesse untersucht. So finden sich unter den Schlagwörtern “micro grid optimization”, “smart factory optimization”, “energy system optimization” und “energy efficient production scheduling” mehrere 100.000 wissenschaftliche Arbeiten. In diesem Projekt werden die Produktionsplanung und die optimale Steuerung der Versorgungstechnik als zwei Teilbereiche der Betriebsoptimierung betrachtet. Zur optimierten Steuerung der Wärme [75], Kälte- [76] oder elektrischen Energieversorgung [77] eines produzierenden Unternehmens existieren bereits eine Vielzahl an Ansätzen.

Allerdings war besonders die Betrachtung vollständiger, realer Energiesysteme in der Vergangenheit nicht Schwerpunkt der Forschung [78]. In der Forschung zur Optimierung von Versorgungstechnik und Produktionsplanung kommen unterschiedlichste Optimierungstechniken wie beispielsweise genetische Algorithmen, lineare Programmierung oder Reinforcement Learning zum Einsatz [79] [80]. In Hinsicht auf eine energieadaptive Produktionsplanung existieren auch bereits Vorarbeiten, beispielsweise wird in [81] eine Optimierung einer Werkstattfertigung mittels eines exakten Optimierungsverfahrens

durchgeführt. Dabei wird jedoch, wie auch in vielen weiteren Quellen festgestellt, dass das Verfahren bei komplexeren Problemstellungen, wie sie in der Realität auftreten, schnell an seine Grenzen stößt.

Daher finden Optimierungsalgorithmen in der Industrie nur selten Anwendung zur Betriebsoptimierung energetischer Versorgungssysteme [82]. Eine Studie zur Identifizierung der Hemmnisse von Industrie 4.0 stellt vor allem fehlende Standards, unzureichende informationstechnische Infrastruktur, unzureichendes Know-how und unausgereifte Technologien als Problem heraus [83]. Weitere Probleme des Einsatzes von künstlicher Intelligenz zur Steuerung von Energiesystemen erarbeitet eine Metastudie zum Thema Smart Grids. Für den zukünftigen Forschungsbedarf soll eine Vereinheitlichung bestehender Lösungskonzepte in der weiteren Forschung fokussiert werden. Außerdem sind bestehende Werkzeuge zu verfeinern und an die Komplexität realer Systeme unter Unsicherheit anzupassen.

Aus der Recherche geht hervor, dass die Energiedatenerfassung bisher mit großem Aufwand verbunden ist und die Anwendung von Strategien zur Betriebsoptimierung in der Praxis selten umgesetzt wird. Deswegen sollen in KI4ETA Lösungen entwickelt werden, um dies zu vereinfachen.

1.5. Zusammenarbeit der Partner

1.5.1. Aufbau des Forschungskonsortiums

Das Forschungskonsortium besteht aus einem Zusammenschluss von Forschungsinstituten aus Maschinenbau, Mechatronik, Elektrotechnik, Informatik und ausgewählten Industriepartnern, die sowohl an Entwicklungsaufgaben als auch als Anwender der Forschungsergebnisse beteiligt sind. Eine Übersicht der beteiligten Institute und Unternehmen mit der zugehörigen Funktion im Projekt kann Tabelle 1.1 entnommen werden.

Tabelle 1.1: Übersicht der beteiligten Institute und Unternehmen mit der zugehörigen Funktion im Projekt.

Unternehmen / Institut	Funktion im Projekt	Ansprechperson
Geförderte Partner		
 Institut für Produktionsmanagement, Technologie und Werkzeugmaschinen (PTW) Forschung – Produktionstechnik (Maschinenbau)	• Konsortialführer • Leitung TP 3, 4, 5 und 7 • Untersuchungen zum Einsatz von Edge Devices zur Erfassung und Verarbeitung hochfrequenter Daten • Entwicklung von Programmen zur automatisierten Energiedatenaufnahme und –verarbeitung für die energetische Transparenzschaffung und Lastprognose • Entwicklung von Algorithmen zur energetischen Betriebsoptimierung der Fabrik mit KI-Verfahren • Zentrale und dezentrale Anlagensteuerung mit Algorithmen auf Edge Devices und in der Cloud • Entwicklung, Analyse und Bewertung der entwickelten Applikationen im realen Großdemonstrator und Versuchsfeld ETA-Fabrik	Hr. Prof. Dr.-Ing. Matthias Weigold
 Institut für Mechatronische Systeme im Maschinenbau (IMS) Forschung – Mechatronik (Maschinenbau)	• Leitung TP 6 (Sektorenkopplung) • Steuerung und Regelung eines hybriden Speichersystems im Hinblick auf die zentralen Anforderungen der Fabrik • Modellbildung des Hybridspeichers und des Ladesystems zur Integration in zentrale Optimierungsansätze • Aufbau von bidirektionalen Ladepunkten und Entwicklung von geeigneten Ladestrategien zur Optimierung des Mobilitätsenergiebedarfs unter Berücksichtigung der Regelziele der Fabrik • Entwicklung von Kommunikationsschnittstellen und Handelsstrategien zwischen Fahrzeug, Ladesystem und Fabrik	Hr. Prof. Dr.-Ing. Stephan Rinderknecht
 Deutsches Forschungszentrum für Künstliche Intelligenz (DFKI) Forschungsbereich Innovative Fabrikssysteme Forschung – KI in der Fabrik	• Leitung TP 2 (Vernetzung und Sicherheit) • Machine Learning in der Fabrik (Transfer Learning, Transparenz/Erklärbarkeit) • Assistenz mittels Augmented Reality (AR) • Autonome Identifikation von Leckagen	Hr. Prof. Dr. Martin Ruskowski

 atlan-tec OPTIMIERE DEINE MÖGLICHKEITEN.	atlan-tec Systems GmbH Dienstleister – Energieeffizienz Prozessindustrie	• Entwicklung eines Konzeptes für Energiemessungen in der Prozessindustrie • Prognose und Optimierung von Wärmeerzeugung und Wärmebedarfen in Industrieparks • Untersuchungen zur Übertragbarkeit der Projektergebnisse aus der Metallverarbeitung in die Prozessindustrie	Hr. Thomas Froese
 BOSCH	Robert Bosch GmbH Mischkonzern	• Anbindung von Maschinen und Datenerfassung in einem Werk bei Bosch Rexroth • Unterstützung bei der Sicherstellung der industriellen Anwendbarkeit im Projekt entwickelter Lösungen • Untersuchungen zur Anwendung und Übertragbarkeit von datenbasierten Modellen in verschiedenen Produktionsstätten • Entwicklung von energieoptimalen Betriebsstrategien einer Schleifmaschine auf Basis von Petri-Netzen unter Berücksichtigung der Werkstückqualität	Hr. Dr. Michael Walther
	Entega AG Energieversorgungsunternehmen	• Real-time-pricing für produzierende Unternehmen • Bewerten von Assistenzsystemen aus energiewirtschaftlicher Perspektive	Hr. Dr. Nils Roloff
	EJOT SE & Co. KG Metall- und Kunststoffverarbeitung	• Intelligente Anbindung und Auswertung von Sensoren und Energiezählern einer EJOT-Maschine an die Plattform • Bewertung des Nutzens von Energiedaten für Condition Monitoring von Werkzeugen • Austausch von Maschinen- und Energiedaten über OPC UA TSN mit dem Ziel, Bauteilqualität vorherzusagen und somit einen Mehrwert für Energiedaten zu schaffen • Übertragbarkeit von datenbasierten Maschinenmodellen über Transfer Learning	Hr. Dr. Christoph Bauerdick
	etalytics GmbH Dienstleister – Data Analytics & Software	• Leitung TP1 (Smarte Energiemanagementplattform) • Plug&Work von Anlagen auf Plattform-Ebene • Semantische Informationsmodelle und Metadaten Bereitstellung • Deep Reinforcement Learning (KI), mathematische Optimierung (MILP) und Auto-ML Prognose für Energiesysteme	Hr. Dr. Niklas Panten
	Evonik Resource Efficiency GmbH Chemieunternehmen	• Vorschlagwesen für Hydrauliköle mit optimierten Materialparametern, um bei anstehenden Ölwechseln Energie und Kosten zu sparen • Entwicklung einer mobilen Hydraulikölmesseinheit	Hr. Dr. Dmitriy Shakhvorostov
	GreenDelta GmbH	• Untersuchungen zum optimierten Betrieb und Auslegung von Wärmenetzen	Hr. Dr. Andreas Ciroth

	Dienstleister - Ressourceneffizienz	• Ausweitung der Nutzung von Projektergebnissen auf Ressourcenverbräuche • Übertragung der entwickelten Algorithmen von der metallverarbeitenden Industrie auf weitere Industriezweige	
	ÖKOTEC Energiemanagement GmbH Dienstleister – Energiemanagement-Systeme	• Erweiterung und Automatisierung der generischen Energiekennzahlensystematik um Zustandsräume und semantische Informationsmodelle • Muster- und Fehlererkennung aus Energiedaten • Automatisierte Kurzfristprognose zum Netzverhalten in Kältesystemen • Betriebsoptimierung durch Zustandsraummodelle	Hr. Arne Grein
	Software AG Dienstleister – Big Data Software	• Datenpunktidentifikation mittels Machine Learning Algorithmen • Anbindung von Geräten mithilfe des OPC UA over TSN Standards • Vorschlagswesen für Auswertungen mittels Machine Learning	Hr. Dr. Dietmar Gärtner
	TÜV Technische Überwachung Hessen GmbH Dienstleister – IT-Sicherheit und Zertifizierung	• Untersuchung und Bewertung der Zuverlässigkeit von KI gesteuerten Systemen • IT-Sicherheit in hoch vernetzten Systemen • Fehler und Ausfallsicherheit des automatischen Datenflusses in datenbasierten Systemen	Hr. Lars Komrowski
Unterauftragnehmer			
	CuroCon GmbH Dienstleister – Automatisierungstechnik	• Implementieren der für den Einsatz KI-basierter Assistenzsysteme notwendigen Automatisierungstechnik • Bereitstellung von Infrastruktur für die Erprobung von KI-basierten Technologien • Technologie und Programmierung für das bidirektionale Ladesystem • Zukünftige Verwertung der KI-basierten Technologien innerhalb der geplanten Projekte für Depotladetechnik für eNutzfahrzeuge und eBusse und Energiemanagement in Bürogebäuden und im Quartier	Hr. Michael Wißbach
	Mader GmbH & Co. KG Drucklufttechnik	• Entwicklung eines Roboters zur Detektion von Leckagen im Druckluftnetz der Fabrik • Untersuchungen zum Datenaustausch zwischen unterschiedlichen IoT-Plattformen	Fr. Stefanie Kästle

Assoziierte Partner

 A Bosch Company	Bosch Rexroth AG Industrieautomatisierung	• Anwendung entwickelter Lösungen im Werk Schweinfurt • Unterstützung mit Know-How aus dem Bereich der Produktion und der Energieeffizienten Fertigung	Hr. Leo Pototzky
	B&R Industrial Automation GmbH Industrieautomatisierung	• Unterstützung mit Industrie PCs und zugehöriger Steuerungs- und IO-Hardware • Support für Hardware und Softwareanwendungen auf B&R Komponenten	Hr. Frederik Winter
	Citiworks AG Energiehandelsunternehmen	• Einsatz von Blockchain im Energiehandel • Untersuchungen zum Einsatz von Smartmetern (intelligenten Stromzählern) im Fabrikumfeld	Hr. Tomislav Luksa
	Energeering AG Dienstleister – Energieberatung	• Beistellung von Daten, zur Erprobung entwickelter Methoden und Algorithmen • Unterstützung bei der Erarbeitung von optimierten Steuerungsvorgaben von Kalteanlagen und Kühlsystemen • Optimierung der Steuerung von elektrischen Kälte- und Wärmesystemen	Hr. Holm Riedel
	Janitza electronics GmbH Energiesmesstechnik	• Beistellung von Messtechnik zur Leistungsanalyse • Beratende Mitwirkung im Projekt im Bereich der Energiesmesstechnik	Hr. Holger Dietz
	MVV Umwelt Asset GmbH Energieversorgungsunternehmen	• Unterstützung bei der Betrachtung von Dampfnetzen • Bereitstellung von Daten aus einem ausgesuchten Prozess bei MVV • Möglichkeit zur Implementierung im Projekt entwickelter Lösungen	Hr. Georg Baumgärtner



**Verband Deutscher Maschinen- und
Anlagenbau e.V.**

Industrieverband
(Fachverband Allgemeine Lufttechnik)

- Unterstützung des Transfers entwickelter Lösungen in die Industrie, insbesondere im Bereich der Maschine-Maschine Kommunikation
- Einbringen von Projektergebnissen in das BMWi geförderte Projekt Interfaces for Industrial Production

Hr. Dr. Thomas Schröder

1.5.2. Koordination des Projekts

Die Gesamtkoordination des Projekts übernimmt das PTW in Person des Institutsleiters Prof. Dr.-Ing. Matthias Weigold. In diesen Verantwortungsbereich fallen alle wesentlichen Koordinationsaufgaben, wie die Planung, Abstimmung und Fortschreibung des Projektrahmenplanes. Auch die Sicherstellung des Informations- und Erfahrungsaustausches der Projektpartner, die Organisation des Berichtswesens und die Öffentlichkeitsarbeit sind in der Koordinationsverantwortung enthalten. Das Berichtswesen beinhaltet die Erstellung von halbjährlichen Zwischenberichten zu Ergebnissen des Projektverbunds durch Zusammenführung der Berichte der einzelnen Projektpartner. Hierin sind auch Verwendungsnachweise zu den einzelnen Meilensteinterminen enthalten.

Des Weiteren trägt jeder Teilprojektleiter die Verantwortung zur Durchführung der einzelnen Projekte und deren Abstimmung im Gesamtkontext. Der Projektkoordinator verantwortet die Publikation eines finalen Abschlussberichts, der die wissenschaftlichen Ergebnisse der breiten Öffentlichkeit zugänglich macht.

Für die Durchführung des Projektes KI4ETA ist die Zusammenarbeit einer Vielzahl von Partnern aus Forschung und Industrie mit verschiedenen wissenschaftlichen Hintergründen nötig. Die Arbeitsteilung wird entsprechend der in




Abbildung 1.7 dargestellten Teilprojekte realisiert. Für jedes Teilprojekt ist einer der genannten Kooperationspartner als Teilprojektleiter verantwortlich.




Abbildung 1.7: Übersicht der Projektorganisation.

Eine wichtige Aufgabe ist die Sicherstellung der Kommunikation zwischen allen Projektpartnern. Im Projekt werden dazu folgende Maßnahmen etabliert:

- Persönliche Arbeitstreffen sowie telefonische Abstimmung zwischen Bearbeitern eines Arbeitspaketes zur inhaltlichen Erarbeitung der Forschungsergebnisse
- Regelmäßige Arbeitssitzungen zum Informations- und Erfahrungsaustausch zwischen den verschiedenen Teilprojekten und ganzheitlichen Integration der Einzelergebnisse zu einem wissenschaftlichen, aber auch praxisgerecht anwendbaren Gesamtergebnis. Diese können vor Ort bei einzelnen Projektpartnern oder als Webkonferenz stattfinden.

2. Wissenschaftlich-technische Forschungsergebnisse

2.1. Teilprojekt 1: Smarte Energiemanagementplattform

Im Rahmen dieses Teilprojektes soll eine innovative Datenmanagementplattform geschaffen werden, die hochspezialisiert für vernetzte Energiesysteme und Data Analytics Anwendungen ausgelegt wird. Sie stellt die technologische Grundlage für viele der in anderen Teilprojekten erarbeiteten smarten Services dar. Weil KI- und Optimierungsverfahren sowie Energiesimulationen in der Praxis von Energiemanagement-Teams häufig an der Komplexität scheitern, liegt ein Fokus der Plattform auf der Usability für den Endanwender.

Ein Ziel ist es, Lösungen zu generieren, wie die Plattform durch fortwährende Hintergrundprozesse automatisch Vorschläge generieren und den Menschen bei der Interaktion mit dem System unterstützen kann. Durch Plug & Work Funktionalität und die Machine Learning basierte Identifizierung von Datenpunktpprofilen soll der Zeitaufwand zur Parametrierung der Software weiter reduziert werden. Zudem müssen die in anderen Arbeitspaketen entwickelten komplexen Algorithmen möglichst flexibel und unabhängig von den Grundfunktionalitäten der Plattform eingebunden werden können.

Dafür werden eine Data Analytics Engine und standardisierte Schnittstellen entwickelt, die durch entsprechende Module der Plattform parametriert, ausgelesen und gesteuert werden können. Die

Plattform erspart dem Energiemanager letztlich Zeit bei der Auswertung großer Datenmengen, sodass die begrenzten Personalressourcen auf die tatsächliche Optimierung der Energiesysteme fokussiert werden können. Durch die flexible Integration von innovativen KI-basierten Methoden lassen sich zudem neue Einsparpotenziale heben. Die einfache Integration von Daten und KI-Algorithmen räumt somit bisher bestehende Hemmnisse bei der Implementierung aus.

Tabelle 2.1: Arbeitspakete in Teilprojekt 1.

Smarte Energiemanagementplattform		Beteiligte Partner
Teilprojektleitung: etalytics		
AP 1.1	Semantisches Informationsmodell für die Sensor- und Metadaten vernetzter Energiesysteme	etalytics, Bosch, DFKI, Software AG
AP 1.2	Flexibles Data Analytics und Energiemanagement Backend	etalytics, PTW
AP 1.3	Objektorientiertes Daten-Gateway für Plug & Work Connectivity	etalytics
AP 1.4	ML-basierte Datenpunktidentifikation	Software AG, PTW
AP 1.5	Cross-Plattform Kommunikation	etalytics, Entega, Mader, Software AG

2.1.1. Arbeitspaket 1.1: Semantisches Informationsmodell für die Sensor- und Metadaten vernetzter Energiesysteme

Aufgabenstellung aus dem Antrag: Die ursprüngliche Aufgabe des Projekts bestand darin, ein semantisches Informationsmodell (IM) für die Sensor- und Metadaten vernetzter industrieller Energiesysteme zu entwickeln. Dieses Modell sollte die umfassenden Verknüpfungen zwischen den kontinuierlich erfassten Daten und zugehörigen Metadaten erfassen und für Data Analytics Anwendungen nutzbar machen. Ziel war es, ein System zu schaffen, das sowohl in Brownfield- als auch in Greenfield-Umgebungen innerhalb einer Energiemanagementplattform leicht integriert und genutzt werden kann.

Durchgeführte Arbeiten und Ergebnisse: Im Laufe des Projekts wurden mehrere zentrale Aktivitäten durchgeführt. Zunächst wurde ein Workshop mit allen beteiligten Konsortialpartnern organisiert, um die Anforderungen für das semantische Informationsmodell zu diskutieren und zu aggregieren. Es wurde entschieden, dass jedes Unternehmen im Konsortium seine eigenen, bereits etablierten Datenmodelle weiterverwendet und bei Bedarf ein Mapping zwischen den Modellen entwickelt, um eine reibungslose Integration zu gewährleisten. Das Datenmodell von Cumulocity ist in Abbildung 2.1 zu sehen und das von etaONE in Abbildung 2.2. Dieser Ansatz ermöglichte eine flexiblere Handhabung der unterschiedlichen Systeme und Technologien der Partner.




Abbildung 2.1: Domänenmodell von Cumulocity.




Abbildung 2.3: Screenshot eines ersten funktionalen Demonstrators inklusive Visualisierung von Verbindungseigenschaften durch Farben sowie Animationsgeschwindigkeit.

Zusammenfassung der Ergebnisse: Die Ergebnisse des Projekts zeigen, dass durch die Entwicklung und Implementierung des semantischen Informationsmodells eine effiziente Verwaltung und präzise Modellierung vernetzter Energiesysteme ermöglicht wird. Die Graph-basierten Informationsmodelle und die dazugehörigen Visualisierungstools haben sich als besonders wertvoll erwiesen, um die komplexen Interaktionen und Zustände innerhalb der Energiesysteme darzustellen und zu analysieren. Die Flexibilität, bestehende Datenmodelle der Konsortialpartner zu integrieren und bei Bedarf zu erweitern, hat zudem eine breite Akzeptanz und Anwendbarkeit in verschiedenen industriellen Kontexten gefördert. Insgesamt bieten die entwickelten Systeme und Werkzeuge eine solide Grundlage für weitere Optimierungen und Erweiterungen im Bereich des Energiemanagements und der automatisierten Systemanalyse.

Zusammenfassung der Arbeiten je Partner

etalytics (Leitung):

- Organisation und Durchführung von Workshops zur Diskussion und Aggregation von Anforderungen für das semantische Informationsmodell (IM).
- Evaluation verschiedener Open-Source-Modelle sowie Weiterentwicklung des eigenen proprietären Informationsmodellkonzepts.
- Entwicklung der ersten Benutzeroberflächen-Skizzen sowie weiterführende Entwicklung und Professionalisierung dieser Oberflächen basierend auf einer kommerziellen Diagrammbibliothek.
- Implementierung dynamischer Verbindungsfarben und -geschwindigkeiten abhängig von ausgewählten Systemeigenschaften.
- Entwicklung einer Funktionalität für eine vollständig automatische Anordnung von Elementen und Verbindungen gemäß der Topologieinformationen.

- Technische Spezifikation und Implementierung von verschachtelten Systemen ("Scope Nodes") im Backend und in der API.
- Forschung und Analyse zu alternativen Visualisierungsbibliotheken zur Ablösung der aktuellen kommerziellen Bibliothek.

Bosch:

- Teilnahme an Workshops und Diskussionen zum Informationsmodell.
- Vorstellung und Integration des Bosch Industry 4.0 Knowledge Graph.
- Diskussion der Erweiterung des Informationsmodells durch Übernahme spezifischer Antriebsdaten (SERCOS Parameter).

DFKI:

- Diskussion und Beitrag zu den Anforderungen des Informationsmodells im Rahmen der Workshops.

ÖKOTEC:

- Bewertung der Übertragbarkeit semantischer Informationsmodelle im Kontext bestehender Datenstrukturmodelle in der EnEffCo® Software.

Software AG:

- Teilnahme an Diskussionen zum Informationsmodell und Abstimmung über das Datenmodell mit etalytics.

2.1.2. Arbeitspaket 1.2: Flexibles Data Analytics und Energiemanagement Backend

Aufgabenstellung aus dem Antrag: Die Notwendigkeit, große Datenmengen effizient zu verarbeiten, um energieintensive Prozesse zu optimieren, hat zur Entwicklung eines innovativen Energiemanagementsystems geführt. Bestehende Systeme waren oft nicht in der Lage, KI-Verfahren effektiv zu integrieren oder große Mengen an Energie- und Produktionsdaten zeitnah zu verarbeiten. Ziel dieses Projektes war es, eine flexible, erweiterbare Infrastruktur zu schaffen, die leistungsfähig genug ist, um anspruchsvolle Data Analytics Jobs und Machine Learning Modelle zu unterstützen, insbesondere in Brownfield- und Greenfield-Anwendungen (vgl. Beispiel in Abbildung 2.4).

Durchgeführte Arbeiten und Ergebnisse: Das Projektteam hat eine fortschrittliche Backend-Infrastruktur entwickelt, die es ermöglicht, Daten effizient zu speichern, zu verwalten und abzurufen. Hierfür wurde eine Open-Source noSQL Zeitreihen-Datenbank implementiert, die speziell auf die Anforderungen von Zeitseriendaten zugeschnitten ist. Es wurden auch eine Data Analytics Job Pipeline und eine REST/JSON Schnittstelle entwickelt, um die Verwaltung von Data Analytics Jobs zu vereinfachen.




Abbildung 2.4: Beispielhafter Use Case für Data Analytics Backend (Scripts Engine).

Ein wichtiger Bestandteil des Projekts war die Integration von Python-basierten Machine Learning Modellen, die eine Verarbeitung von Echtzeitdaten ermöglichen. Die entwickelte Lösung nutzt Container und Kubernetes, um eine skalierbare und sichere Ausführung der Algorithmen zu gewährleisten (s. Schema in Abbildung 2.5).




Abbildung 2.5: Schema zur entwickelten Architektur.

Dieser Ansatz hat es ermöglicht, rechenintensive Aufgaben effizient zu verwalten und bei Bedarf auf externe Ressourcen auszulagern. Dabei wurden unterschiedliche Studien zur Ausführungszeit von

nativen Python Scripts, mit Docker virtualisierten Scripts sowie in Kubernetes orchestrierten Scripts durchgeführt (s. Beispielhafte Ergebnisse in Abbildung 2.6).




Abbildung 2.6: Untersuchungen zu mittlerer Ausführungszeit einer Python Anwendung in Kubernetes, Docker und nativ.

Demonstratoren und Versuchsaufbauten: Ein zentraler Demonstrator des Projekts ist die „Scripts Engine“, die es Nutzern ermöglicht, Machine Learning Skripte in einer gesicherten Umgebung auszuführen. Die Skripte können über eine grafische Benutzeroberfläche gesteuert werden, die auch industriellen Nutzern eine intuitive Bedienung ermöglicht. Der Demonstrator hat gezeigt, wie verschiedene Anwendungsfälle, insbesondere in den Bereichen Real-Time Data Streaming und Batch-Processing, effektiv umgesetzt werden können.

Zusammenfassung der Ergebnisse: Die Ergebnisse des Projekts umfassen eine leistungsfähige Infrastruktur für das KI-gestützte Energiemanagement, die sowohl die technischen als auch die funktionalen Anforderungen moderner Industrieanwendungen erfüllt. Die entwickelte Plattform ermöglicht eine flexible Anbindung von Energiedaten, die Ausführung von komplexen Algorithmen und eine skalierbare Ressourcenverwaltung. Durch die Implementierung von Best Practices für IT-Sicherheit und die Nutzung von Open-Source Technologien konnte eine kosteneffektive und robuste Lösung realisiert werden, die auch für zukünftige Anforderungen erweiterbar bleibt.

Zusammenfassung der Arbeiten je Partner

etalytics (Leitung):

- Durchführung von Workshops zur Aggregation von Anforderungen und Sammlung technischer Use Cases für das Data Analytics Backend.
- Evaluation verschiedener technischer Lösungen für die Implementierung der Scripts Engine.
- Entwicklung und Programmierung eines Proof of Concept (PoC) für die API und das Data Analytics Backend.
- Sicherheitsanalyse bei der Ausführung von Skripten zur Wahrung der IT-Sicherheit.
- Testen und Evaluation der Funktionalität des Data Analytics Backends.
- Vorbereitungen und Durchführung des On-Premises Deployments auf einer virtuellen Maschine des PTW.
- Weiterentwicklung des Scripts Engine Demonstrators, insbesondere Optimierung der Storage-Performance und strukturierteres Logging.
- Reduktion der Größe von automatisiert erzeugten Python Environments für schnellere Ausführungen.
- Entwicklung eines Transformations Engine Demonstrators zur mathematischen Vorverarbeitung von Zeitseriendaten.
- Robustheitsanalyse und Debugging des Scripts Engine Demonstrators unter hoher Last.

- Weiterentwicklung der Transformations-Engine zur Unterstützung von verschachtelten Transformationen.
- Entwicklung neuer Transformationsmethoden für die Zeitserien (Integration, Ableitung, kumulierte Summe, Potenz).
- Entwicklung einer Funktion zur Verknüpfung von Features in Transformationen.
- Spezifikation eines Retention Policy Features zur automatischen Aggregation und Löschung älterer Zeitseriendaten.
- Implementierung und Stabilisierung neuer Funktionen wie GlobalMax, GlobalMin, GlobalSum sowie logischer Funktionen.

PTW:

- Mitwirkung bei der Sammlung von Anforderungen für das Data Analytics Backend.
- Bereitstellung einer virtuellen Maschine für das Deployment der Software Services in der ETA-Fabrik.
- Unterstützung bei der Datenanbindung in der ETA-Fabrik.
- Erprobung der Scripts Engine und Einsatz erster ML/KI Scripte.

2.1.3. Arbeitspaket 1.3: Objektorientiertes Daten-Gateway für Plug & Work Connectivity

Aufgabenstellung aus dem Antrag: Die zunehmende Verfügbarkeit von Daten auf Anlagen- und Komponentenebene stellt eine große Herausforderung dar, da die Integration dieser Daten in eine gemeinsame Datenbasis für Data Analytics Anwendungen mit angemessener Semantik erheblichen Aufwand erfordert. Bisher mussten tausende von Sensoren und Prozessvariablen manuell in Monitoringsystemen parametrieren werden, was sowohl zeitintensiv als auch fehleranfällig ist und somit eine signifikante Barriere für den Einsatz von KI-gestützten Verfahren darstellt. Das Ziel dieses Arbeitspaketes war die Entwicklung einer Plug & Work Funktionalität für ein smartes Energiemanagement, die die Anbindung von Sensoren, Zählern und weiteren Feldgeräten vereinfacht. Diese Funktionalität sollte im Backend der Energiemanagementplattform implementiert werden, um die effiziente Verwaltung und Parametrierung von Geräten und Daten zu ermöglichen. Der Fokus lag auf der Anwendung in Greenfield-Szenarien mit besonderem Augenmerk auf der Unterstützung moderner Kommunikationsprotokolle wie OPC UA, Modbus TCP und BACnet.

Durchgeführte Arbeiten und Ergebnisse: Ein modular erweiterbares Daten-Gateway wurde entwickelt, das die Anbindung von TCP/IP-basierten Protokollen mit flexiblen Gerätespezifikationen ermöglicht. Dieses Gateway integriert die Ergebnisse aus vorherigen Arbeitspaketen, insbesondere im Hinblick auf die Standardisierung von Datenstrukturen durch OPC UA Companion Specifications. Eine wichtige Komponente des Gateways ist die REST/JSON Schnittstelle, die eine einfache Parametrierung der Devices und Datenkanäle ermöglicht. Zudem wurde eine graphische Benutzeroberfläche entwickelt, die die Konfiguration des Daten-Gateways vereinfacht und es Benutzern ermöglicht, Daten effizient an Cloud-Plattformen weiterzuleiten (vgl. UI/UX Skizzen in Abbildung 2.7).




Abbildung 2.7: Erster Entwurf von UI/UX Skizzen für objektorientierte Daten-Gateway Funktionalität.

Demonstratoren und Versuchsaufbauten: Die entwickelte Lösung beinhaltet eine objektorientierte Daten-Gateway Funktionalität, die eine effiziente Verwaltung von wiederkehrenden Datenpunkt-Schemata ermöglicht. Durch die Einführung von "Managed Ressourcen" innerhalb der Plattform können nun komplette Datenpunkt-Sets von Geräten, die durch Standards wie die OPC-UA Companion Specifications definiert sind, mit wenigen Klicks angebunden werden (s. Screenshots des Demonstrators in Abbildung 2.8). Die Funktionalität wurde durch einen funktionalen Demonstrator untermauert, der die automatisierte Erzeugung und Synchronisation von Ziel-Zeitserien aus einzelnen Datenpunkten zeigt.




Abbildung 2.8: Screenshots des funktionalen Demonstrators für die Plug&Work Fähigkeit von Datenpunkt Sets.

Zusammenfassung der Ergebnisse: Die Ergebnisse des Projekts haben zu einer signifikanten Vereinfachung der Geräteanbindung und Datenmanagement in Energiemanagementsystemen geführt. Die neu eingeführte Funktionalität reduziert den Parametrierungsaufwand erheblich und verbessert die Datenqualität durch automatisierte Verfahren. Die entwickelte Lösung stellt eine wichtige Basis für zukünftige Erweiterungen und Optimierungen im Bereich des smarten Energiemanagements dar und bietet eine robuste Plattform für die Implementierung von Data Analytics und Machine Learning Algorithmen.

Zusammenfassung der Arbeiten je Partner

etalytics (Leitung):

- Durchführung von Workshops zur Aggregation von Anforderungen und zur Sammlung von User Stories und technischen Use Cases.
- Entwicklung der ersten UI/UX Skizzen und der API für das objektorientierte Daten-Gateway.
- Konzeption und Entwicklung der REST API im openAPI Format, um die Parametrierung und Verwaltung des Daten-Gateways zu ermöglichen.
- Entwicklung eines flexiblen, modular erweiterbaren Daten-Gateways zur Anbindung von Geräten über TCP/IP basierte Protokolle wie OPC UA, Modbus TCP und BACnet.
- Integration der Daten-Gateway-Funktionalität als Microservice/Container für das Deployment auf industriellen Edge-Devices.
- Umfangreiche Entwicklung und Programmierung der Endpunkte der Rest API, die das Anlegen von Datenpunkt Set Typen und deren Instanzen ermöglicht.
- Implementierung der "Managed Ressourcen" in der etaONE Plattform zur Unterstützung der automatisierten Erzeugung und Synchronisation von Ziel-Zeitserien aus Datenpunkten.
- Entwicklung einer graphischen Benutzeroberfläche zur einfachen und intuitiven Parametrierung des Daten-Gateways.
- Spezifikation und Implementierung neuer Funktionalitäten für die effiziente Verwaltung von Geräteanbindungen und Datenpunkten, insbesondere im Kontext der OPC-UA Geräte.
- Implementierung und Testung der neuen Funktionalitäten, insbesondere die automatisierte Erzeugung und Verwaltung von Datenpunkt Sets.

PTW:

- Unterstützung bei der Datenanbindung und Integration in die ETA-Fabrik.

2.1.4. Arbeitspaket 1.4: ML-basierte Datenpunktidentifikation

Im Rahmen dieses APs wurde eine Machine-Learning basierte Datenpunktidentifikation entwickelt, die im späteren Betrieb ohne Expertenwissen eine automatische Schätzung von Metadaten (z. B. physikalische Größen, Einheiten oder Kontext) ermöglicht. Der Zeitaufwand zur Einbindung und Aktualisierung von Datenpunkten wird auf diese Art reduziert, da weniger Eingaben manuell vorgenommen werden müssen.

Da die meisten Messdaten der verwendeten Maschinen und Systeme in diesem Projekt mittels OPC UA Server zugänglich sind, wurde an der ETA-Fabrik Zugriff auf die verwendeten OPC UA Server für Projektpartner geschaffen, um die Maschinendaten abrufen zu können. Zu verschiedenen Zeitpunkten im Jahr finden sogenannte Produktionswochen statt, in denen Werkstücke bearbeitet werden, sodass während dieses Prozesses die Daten in Echtzeit ausgelesen, weitergeleitet und weiterverarbeitet werden konnten. Darüber hinaus sind die Daten aus vorangegangenen Produktionswochen aus dem EnEffCo®-System auslesbar.

Es sind folgende Schritte zur ML-basierten Bestimmung der Datenpunkte durchgeführt worden:

1. Erstellung eines Programms, das sich mit einem OPC UA Server verbindet und die Baumstruktur automatisch durchläuft, um zu bestimmen, an welchen Stellen des Baums sich verändernde

-
- Messwerte befinden. Von diesen wird der Datentyp bestimmt und die gesammelten Informationen werden zur späteren Weiterverarbeitung gespeichert.
 2. Nachdem die sich verändernden Messwerte eines OPC UA Servers bestimmt wurden, werden für jede dieser Zeitreihen über einen längeren Zeitraum Daten aufgenommen, um sie analysieren zu können.
 3. Die Analyse erfolgt mittels Machine-Learning Methoden, um die Art der Messwerte, z. B. Spannung oder Temperatur oder Drehzahl, zu bestimmen und diese zu klassifizieren und in Gruppen einteilen zu können.
 4. Erstellung eines Vorschlagswesens, um die Art des Datenpunktes bestimmen zu können.
 5. Aufgrund der ermittelten Klassen können automatisiert sogenannte Device Protocols für den jeweiligen OPC UA Server für die IoT-Plattform Cumulocity der Software AG erstellt und in diese importiert werden. Dort ist dann automatisch die korrekte Einheit für den Messwert vermerkt und man kann verschiedene Messwerte des gleichen Typs zusammenfassen, sodass sie später in einem Graphen angezeigt werden.
 6. Bei den erfolgten Produktionswochen wurden die Werte automatisch in der IoT-Plattform aufgezeichnet. Auch könnte man aufgrund der vormals bestimmten Wertebereiche eine automatisierte Eliminierung von Messfehlern vornehmen, indem die einzelnen Werte vor dem Abspeichern auf ihre Plausibilität untersucht werden.

Da die betrachteten Daten von OPC UA-Servern stammen, wurde das vom PTW verwendete Erfassungskonzept in Form einer Excel-Tabelle als Datenmodell übernommen.

Zur Umsetzung von Punkt 1 der obigen Aufzählung wurde ein Python-Skript entwickelt, das den OPC UA-Baum durchläuft. Es erkennt Änderungen bei Werten des Typs Integer oder Float, speichert diese und schreibt sie in eine Datei. Anschließend wurden für jeden erfassten Messwert einige Datenpunkte aufgezeichnet, um Punkt 2 zu adressieren.

Nach dem Durchlauf des OPC UA-Baums bietet das Skript eine Konfigurationsmöglichkeit: Es fragt den Benutzer, ob die erkannten Messwerttypen korrekt sind oder angepasst werden sollen. Dabei werden die drei passendsten Typen mit der ermittelten Genauigkeit vorgeschlagen. Falls erforderlich, kann der Benutzer jedoch einen eigenen Typ festlegen (Punkt 4).

Sobald die messbaren Größen bestimmt wurden, generiert das Python-Skript ein Cumulocity-Template. Nach dem Laden ermöglicht dieses Template die direkte Erfassung der Daten in Cumulocity (Punkt 5).

Ein typischer Durchlauf des Skripts ist in Abbildung 2.9 dargestellt: Links ist die Kommandozeilenausgabe zu sehen, unten in der Mitte ein Ausschnitt aus dem generierten Cumulocity-Template und rechts der Benutzerdialog zur Festlegung der Messreihe. Zur Unterstützung dieser Entscheidung werden die letzten erfassten Werte grafisch dargestellt.




Abbildung 2.9: Beispiel für die graphisch unterstützte Datenpunktidentifikation.

Punkt 3 wurde durch eine von der Software AG betreute Bachelorarbeit adressiert [84]. In dieser Arbeit wurden verschiedene Algorithmen miteinander verglichen. Beim Preprocessing der Daten unter Verwendung einer für Zeitreihen optimierten Bibliothek wurden Erkennungsgenauigkeiten (accuracy) von über 95 % erzielt (siehe Abbildung 2.10).

Zusätzlich zu den OPC UA-Serverdaten wurden auch Daten von Modbus-Servern angebunden. Eine automatisierte Integration ist hier jedoch nicht möglich, da eine genaue Kenntnis der jeweiligen Serverstruktur erforderlich ist. Dazu gehören unter anderem Informationen darüber, ob das System im Big-Endian- oder Little-Endian-Format arbeitet und in welchen Registern die relevanten Daten gespeichert sind.




Abbildung 2.10: Vergleich der Accuracy verschiedener ML Algorithmen zur Datenpunktidentifikation.

Zusammenfassung der Arbeiten je Partner

Software AG (Leitung):

- Erstellung eines Python-Skripts zum Scannen des OPC UA Baums und ML-basierter Datenpunktidentifikation
- Anbindung von Modbus Daten
- Erstellung eines UIs zur Klassifizierung der Datenpunkte
- Testen und Dokumentation der erstellten Python-Skripte im Github Repository

PTW:


- Zur Verfügung stellen von Messdaten durch Einrichtung eines Zugriffs auf OPC UA Server und das Energiemanagementsystem der ETA-Fabrik
- Bereitstellung von Daten der ETA-Fabrik via Modbus
- Unterstützung bei Klassifizierung anhand des Verlaufs durch anwenderspezifisches Wissen
- Bereitstellung einer virtuellen Maschine für die Einrichtung der Software-Dienste

2.1.5. Arbeitspaket 1.5: Cross-Plattform Kommunikation

Aufgabenstellung aus dem Antrag: In der Produktion werden vielfältige Softwaresysteme eingesetzt, die oft über veraltete oder schlecht dokumentierte Schnittstellen verfügen. Diese Situation erschwert die Integration einer umfassenden Datenbasis für aussagekräftige Entscheidungsmodelle im Bereich des KI-gestützten Energiemanagements erheblich. Die Herausforderung liegt insbesondere in der mangelnden Kompatibilität vorhandener APIs mit Anwendungen außerhalb ihrer ursprünglichen Plattform. Das Ziel des Arbeitspakets war die Entwicklung einer Lösung, die eine automatische und effiziente Kommunikation zwischen verschiedenen IoT-Plattformen ermöglicht, um Zeitserien- und Metadaten nahtlos auszutauschen. Dies sollte speziell in Brownfield- und Greenfield-Anwendungen im Backend der Energiemanagementplattformen realisiert werden.

Durchgeführte Arbeiten und Ergebnisse: Zur Erreichung dieses Ziels wurden zunächst Anforderungen und Use-Cases für die Cross-Plattform Kommunikation aggregiert. Es wurde eine OpenAPI Spezifikation entwickelt, um einen standardisierten Kommunikationsstandard zwischen den Plattformen zu definieren. Diese Spezifikation unterstützt API-Callback Funktionen, die eine standardisierte Abfrage von Daten oder die Auslösung von Aktionen auf der empfangenden Plattform ermöglichen. Weiterhin wurde ein Demonstrator entwickelt, der den vereinfachten Austausch von Energie- und Prozessdaten zwischen Plattformen zeigt.

Demonstratoren und Versuchsaufbauten: Im Laufe des Projekts wurden mehrere Workshops mit Stakeholdern wie ENTEGA, Software AG, Mader und DFKI organisiert, um die Use Cases zu diskutieren, die einen Datenaustausch zwischen den Plattformen erforderlich machen. Ein zentraler Demonstrator wurde entwickelt, um die neu entwickelten Schnittstellen und deren Funktionen in der Praxis zu testen (vgl. Screenshots in Abbildung 2.11 und Abbildung 2.12). Dieser Demonstrator dient als praktisches Beispiel für den automatisierten und effizienten Datenaustausch zwischen unterschiedlichen Energiemanagementplattformen.



Citiworks API	
URL	https://citiworks.de/api
SKIP TLS VERIFY	false
TIMEOUT	PT10S Timeout 10s
RETRIES	1
AUTHENTICATE	AUTHENTICATION TYPE: OPEN_ID.CONNECT
TOKEN ENDPOINT	https://citiworks.de/api/login
CLIENT ID	anything
CLIENT SECRET	*****
GRANT	PASSWORD

Abbildung 2.11: Screenshot des Demonstrators zur Parametrierung eines REST Devices in der Plattform (am Beispiel der ENTEGA / citiworks API).




Abbildung 2.12: Screenshot der via citiworks API in der Plattform importierten Intraday Marktpreise.

Zusammenfassung der Ergebnisse: Die Ergebnisse des Projekts zeigen, dass durch die Entwicklung standardisierter Schnittstellen und die Anwendung der OpenAPI Spezifikation eine erhebliche Reduzierung des Aufwands für die Datenintegration über Plattformgrenzen hinweg möglich ist. Die eingeführten technischen Lösungen ermöglichen eine flexible, effiziente und skalierbare Kommunikation zwischen verschiedenen Softwaresystemen, was insbesondere für das Energiemanagement von kritischer Bedeutung ist. Die entwickelten Methoden und Werkzeuge verbessern nicht nur die Datenqualität und Verfügbarkeit, sondern erleichtern auch die Implementierung von KI-basierten Analyseverfahren in heterogenen Systemlandschaften.

Zusammenfassung der Arbeiten je Partner

etalytics (Leitung):

- Organisation und Durchführung von Workshops mit Stakeholdern zur Diskussion und Definition der Anforderungen an die Cross-Plattform Kommunikation.

-
- Entwicklung und Bereitstellung der OpenAPI Spezifikationen für die standardisierte Kommunikation zwischen den beteiligten Plattformen.
 - Implementierung eines Demonstrators zur Veranschaulichung der vereinfachten Datenintegration und Kommunikation zwischen verschiedenen Plattformen.
 - Entwicklung und Testung einer generalisierten REST API-Schnittstelle, die eine einfache und flexible Anbindung von Drittsystemen ermöglicht, insbesondere für lesende Zugriffe.
 - Start der Entwicklung einer Funktion für schreibende Zugriffe über REST APIs, um Interaktionen wie das Schreiben von optimierten Stellsignalen oder das Tätigen von Orders zu ermöglichen.

Mader:

- Beteiligung an den von etalytics geleiteten Workshops zur Ausgestaltung der Kommunikationsschnittstellen.
- Bereitstellung technischer Dokumentation und Testung der REST API, um die Anbindung der LOOXR Plattform zu ermöglichen.
- Evaluierung und Entscheidung zur technischen Umsetzung hinsichtlich der Integration von Leckageerfassungsdaten durch Roboter, einschließlich der Überlegung, ob eine OPC-UA Schnittstelle aufgebaut wird.

Entega:

- Enge Abstimmung mit etalytics zur Ausgestaltung und Implementierung der Schnittstelle zwischen den Energiemanagementsystemen von ENTEGA/citiworks und etalytics.
- Teilnahme an den Workshops und Unterstützung bei der Definition relevanter Use Cases für die Datenintegration.
- Durchführung von Tests zur Verifizierung der Schnittstellenfunktionalität, insbesondere in Bezug auf die Integration von Marktdaten in das Energiemanagementsystem.

Software AG:

- Teilnahme an den von etalytics organisierten Workshops zur Cross-Plattform Kommunikation.
- Bereitstellung der Cumulocity IoT Plattform APIs, die ebenfalls als OpenAPI Spezifikation verfügbar sind, und Unterstützung bei deren Integration und Testung im Rahmen des Projekts.

2.2. Teilprojekt 2: Vernetzung & Sicherheit

Eine wichtige Grundlage für die im Projekt betrachteten Themen ist die Vernetzung der Produktion. Sie ist Voraussetzung für die Datenerfassung und wird für die Steuerung von Komponenten und Anlagen benötigt. Insbesondere wenn, wie in diesem Projekt, Betriebsoptimierungsansätze verfolgt werden, ist ein zuverlässiger Datenaustausch zwischen verschiedenen Anlagen und der zentralen Plattform wichtig. Gleichzeitig liegt hier jedoch ein erstes Hindernis für die Schließung der Energieeffizienzlücke, da die Herstellung der Vernetzung üblicherweise mit hohen Kosten verbunden ist, deren Nutzen sich für ein Unternehmen nicht sofort erschließt. In diesem Teilprojekt soll daher eine Kostensenkung angestrebt werden, die durch Vereinfachungen in mehreren Teilbereichen erzielt wird. Gleichzeitig müssen Sicherheit und Zuverlässigkeit hochgradig vernetzter Systeme sichergestellt werden, um die nötige Akzeptanz für die Anbindung von Anlagen an ein Netzwerk bei Unternehmen, Mitarbeitern und Kunden zu schaffen.




Abbildung 2.13: Anbindung von Geräten über Edge Devices an die zentrale Managementplattform.

In diesem Teilprojekt werden Endgeräte befähigt, sodass sich diese, ähnlich der Plug & Play Technologie, die aus dem Bereich der Personal Computer bekannt ist, schnell und einfach in die zentrale Managementplattform anbinden lassen. Messsysteme sollen Daten mittels maschinellen Lernens vorauswerten und direkte Rückmeldung an die Plattform und den Nutzer geben können. Weiterhin werden komplexere Systeme dazu befähigt, die in den nachfolgenden Teilprojekten entwickelten Algorithmen zur Steuerung und energetischen Optimierung lokal ausführen zu können. Neben der einfachen Vernetzbarkeit im industriellen Produktionssystem ist die Sicherheit von zentraler Bedeutung. Daher soll eine Methode entwickelt werden, die sicherstellt, dass viele Geräte in die IKT-Infrastruktur eines Unternehmens eingebunden werden können, ohne die Sicherheit zu beeinträchtigen. Zuletzt wird in diesem Teilprojekt die Zuverlässigkeit von selbstlernenden Systemen untersucht. Damit wird sichergestellt, dass die entwickelten Algorithmen tatsächlich für einen industriellen Einsatz geeignet sind und nicht ungewollt instabile Systemzustände hervorrufen können.

Tabelle 2.2: Arbeitspakete in Teilprojekt 2.

Vernetzung & Sicherheit		Beteiligte Partner
Teilprojektleitung: DFKI		
AP 2.1	Befähigung der Maschinen und IKT-Infrastruktur zum Datenaustausch	PTW, DFKI, Bosch, EJOT, Software AG
AP 2.2	Befähigung von Edge Devices zur Vorverarbeitung hochfrequenter Energiedaten	Software AG, EJOT, PTW
AP 2.3	IT-Security in hoch vernetzten Betrieben	TÜV, etalytics, PTW
AP 2.4	Zuverlässigkeit von selbstlernenden Systemen im industriellen Kontext	DFKI, Bosch, TÜV
AP 2.5	Fehler- und Ausfallsicherheit des automatischen Datenflusses in datenbasierten Systemen	TÜV, CuroCon

2.2.1. Arbeitspaket 2.1: Befähigung der Maschinen und IKT-Infrastruktur zum Datenaustausch

Im Rahmen des Arbeitspaketes wurden mehrere Maschinen bei verschiedenen Forschungspartnern zur Kommunikation und zum Datenaustausch befähigt. Im Folgenden werden die Anlagen kurz vorgestellt und dann die Anbindung im Detail beschrieben.

1) Kurze Beschreibung der ausgewählten Anlagen

Im Arbeitspaket wurden unterschiedliche Produktionsanlagen in der ETA-Fabrik, bei EJOT und bei Bosch Rexroth betrachtet. Die Hauptproduktionslinie der ETA-Fabrik zur Fertigung einer hydraulischen Steuerscheibe besteht aus zwei Werkzeugmaschinen, zwei Reinigungsmaschinen, einem Härteofen und der sie mit Strom, Kühlung, Heizleistung und Druckluft versorgenden Versorgungstechnik. Daneben gibt es eine zweite, kleinere Produktionslinie, zur Fertigung eines Getriebes, das für Workshops und im Rahmen studentischer Projekte genutzt wird. Für dieses Arbeitspaket wurde die Roboterzelle dieser zweiten Linie betrachtet. EJOT-seitig wird eine Kombimaschine aus Pressen und Walzen zur Schraubenherstellung im Werk Tambach-Dietharz betrachtet. Im Bosch Rexroth Werk in Schweinfurt werden Schleifmaschinen der Firma aba Grinding Technologies GmbH betrachtet. Der Standort Schweinfurt fertigt mit mehreren Maschinen gleicher Art Linearführungen - hier im speziellen werden die Führungsschienen geschliffen. Diese Schleifmaschinen können, die bis zu 4000 mm langen Führungsschienen bearbeiten und haben eine Anschlussleistung von 180 kVA. Bei der Bearbeitung pendeln die Werkstücke zwischen den auf zwei gegenüberliegenden Seiten bearbeitenden Schleifscheiben. Weitere Produktionsschritte wie Härten, Richten oder Bohren der Führungsschienen werden nicht betrachtet.

2) Befähigung der Maschinen zur Kommunikation

Die innerhalb der ETA-Fabrik betrachteten Maschinen besitzen alle Speicherprogrammierbare Steuerungen, die zur Kommunikation befähigt wurden. Hier wurde die Kommunikationsinfrastruktur OPC UA gewählt. In der ETA-Fabrik bestand bereits eine OPC UA Kommunikation. Diese war allerdings fehlerhaft und es kam immer wieder zu Kommunikationsabbrüchen. Zur Fehlerberhebung wurden Firmwareupdates der Steuerungen der Produktionsanlagen der Hauptproduktionslinie und der Roboterzelle der zweiten Linie durchgeführt und die Netzwerkstruktur angepasst.

Der Ansatz einer OPC UA Kommunikation wurde bei EJOT geprüft und aufgrund der benötigten Übertragungsgeschwindigkeit verworfen. Vielmehr wurde eine Kommunikationsarchitektur entworfen (siehe Abbildung 2.14), welche zwei Übertragungspfade (Hoch-/Niederfrequent) beinhaltet. Die Aufnahme derjenigen Sensordaten, welche hochfrequent abgetastet werden müssen, erfolgt über einen externen Messverstärker. Sensordaten, welche geringe Abtastraten (z. B. Temperatur) zulassen, werden über die Maschinen-SPS abgegriffen. Innerhalb eines im Rahmen des Projektes entwickeltem Schnittstellentools (EJOT Data Progressor) erfolgt die Aggregation der Maschinendaten zu spezifischen Datenpaketen einer produzierten Schraube. Diese werden im Anschluss zur weiteren Auswertung an die Managementplattform gesendet. Der EJOT Data Progressor beinhaltet zum Datenabruf eine REST-Schnittstelle zum Messverstärker sowie eine S7-Schnittstelle zur SPS. Die Datenbereitstellung erfolgt über REST an die Managementplattform.




Abbildung 2.14: Kommunikationsstruktur der EJOT-Maschine.

Zur Umsetzung der Kommunikationsarchitektur wurde, mit Hinblick auf weitere Teilprojekte, ein mobiler PC-Schaltschrank (Abbildung 2.15 (a)) angeschafft und mit benötigter Hardware ausgestattet (Abbildung 2.15 b)). Hierzu zählt unter anderem ein Edge PC sowie externe Messverstärker. Ebenso erfolgte die Erstellung einer Adapterplatte mit diversen Anschlüssen für Sensoren sowie Ethernet-Kabel (Abbildung 2.15 (c) & (d)). Dies ermöglicht ein „Plug-and-Play“ hinsichtlich der Maschinen-Sensorik an die Messverstärker.

Ebenfalls ist es das Ziel des Arbeitspakets die Beispielmaschinen für Bosch zum Datenaustausch mit einem Edge Device zu befähigen. Hierzu soll ein Konzept zur Datenerfassung in der Schleiftechnik aufgestellt und umgesetzt werden. Für die Arbeitspakete 5.1 und 5.2 müssen Steuerbarkeit und Beobachtbarkeit in Bezug auf Energie und Qualität hergestellt werden. Hierfür sind zwei unterschiedliche Systemgrenzen mit unterschiedlichen Zeitkonstanten sinnvoll. Für das Verbrauchs- bzw. Verhaltensmodell der Fabriksteuerung werden die Daten im Bereich der Bearbeitungszeit eines Werkstückes, also im Minutenbereich, benötigt. Ebenso bedarf es mehrerer Maschinen. Für die maschineninternen Wechselbeziehungen zwischen Werkstückqualität und benötigter Energie werden erheblich kleinere Zeitkonstanten benötigt. In dieser Beziehung sind die aus der Antriebsregelung stammenden Bewegungen relevant und somit ist ein Wert um 1 ms zielführend. Die Kommunikation zwischen CNC-Steuerung und Antriebsregler ist hier der geeignetste Ort, da alle Daten digital vorliegen und in entsprechendem Takt verfügbar sind. Auf der Ebene der Fabriksteuerung ist eine Kommunikation

mittels OPC UA ausreichend. Daher kann auf die vorhandene Infrastruktur zurückgegriffen werden. Im Werk Schweinfurt sind alle bisher benötigten Daten verfügbar. Eine Änderung führt nach bisherigem Stand zu keiner Verbesserung, daher wurden diesbezüglich keine weiteren Arbeiten durchgeführt. Für die maschinennahe Betrachtung sind die Daten in der geforderten Taktzeit von ~ 1 ms in keinem IKT-Netz vorhanden. Eine steuerungsinterne Aufzeichnung und Gateway-Funktion ist möglich, jedoch nicht rückwirkungsfrei auf die Leistungsfähigkeit der Steuerung. Eine durch zusätzliche Rechenlast verursachte Überschreitung von Interpolations- bzw. SPS-Takt führt zu einem unmittelbaren Maschinenstillstand. Aus diesem Grund wird in dem ausgewählten Ansatz der Antriebsbus passiv auf einer zusätzlichen Hardware mitgeschrieben. Die Daten auf dem Antriebsbus werden durch einen Test Access Point (TAP) mitgeschrieben. Diese Funktion übernimmt ein Einplatinenrechner (hier RASPBERRY PI 4). Eine schematische Darstellung ist in Abbildung 2.16 dargestellt. Dieser Aufbau wurde vorab getestet und steht nun für einen maschinennahen Test bereit.




Abbildung 2.15: Verwendete Hardware bei EJOT (a) PC-Schaltschrank, (b) Edge PC und Messverstärker, (c) & (d) Adapterplatte zum Anschluss von Sensorik und Netzwerkkommunikation.

Für die maschinennahe Betrachtung sind die Daten in der geforderten Taktzeit von ~ 1 ms in keinem IKT-Netz vorhanden. Eine steuerungsinterne Aufzeichnung und Gateway-Funktion ist möglich, jedoch nicht rückwirkungsfrei auf die Leistungsfähigkeit der Steuerung. Eine durch zusätzliche Rechenlast verursachte Überschreitung von Interpolations- bzw. SPS-Takt führt zu einem unmittelbaren Maschinenstillstand. Aus diesem Grund wird in dem ausgewählten Ansatz der Antriebsbus passiv auf einer zusätzlichen Hardware mitgeschrieben. Die Daten auf dem Antriebsbus werden durch einen Test

Access Point (TAP) mitgeschrieben. Diese Funktion übernimmt ein Einplatinenrechner (hier RASPBERRY PI 4). Eine schematische Darstellung ist in Abbildung 2.16 dargestellt. Dieser Aufbau wurde vorab getestet und steht nun für einen maschinennahen Test bereit. Ein wesentlicher Vorteil ist, dass neben den Energie- und Leistungsdaten auch weitere Daten wie die Achspositionen zeitsynchron aufgezeichnet werden können. So kann neben einem Zeitbezug auch ein Orts- und Zustandsbezug (Bearbeitungsbahn oder Werkzeugwechsel) hergestellt werden. Dies ermöglicht das Zuschneiden von Zeitreihen in sogenannte Prozesskurven (Anfang und Ende sind durch einen externen Bezug wie Positionen gegeben). Diese Prozesskurven können dann einer Bearbeitung und einem Abschnitt im NC-Programm zugeordnet werden. Mittels dieser Zuordnung können dann gezielt Optimierungen im NC-Programm durchgeführt werden.




Abbildung 2.16: Schematische Kommunikationsarchitektur bei Bosch.

3) Anbindung der Anlagen an die Managementplattform

In KI4ETA erfolgt nun die Anbindung an die IoT-Plattform Cumulocity, die neben der Datenspeicherung in einer Datenbank auch das Ausführen von Skripten ermöglicht, die für KI-Anwendungen genutzt werden. Außerdem ist hier auch eine Datenaufnahme mit einer höheren Frequenz möglich, die in mehreren Anwendungsfällen (siehe AP 2.2) gebraucht wird. OPC UA wird von Cumulocity nativ unterstützt und die Definition der Datenpunkte kann über das Laden von Konfigurationsdateien teilautomatisiert werden. Die Anbindung wurde schon mit mehreren OPC UA Servern getestet. Des Weiteren erfolgt die Anbindung einzelner Maschinen an die etaOne Plattform, um auch hier die Funktionalitäten wie Datenspeicherung und -auswertung sowie das Ausführen von Skripten zu testen. Neben der Anbindung der beiden Plattformen, wurde im Rahmen einer Masterarbeit der Einsatz des am PTW entwickelten Pythonframeworks eta_utility auf zwei Edge Devices getestet. Der Python-Code wurde in einen Docker-Container verpackt, der dann auf einem Raspberry Pi und einem Beckhoff Industrie PC installiert wurden. Dabei wurde zum Datenaustausch die Software Telegraf, zum Speichern der Daten die Datenbank InfluxDB und zum Visualisieren Chronograf benutzt. Mit Inference wird die Ausführung des Python-Frameworks zur Kommunikation und der Ausführung eines KI-Algorithmus zur Prognose der Wirkleistung einer Werkzeugmaschine bezeichnet. In der Masterarbeit konnte gezeigt werden, dass die Ausführung von KI-Algorithmen auf Edge Devices mit eingeschränkter Hardwareleistung möglich ist. Die Ausführung des Modells war mit einer Taktrate von etwa einer Sekunde möglich und für den Use Case gerade ausreichend, da jede Sekunde eine neue Prognose benötigt wurde. Da die Dauer der Ausführung schwankt und es somit möglich ist, dass die Ausführung über eine Sekunde benötigt, muss das System hier noch verbessert werden.

Neben den oben beschriebenen Use Cases wurde eine weitere Werkzeugmaschine des PTW an die IoT-Plattform Cumulocity angeschlossen. Es handelt sich hierbei um eine Hermle C32U dynamic, die im TEC-Lab steht, dem zweiten großen Versuchsfeld des PTW neben der ETA-Fabrik. Die Anbindung an dieselbe Cumulocity-Instanz, wie die der Anlagen der ETA-Fabrik, soll es perspektivisch ermöglichen, die Produktion der Hermle auf den Prozess in der ETA-Fabrik abzustimmen. Hierbei sollen günstige Strompreise ausgenutzt und für die Optimierung der Produktionsplanung berücksichtigt werden.

Wie aus der Kommunikationsarchitektur von EJOT zu entnehmen, wurde die Managementplattform Comulocity IIoT als Edge-Version direkt auf der Edge installiert. Somit ist in diesem Fall die Anbindung der Maschine an den Edge PC gleichbedeutend mit der Anbindung an die Managementplattform.

4) Aufbau einer OPC UA Kommunikationsstruktur

Im Rahmen des Arbeitspakets wurde am PTW ein OPC UA Datenmodell entwickelt, um Produktionsmaschinen und Maschinen der Versorgungstechnik mit energieflexiblen Algorithmen ansteuern zu können. Das Datenmodell wurde erfolgreich an einer versorgungstechnischen Anlage implementiert und wird im Rahmen von *ETA im Bestand* (FKZ: 03EN2048A-I) auf die weitere Versorgungstechnik der ETA-Fabrik übertragen. Das Datenmodell wurde außerdem im Rahmen von KI4ETA erweitert und für die Optimierung in Arbeitspaket 5.1 auf die Reinigungsmaschine MAFAC KEA übertragen. Das Datenmodell und seine Erweiterung werden in zwei wissenschaftlichen Veröffentlichungen publiziert. Die Datenstruktur soll ähnlich der OPC UA Companion Specifications eine einheitliche Grundlage für die Maschinenkommunikation für den energieflexiblen Betrieb von Produktionsmaschinen schaffen. Das entstandene Datenmodell kann dann eine Grundlage für weitere OPC UA Companion Specifications darstellen. Hierzu erfolgt ein Austausch mit den entsprechenden Arbeitsgruppen im VDMA.

Zur Anbindung des Leakage-Roboters an die Energiemanagement-Plattform wurde vom DFKI eine OPC-UA Schnittstelle entwickelt, über welche die Daten aus der Leakage-Detektion zur Verfügung gestellt werden können. Zuerst wurde ein Nodeset entwickelt und mit Etalytics abgesprochen. Da durch die Hardware-Problematik in AP 3.2 zunächst noch keine Real-Daten des Roboters zur Verfügung stehen, wurde begonnen eine Simulation für die Datenübertragung zu entwickeln. Damit kann die Anbindung des Roboters an die Plattform vollständig getestet werden. Dies stellt einen Abschluss des Meilensteins MS 2.1.5 dar, denn bei der Übertragung auf den realen Roboter im Zuge des Arbeitspaketes 3.2 bleibt die Schnittstelle zur Plattform gleich. Es muss lediglich die Informationsbereitstellung auf dem OPC-UA Server im Backend geändert werden, was durch die Pub-Sub Kommunikationsstruktur von ROS (Robot Operating System) unterstützt wird.

Der Datenaustausch auf Basis von Dateien wurde bei Bosch fokussiert. Eine Vernetzung mittels OPC UA liegt im Werk Schweinfurt schon vor und kann genutzt werden. Ohne den Ergebnissen des AP 2.4 vorzugreifen, wird ein schreibender Zugriff auf die Maschinensteuerung kritisch bewertet. Als alternativer Zugang zu der CNC-Steuerung ist der G-Code möglich. Zusätzlich zu den ursprünglichen G-Befehlen (siehe DIN 66025/ISO 6983 [85]) können Daten durch den NC-Kern (zentraler Ort der Interpolation von G-Befehlen zu Achssollpositionen) in eine Datei geschrieben bzw. ausgelesen werden. Ebenfalls ist eine Datenbankbindung für die Werkzeugverwaltung vorhanden. Es wurde ein NC-Programm erstellt, das im laufenden Automatik-Modus eine Änderung der nächsten Bewegung, z.B. des Geschwindigkeitsprofils, ermöglicht. Die bei einer Änderung üblichen Zwischenschritte „laden der Änderung in den NC-Kern“ und Aktivierung des Befehls „NC-Start“ sind hierfür nicht nötig. Ein Eingriff

in eine aktuell durchgeführte Bewegung ist nicht möglich. Mögliche Kollisionen im Dateisystem wie gleichzeitiges Lesen und Schreiben zweier unterschiedlicher Instanzen wurde hierbei beachtet.

5) Validierung der Anbindung

Die Anbindung der Maschinen-Sensorik an das Edge Device bei EJOT konnte auf mehrere Arten validiert werden. Zum einen bietet der Messverstärker einen Zugriff über den Browser. Hierdurch ist die Validierung der angeschlossenen Sensoren sehr schnell ersichtlich. Des Weiteren konnte durch Sichtung der gespeicherten Datenpakete die Anbindung bestätigt werden.

Die Datenerfassung und Integration in den bei Bosch Rexroth Steuerungen verwendeten Automatisierungsbus SERCOS wurde durch Testszenarien überprüft. Es wurden unterschiedliche Bewegungen von Antriebsachsen durch einen NC-Code erzeugt und die vorgegeben Zustände wie Strecken und Geschwindigkeit gemessen. Ebenfalls wurden Messungen mittels antriebsinterner Oszilloskope erfolgreich mit den aufgezeichneten Messdaten abgeglichen. Eine Störung des Automatisierungsbus SERCOS konnte nicht festgestellt werden. Die „bordeigenen“ Fehlerzähler wie Telegrammausfall waren nicht auffällig.

Im Rahmen von Versuchen konnten in der ETA-Fabrik der lesende Datenzugriff, also das Speichern von Sensor- und Maschinendaten in Cumulocity, etaOne und eta_utility validiert werden. Daneben wurde die Reinigungsmaschine MAFAC KEA im Rahmen von Versuchen in AP 5.1 über eta_utility auch direkt angesteuert. Somit wurde auch der steuernde Zugriff validiert.

6) Datenstruktur für Broadcast-Updates

Im Rahmen der Untersuchungen im Arbeitspaket hat sich herausgestellt, dass die Verwendung von Broadcast-Updates nicht zielführend ist, da sich die einzelnen Maschinen zu stark voneinander unterscheiden. Deswegen wurde diese Idee verworfen und nicht weiterverfolgt.

Partnerspezifische Übersicht der Arbeiten

PTW (Leitung):

- Befähigung der Produktionsmaschinen in der ETA-Fabrik und im TEC-Lab zur Kommunikation über OPC UA
- Anbindung der Maschinen an Cumulocity, etaOne und eta_utility
- Testen der Datenanbindung lesend und schreibend
- Entwicklung eines Datenmodells für den energieflexiblen Betrieb von Produktionsanlagen und industrieller Versorgungstechnik

Software AG:

- Testen der Anbindung von hochfrequenten Datenquellen an die Cumulocity Plattform
- Testen der Ausführung von Machine Learning Algorithmen auf die hochfrequent an Cumulocity gesendeten Daten
- Unterstützung von EJOT und dem PTW beim Erstellen der Cumulocity Anbindung

EJOT:

- Iterative Konzeptionierung und Entwicklung der Kommunikationsarchitektur bei EJOT
- Auslegung PC-Schaltschrank, Messverstärker, Edge Device

- Aufbau eines mobilen PC-Schaltschranks inklusive Verkabelung, Hardwareinstallation und Netzwerkanschluss
- Bestimmung vorhandener und zusätzlich benötigter Sensorik sowie Auslegung und Umsetzung Sensorspezifischer Messketten
- Beschaffung benötigter Hardwarekomponenten zur Umsetzung der Kommunikationsarchitektur
- Umsetzung der Kommunikationsarchitektur
- Steuerungsseitige Befähigung der Beispielmachine zum Datenaustausch
- Entwicklung EJOT Data Progressor
- Erprobung der Schnittstellen sowie Übertragungsverfahren Maschine-Edge Device
- Erste Datenaufnahme mittels Edge Device von Maschinendaten

Bosch:

- Übersicht und Bewertung der vorhandenen IKT-Infrastruktur, Handlungsfelder identifiziert, die im Projektrahmen geleistet werden müssen, der Schwerpunkt lag dabei auf maschineninternen Datenquellen
- Konzeption möglicher Validierungsmessungen für unterschiedliche Datenquellen für das gleiche physikalische Phänomen, wie z. B. Netzleistung und elektrische Motorleistung
- Unterstützung des PTW bei der Nutzung von maschineninternen Datenquellen aus Bosch Rexroth Steuerungen

DFKI:

- Entwicklung eines OPCUA Nodesets zur Anbindung und Datenübermittlung durch den Leckage-Roboter in Abstimmung mit Etalytics
- Aufbau einer containerisierten Demo zum praktischen Test der Datenübertragung über die Schnittstelle

2.2.2. Arbeitspaket 2.2: Befähigung von Edge Devices zur Vorverarbeitung hochfrequenter Energiedaten

Ziel dieses Arbeitspaketes war es, hochfrequente Energiedaten aus Werkzeugmaschinen mit Hilfe von Edge Devices aufzunehmen und dort vorzuverarbeiten. Dazu wurden zwei Anwendungsfälle betrachtet, einer beim Industriepartner EJOT und einer in der ETA-Fabrik.

Im Falle des EJOT Anwendungsfalls wurden die hochfrequenten Energiedaten zur Bauteilqualitätsüberwachung mittels Predictive Maintenance genutzt. Dazu war geplant, die Daten innerhalb des *EJOT Data Progressor* aus den unterschiedlichen Datenquellen (Messverstärker, SPS) zusammen zu tragen, zu aggregieren und mittels REST an die *Cumulocity IoT Edge* zu senden. Die Aggregation der Daten erfolgte so, dass das gesendete Datenpaket immer nur Daten der aktuell produzierten Schraube beinhaltet. Hierdurch werden die Daten sortiert weitergeleitet und die direkte Verarbeitung mittels Feature Extraktion und ML-Applikationen ermöglicht.

Die Implementierung von Testmodellen sowie Algorithmen zur Feature Extraction in den Streaming-Analytics-Bereich der *Cumulocity IoT Edge* wurde getestet. An dieser Stelle sind Probleme aufgetreten, welche nicht gelöst werden konnten. Aufgrund dessen, ergibt sich die folgende Umstrukturierung (siehe Abbildung 2.17): Mittels FASTAPI wurde eine REST-Schnittstelle entwickelt. Diese ermöglicht die Sendung der aggregierten Daten direkt an einen Endpunkt, welcher die entwickelten Programme zur

Feature Extraction und die Modelle anstößt. Im Anschluss werden die Ergebnisse des Modells dann an die Cumulocity übermittelt, welche diese dann mittels eines Dashboards darstellt. Diese Umstrukturierung wurde getestet und ist funktionsfähig.




Abbildung 2.17: Angepasste Struktur der Datenübermittlung und -Verarbeitung bei EJOT für hochfrequente Daten.

Im Anwendungsfall ETA-Fabrik wurde aufgrund der begrenzten Verfügbarkeit der bestellten TSN-fähigen Elektronik an einem Konzept gearbeitet, eine Übergangs-Messstrecke unter Zuhilfenahme von Leihkomponenten von B&R aufzubauen. Überlegungen eine TSN-Messstrecke mit Komponenten anderer Hersteller aufzubauen, wurde nach dem Besuch der Hannover Messe und Gesprächen mit anderen Herstellern verworfen.

Für den Aufbau des TSN-Demoschaltkastens in der ETA-Fabrik ist Ende 2022 die Firma Curocon beauftragt worden. Der Kasten enthält Komponenten von B&R (SPS, IPC, TSN-Switch, Netzteil) sowie von Rosch Rexroth (ctrlX). Der Aufbau des Schaltkastens kann Abbildung 2.18 entnommen werden.




Abbildung 2.18: Aufbau des TSN-Schaltkastens und Anbindung an den DC-Schaltschrank.

Die ctrlX gehört zur neuesten Generation an Steuerungen, die Bosch Rexroth vertreibt. Das Besondere an diesen Steuerungen ist der modulare Aufbau der Software mit Hilfe von Apps. Unter der Vielzahl an Apps existiert eine App für das Aufsetzen eines OPC UA Servers und die Service-Bridge-App. Letztere

bietet ähnliche Funktionalitäten wie das Bosch Rexroth IoT Gateway und kann damit als OPC UA Client eine Verbindung zu OPC UA Servern anderer Komponenten aufbauen.

Der ursprüngliche Projektplan sah vor, eine SPS von B&R mit einem IPC von B&R kommunizieren zu lassen. Dazu steht der echtzeitfähige Standard OPC UA FX (field exchange) zur Verfügung. Da es allerdings massive Lieferschwierigkeiten bei dem IPC gab, wurde stattdessen die Steuerung von Bosch Rexroth eingesetzt, um die Interoperabilität zu prüfen. Diese Steuerung unterstützt allerdings noch kein OPC UA FX, sondern nur OPC UA PubSub, was eine hochfrequente, wenn auch nicht echtzeitfähige Verbindung via OPC UA ermöglicht. Diese Funktion steht bis heute allerdings auch lediglich als Pre-Release zur Verfügung.

Um zwei Geräte via OPC UA PubSub kommunizieren lassen zu können, müssen sie mit dem UA Expert verbunden werden, wobei es sich um eine Freeware Software von Unified Automation handelt. Wie in Abbildung 2.19 zu sehen, muss dann eine Konfigurationsdatei, die in der B&R Entwicklungsumgebung erzeugt werden kann, auf die ctrlX übertragen werden. Mit dieser Datei werden die B&R SPS als Publisher (Sender) und die ctrlX als Subscriber (Empfänger) konfiguriert. Dieser Schritt ist nötig, damit sich die Komponenten im Netzwerk finden können.




Abbildung 2.19: Ablauf zum Aufbau einer OOPC UA PubSub-Verbindung.

Leider ist eine erfolgreiche Kommunikation der beiden Geräte auch mit Hilfe der Steuerungshersteller nicht möglich gewesen. Zwar kann die SPS von B&R Daten ins Netzwerk senden. Allerdings ist es aufgrund des Beta Status der Bosch-Rexroth Software nicht möglich gewesen, die ctrlX diese Daten auch empfangen zu lassen. Eine Interoperabilität konnte daher nicht gezeigt werden und verdeutlicht die Neuheit und den damit einhergehenden Entwicklungsbedarf dieser Technologie.

Nach weiteren Versuchen, die hochfrequente Echtzeitverbindung zwischen dem IPC und der SPS von B&R im Versuchsfeld des PTW aufzubauen, wurden weitere Gespräche mit den entsprechenden Experten geführt. Der aktuelle Softwarestand lässt eine Verbindung nicht zu.

Die im Projekt entwickelte hardwareseitige Datenaufnahme und Vorverarbeitung ist funktionsfähig (Leistungsdaten können mit 500 Hz aufgenommen und für den Versand komprimiert werden), und kann

nach dem Release der entsprechenden Software, ggf. In Kombination mit anderer Hardware, um die Komponente der OPC UA Verbindung erweitert werden.

Das Arbeitspaket gilt damit als unvollständig abgeschlossen, wobei die echtzeitfähige OPC UA Verbindung in Folgeprojekten angegangen werden muss.

Zusammenfassung der Arbeiten je Partner

Software AG (Leitung):

- Untersuchung der günstigsten Kommunikationsmethoden zwischen Edge Devices und der Cumulocity Plattform
- Für hoch-frequente Daten beim EJOT Use Case wird die Anbindung über das REST API von Cumulocity empfohlen
- Unterstützung von EJOT bei der Installation, Konfiguration und Benutzung der vor-Ort installierten Cumulocity IoT Plattform

EJOT:

- Bestimmung aller notwendigen Schnittstellen zwischen Edge und Cumulocity
- Bestimmung der Datenaggregationsverfahren für die Schnittstelle EJOT Data Progressor - Cumulocity Edge
- Auswahl der Schnittstelle zur Cumulocity Edge, Herstellung der Datenübertragung
- Umstrukturierung des Datenflusses und dessen Erprobung
- Entwicklung REST-API mittels FASTAPI

PTW:

- Vorbereiten des SPS-Programms zur Aufnahme der Leistungsdaten aus dem DC-Schaltschrank, Testen des Programms und Erstellen eines Dashboards, um Daten einfach visualisieren und speichern zu können
- Tests zur Kommunikation zwischen B&R-SPS und ctrlX via OPC UA PubSub
- Erweiterung des Konzepts des TSN-Schaltkastens um ctrlX von Bosch Rexroth und dessen Beschaffung
- Expertengespräche mit Bosch Rexroth und B&R wurden geführt, was den aktuellen Stand der OPC UA PubSub App bzw. die OPC UA FX Verbindung angeht mit dem Ergebnis, dass die bisherige Hardware mit dem aktuellem Softwarestand entgegen den ursprünglichen Erwartungen nicht für den entsprechenden Use-Case geeignet ist.

2.2.3. Arbeitspaket 2.3: IT-Security in hoch vernetzten Betrieben

Das Arbeitspaket befasste sich mit der Integration von IT-Sicherheit in die Entwicklung von KI-Systemen zur Energieeinsparung in der Produktionstechnik. Da der Datenaustausch und die Speicherung sensibler Sensordaten innerhalb der IT-Infrastruktur anfällig für Cyber-Angriffe sind, wurde eine systematische Sicherheitsanalyse angewendet.

Es wurde eine Systemübersicht über das in diesem Arbeitspakete betrachteten Teilsystem der ETA-Fabrik erstellt, dargestellt in Abbildung 2.20. Das System besteht aus drei Teilen, dem Klimaraum Subsystem in der Produktionshalle, dem Büro mit den Arbeitsplätzen der Mitarbeitenden, sowie dem Server-Raum

in welchem die etaONE Energiemanagementplattform innerhalb einer virtuellen Maschine (VM) auf einem der Server ausgeführt wird.

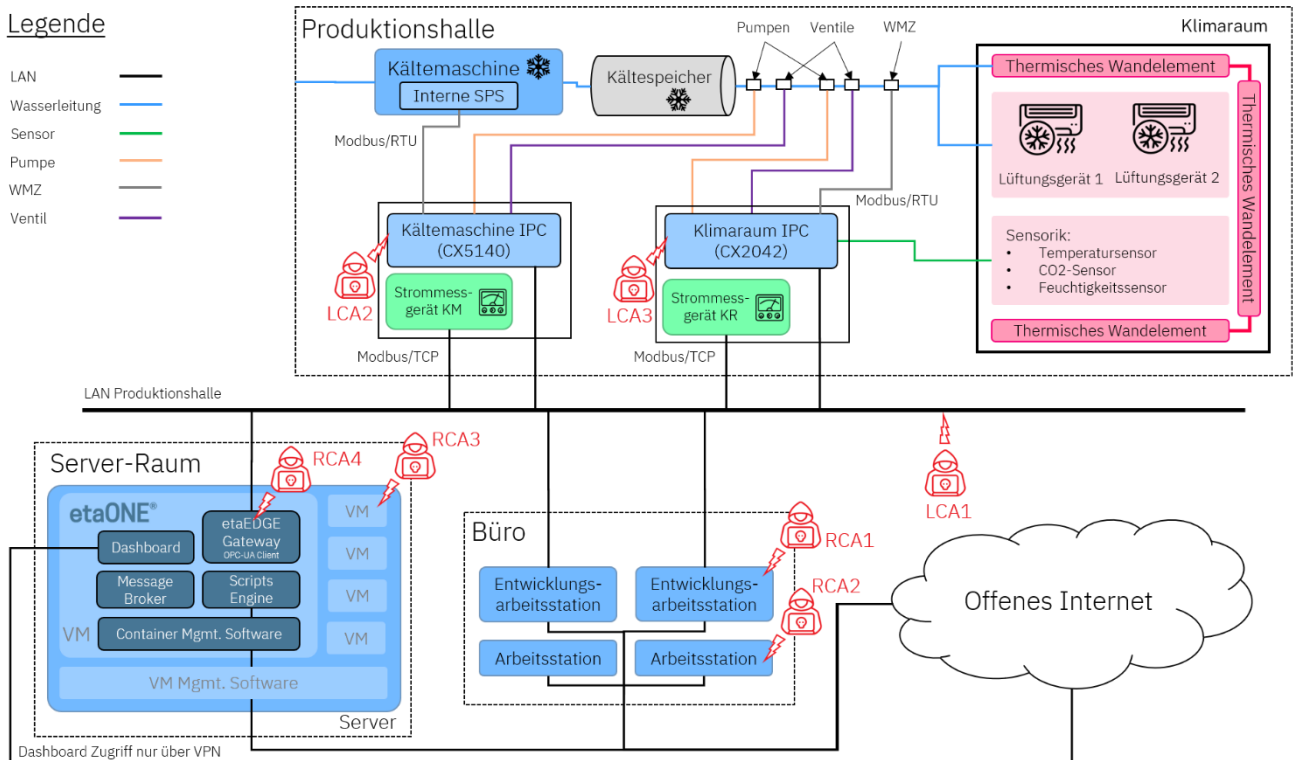


Abbildung 2.20: Übersicht des bei der Cybersicherheitsanalyse betrachteten Systems.

Nach der Aufstellung der Systemübersicht wurde ein Angreifermodell für die im Anschluss durchgeführte Cybersicherheitsanalyse ausgearbeitet, beginnend mit der Definition der Ziele des Cyberangreifers und den Fähigkeiten des Cyberangreifers. Insbesondere wurden die vom Angreifer ausführbaren Angriffe kategorisiert, je nachdem, ob die Angriffe lokal innerhalb der Produktionsumgebung ausgeführt werden (lokaler Cyberangriff) oder remote nur über digitale Schnittstellen der Zielgeräte (remote Cyberangriff). Die sich ergebenden Angriffsvektoren für die Subsysteme sind in Abbildung 2.20 rot markiert. Zum Abschluss der Ausarbeitung wurde definiert, welchen Einschränkung der Cyberangreifer unterliegt und welche Angriffe daher bei der Cybersicherheitsanalyse nicht betrachten werden.

Im Anschluss wurde eine detaillierte Sicherheitsanalyse der Subsysteme Produktionshalle, Büro und Server-Raum durchgeführt. Dabei wurden für jedes Subsystem zuerst Angriffsvektoren ermittelt und dann analysiert, mit welchen Techniken es Cyberangreifern gelingen kann, die entsprechenden Systeme zu attackieren, dabei erfolgte auch eine Abbildung der Angriffsvektoren auf die zuvor im Angreifermodell definierten Cyberangriffe.

Im letzten Schritt dieses Arbeitspakets wurden konkrete Sicherheitsmaßnahmen für die genannten Subsystem ermittelt, um diese gegen die aufgezeigten Cyberangriffe zu schützen. Die Empfehlungen erstrecken sich dabei von der sicheren Konfiguration von Automatisierungsprodukten, durch die Verwendung von bereits auf diesen vorhandene Sicherheitsfunktionalitäten, über die Umsetzung eines konsequenten Geräte- und Update-Management, bis hin zur Verwendung von speziellen Sicherheitsarchitekturen. Zum Abschluss wurden die Handlungsempfehlungen für das Serverraum

Subsystem auch für das konkrete Beispiel der etaONE Plattform ausgearbeitet und zwischen den beteiligten Projektpartnern abgestimmt.

Basierend auf den Ergebnissen der Sicherheitsanalyse und der Risikoanalyse mit Fokus auf den Anwendungsfall der Betriebsoptimierung wurden durch etalytics die Sicherheitsmaßnahmen für Entwicklung und Betrieb der Energiemanagementplattform geprüft und erweitert. Im Entwicklungsprozess werden hierbei unter anderem Tools zum Erkennen von Konfigurationsproblemen in Kubernetes eingesetzt, wodurch Best Practices zur Vermeidung von Sicherheitslücken automatisiert angewandt werden können.

Ebenso wird automatisiert vermieden, dass versehentlich Passwörter oder andere geheime Informationen mit unbefugten Personen geteilt werden. Des Weiteren werden Scanner benutzt, welche die verwendeten Softwarekomponenten und -bibliotheken auf bekannte Sicherheitsprobleme prüfen. Somit kann auch auf Sicherheitslücken in der Software-Lieferkette umgehend reagiert werden.

Zusammenfassung der Arbeiten je Partner

PTW (Leitung):

- Anleitung und Abstimmung der Arbeiten von SANCTUARY Systems
- Bereitstellung von Informationen zur Systemarchitektur in der ETA-Fabrik

SANCTUARY Systems:

- Erstellung einer Übersicht des betrachteten Systems
- Abstimmung und Ausarbeitung Angreifermodell
- Sicherheitsanalyse der Subsysteme Produktionshalle, Büro und Server-Raum
- Entwicklung Handlungsempfehlungen für die Subsysteme Produktionshalle, Büro und Server-Raum

etalytics:

- Unterstützung der Sicherheitsanalyse durch Bereitstellung relevanter System- und Prozessdaten zu Datenflüssen, Authentifizierung und Zugriffskontrollen in der Energiemanagementplattform.
- Durchführung einer Risikoanalyse für den Betriebsoptimierungs-Use Case, mit Fokus auf potenzielle Angriffspunkte wie Datenmanipulation, unbefugten Zugriff und Sicherheitslücken in Kommunikationsprotokollen.
- Ableitung und Umsetzung von zusätzlichen Abwehrmaßnahmen, darunter verbesserte Zugriffskontrollen, Überwachung der Systemintegrität und Härtung der Softwareumgebung durch Sicherheits-Scans und Update-Management.

2.2.4. Arbeitspaket 2.4: Zuverlässigkeit von selbstlernenden Systemen im industriellen Kontext

Die Sicherheit von KI-Systemen ist ein zentrales Thema für Vertrauen in KI-basierte Systeme. AP 2.4 beschäftigte sich daher mit der sicherheitstechnischen Bewertung von Anwendungen mit integrierten KI-Komponenten. Das Arbeitspaket verfolgt dabei einen zweistufigen Ansatz:

1. Da bestehende rechtliche Anforderungen meist auf deterministischen Regeln basieren, sollte zunächst das Risikopotenzial von KI-Anwendungen analysiert werden. Daraus werden

-
- Sicherheitsanforderungen und ein Risikobewertungssystem abgeleitet. Zudem wurde untersucht, ob aktuelle und künftige rechtliche Vorgaben erfüllt sind und welche Regelungslücken bestehen.
2. Viele KI-Modelle sind nicht intuitiv nachvollziehbar. XAI-Ansätze sollen ihre Entscheidungsprozesse transparenter machen. Es wurde daher untersucht, welche Verfahren sich für sicherheitskritische Anwendungen eignen.

Zur Auswahl und Implementierung eines Bewertungskonzepts zur Sicherheit von KI-Anwendungen (AP 2.4.1) wird zunächst die gesetzliche Regelung der Sicherheit in Deutschland und der EU betrachtet. Dies ermöglicht zugleich die praktische Umsetzung rechtlicher Anforderungen für KI-gestützte Fabrikoptimierung. Industrielle Sicherheitsanforderungen sind in der EU und Deutschland detailliert geregelt, z. B. für Maschinen durch Gesetze, Verordnungen und Normen. Klassische Bewertungsprinzipien sind meist deterministisch und daher für KI-Anwendungen schwer anwendbar, da diese sich stetig weiterentwickeln und ihre Entscheidungen nicht immer nachvollziehbar sind. Entsprechende KI-spezifische Regelwerke befinden sich noch in Arbeit. Mit dem AI-Act hat die EU die weltweit erste verbindliche KI-Regulierung geschaffen. KI-Systeme werden in vier Risikostufen unterteilt: Verbotene Anwendungen, Hochrisiko-KI, spezifisches Risiko und minimales Risiko. Die Vorschriften treten schrittweise in Kraft, mit Übergangsfristen bis 2027. Neben dem AI-Act gelten weiterhin bestehende Regelungen wie die EU-Maschinenverordnung und das Produktsicherheitsgesetz, je nach Gefährdungspotenzial des Produkts.

Da klassische Sicherheitsnachweise für KI-Systeme oft unzureichend sind, könnten probabilistische Verfahren helfen – etwa über Fehlerquoten. Jedoch erschwert die sich kontinuierlich ändernde Natur von KI eine verlässliche Bewertung, da heutige Fehlerquoten morgen bereits anders sein können. Bestehende Vorschriften zu Softwareupdates greifen hier nur bedingt, da sie nach jeder Änderung eine erneute Prüfung verlangen. Eine alternative Absicherung besteht darin, Maschinen mit zusätzlichen, nicht von KI beeinflussten Sicherheitsmaßnahmen auszustatten. Dazu gehören etwa reduzierte Geschwindigkeiten oder sicherheitsgerichtete Sensoren zur Personenerkennung.

Im Forschungsprojekt wird untersucht, wie sich die Nachrüstung bestehender Maschinen mit KI auf deren Sicherheit auswirkt. Besonders tiefgreifende Eingriffe – etwa eine KI-gesteuerte Drehzahlregelung – können neue Gefahren schaffen, z. B. unkontrollierte Bewegungen bei einem Werkzeugwechsel. Greift die KI jedoch nur auf einer Ebene ein, auf der der Bediener zuvor bereits manuell agieren konnte (z. B. durch Einschalten eines Antriebsmotors), entsteht grundsätzlich keine neue Gefährdung, da die Maschine entsprechend sicher konstruiert sein muss. [86].

Anhand der EMAG VLC 100 Fräsmaschine der ETA-Fabrik wurde geprüft, ob die KI-Steuerung zusätzliche Risiken verursacht. Da alle Steuerungsfunktionen der KI auch über das Bedienfeld ausgeführt werden können und die KI lediglich den Zeitpunkt der Ausführung bestimmt, liegt keine wesentliche Veränderung im Sinne der Maschinenrichtlinie vor (Details siehe AP 2.5). Die bestehende Sicherheitsarchitektur bleibt unverändert. Anders verhält es sich beim kollaborierenden Roboter (UR5e), der den Bediener der Fräsmaschine beim Werkzeugwechsel unterstützt. Da die KI hier Bewegungen des Roboterarms steuert, besteht potenziell eine Gefährdung durch Kollisionen oder den Transport von Werkzeugen im Greifer [87].

Der Roboterarm wurde mit einem Kamerasystem (mehrere Kameras) und einem adaptiven Greifer zum Greifen von Objekten ausgerüstet. Darüber hinaus wurde ein KI-System implementiert, welches Personen in der Nähe des Roboterarms erkennt. Dies beinhaltet auch die Erkennung, Lage und Bewegung der Extremitäten der Personen, wie abgebildet in Abbildung 2.21.




Abbildung 2.21: Personenerkennung im Bereich des Roboterarms

Die Steuerung des Roboterarms ist so umgesetzt, dass er bei Annäherung einer Person verlangsamt und stoppt, um Kollisionen zu vermeiden [87]. Das Hauptrisiko besteht in mechanischen Verletzungen durch eine Kollision mit dem Greifer und dem gehaltenen Objekt. Wesentliche Einflussfaktoren sind:

- **Bewegungsparameter des Arms:** Der Roboter trägt max. 5 kg und bewegt sich moderat.
- **Objekteigenschaften:** Harte, scharfkantige Werkzeuge (z. B. Bohrer) bergen ein höheres Verletzungsrisiko als weiche, runde Objekte.
- **Aufprallstelle:** Eine Kollision am Unterarm ist weniger kritisch als im Augenbereich, wo bereits geringe Kräfte schwere Schäden verursachen können.
- **Persönliche Schutzausrüstung (PSA):** Schutzbrillen, Handschuhe oder Helme können Verletzungen mindern.

Die bisherigen Ergebnisse zeigen, dass bei unkritischen Objekten ein sicherer Betrieb möglich ist, da die Kollisionsfolgen gering bleiben. Eine präzise Sicherheitsbewertung erfordert jedoch detaillierte Szenarioanalysen. Für scharfe/spitze Objekte bleibt trotz PSA ein hohes Verletzungsrisiko bestehen. Eine sichere Anwendung erfordert daher strikte Maßnahmen zur Kollisionsvermeidung. Eine funktionale Sicherheitsbewertung gemäß IEC 61508 führt in diesem Fall zu einer hohen Einstufung (mindestens SIL 1), da irreversible Verletzungen bei einer Kollision möglich sind. Je nach Eintrittswahrscheinlichkeit einer Kollision mit einem scharfkantigen Werkzeug erfordert IEC 61508 eine Einstufung in SIL 1 bis SIL 3, mit Fehlerquoten von maximal 1-mal in 1 Mio. Jahren (SIL 2) bzw. 1-mal in 10 Mio. Jahren (SIL 3). Die Kollisionserkennung hängt wesentlich von der KI-gestützten Personenerkennung ab. Eine zuverlässige Fehlerquotenbestimmung für ein individuelles KI-System ist jedoch mit hohem Aufwand verbunden und möglicherweise nicht nachweisbar. Daher müssen konservative Annahmen getroffen werden, was eine rechtskonforme Nutzung des Roboters für den Werkzeugwechsel (mit spitzem/scharfem Werkzeug) ausschließt [88]. Der fehlende Nachweis einer ausreichenden Sicherheit ergibt sich aus dem Fehlen geeigneter normativer Vorgaben für KI-Systeme. Für weniger kritische Anwendungen (z. B. weiche, nicht scharfkantige Objekte) ist hingegen ein sicherer Betrieb möglich, da auch bei hoher KI-Fehlerquote das Verletzungsrisiko gering bleibt.

Insgesamt zeigt sich, dass derzeit kein technisches Regelwerk existiert, um KI-gestützte Steuerungen für sicherheitskritische Maschinen systematisch zu bewerten. In der Praxis wird dieses Problem oft umgangen, indem klassische Sicherheitslösungen ohne KI-Einfluss genutzt werden.

Im Rahmen dieses Forschungsprojekts zur energetischen Optimierung einer Fabrik mittels KI soll ein System in eine bestehende Produktionsumgebung integriert werden. Dies umfasst:

- Erfassung vorhandener Daten durch Schnittstellen
- Installation zusätzlicher Sensoren
- Implementierung einer KI-gestützten Optimierung der Energieflüsse
- Einrichtung einer neuen Steuerung für Fabrikkomponenten

Da diese Maßnahmen bestehende Maschinen betreffen, ist zu prüfen, ob eine wesentliche Veränderung gemäß Maschinenrichtlinie bzw. EU-Maschinenverordnung vorliegt. Falls ja, wäre eine aufwendige Konformitätsbewertung erforderlich, deren wirtschaftlicher Nutzen von Einsparpotenzial, Maschinenlebensdauer und Neubewertungsaufwand abhängt. Für viele Maschinen, darunter der betrachtete kollaborative Roboter und die Fräsmaschine, erscheint dies betriebswirtschaftlich nicht sinnvoll. Ob eine wesentliche Veränderung vorliegt, hängt maßgeblich von Eingriffen in bestehende Steuerungen ab. Veränderungen auf vom Hersteller vorgesehenen Steuerungsebenen sind unkritischer als Eingriffe in tiefere Maschinensteuerungen, die Sicherheitsrisiken bergen.

Zur rechtssicheren Umsetzung von KI-Anwendungen in technischen Produkten besteht weiterhin Klärungsbedarf. Dies führte zur Veröffentlichung der „Deutschen Normungsroadmap Künstliche Intelligenz“ (2. Ausgabe, Dezember 2022, DIN e.V. und DKE). Sie beschreibt 116 Normungs- und Standardisierungsbedarfe in neun Schwerpunktthemen, darunter Sicherheit, industrielle Automation und Energie. Die Normungsroadmap Künstliche Intelligenz betrachtet sowohl horizontale als auch vertikale Ansätze zur KI-Sicherheit. Eine zentrale Herausforderung ist der Nachweis der Sicherheit von KI-Systemen. Die Roadmap beschreibt Wege zur Ausschöpfung des Marktpotenzials und zur Risikoreduktion, wobei insbesondere die funktionale Sicherheit thematisiert wird [86]. Damit ist die Korrektheit von KI-Systemen ist Gegenstand aktueller Forschung [87].

Weiterhin wird in der Normungsroadmap festgestellt, dass mit dem Einsatz von KI in technischen Systemen, die bisher von Menschen gesteuert wurden, neue grundsätzliche Herausforderungen bestehen.

„Autonome Systeme in komplexen Umgebungen

Bei steigendem Grad an Automatisierung, komplexen Aufgabenstellungen und unstrukturierten Umgebungen wird es schwieriger, eine Spezifikation zu erstellen, die ausreichend vollständig ist, widerspruchsfrei und ein Verhalten beschreibt, das akzeptabel ist. Während weniger sicherheitskritische KI-Anwendungen geringere Anforderungen erfüllen müssen, ist für sicherheitsrelevante Systeme oft unklar, ob der Stand der Technik genügt. Der Einsatz von KI in bisher menschlich gesteuerten Systemen führt zu neuen Herausforderungen. Beispielsweise ist zu klären, wie akzeptables Betriebsverhalten definiert wird – etwa, ob eine KI-Steuerung mindestens so sicher sein muss wie ein Mensch [87]. Zudem fehlen belastbare Nachweisverfahren zur Bewertung der KI-Zuverlässigkeit.

Dies bedeutet auch, dass zunächst die grundsätzlichen Anforderungen an ein akzeptables Betriebsverhalten definiert werden müssen, bevor entsprechendes Regelwerk definiert werden kann. Es geht um Fragen wie z.B.: ist es ausreichend, wenn eine KI-basierte Steuerung mindestens genauso sicher

ist, wie eine Steuerung durch einen Menschen. Eine zusätzliche Herausforderung besteht dann auch darin, zu definieren, wie genau z.B. die Fehlerquote eines Menschen bzw. der KI-Steuerung zu definieren bzw. nachzuweisen ist. In der funktionalen Sicherheit (z. B. SIL nach DIN EN 61508-1 oder PL nach DIN EN ISO 13849-1) gibt es quantifizierbare und nicht quantifizierbare Schutzmaßnahmen. Für KI-Software besteht jedoch weiterhin Diskussionsbedarf, da bestehende Methoden zur Risikobewertung oft nicht ausreichen. Besondere Herausforderungen bestehen in der mangelnden Interpretierbarkeit und im fehlenden Systemverständnis vieler KI-Modelle. So fehlen zuverlässige Verfahren, um sicherzustellen, dass ein KI-System beispielsweise Fußgänger in jeder Situation erkennt. Trotz laufender Forschung zur Unsicherheitsabschätzung und Erklärbarkeit sind die Nachweise derzeit nicht ausreichend für hochautomatisierte Anwendungen.

Qualitative Risikoreduktion durch KI (Assurance Cases)

Für herkömmliche sicherheitskritische Software existieren etablierte Safety-Level (z. B. SIL, ASIL, PL), die anhand von Risikographen festgelegt werden. Diese basieren auf umfassender Erfahrung, die für KI in sicherheitskritischen Anwendungen jedoch noch fehlt. Daher ist das Konzept der Integritätslevel derzeit nicht sinnvoll auf KI übertragbar. Alternativ können Maßnahmenkataloge zur Auswahl geeigneter Absicherungsmaßnahmen dienen, wobei deren Eignung für spezifische Anwendungsfälle geprüft werden muss. Assurance Cases bieten hierfür einen strukturierten Ansatz: Sie ermöglichen eine nachvollziehbare Argumentation zur Sicherheit von Systemen und sind bereits in anderen Technologiebereichen etabliert. Ihre Nutzung bei KI kann helfen, unzureichend abgesicherte Systeme zu vermeiden und Erfahrungen systematisch zu sammeln. Allerdings bestehen derzeit erhebliche Herausforderungen bei der Evidenzgenerierung für KI-basierte Assurance Cases. Zukünftige Forschung sollte sich auf die Strukturierung, Prüfung und intersubjektive Bewertbarkeit solcher Ansätze konzentrieren, um deren Eignung für die Safety-Normung zu verbessern [87].

Bedarf aus der Normungsroadmap

Die Normungsroadmap betont den hohen Forschungs- und Entwicklungsbedarf für sicherheitskritische KI-Anwendungen, insbesondere in High-Risk-Applikationen gemäß der EU-KI-Regulierung. Eine Safety-Argumentation für KI könnte daher auch für weitere Anwendungsbereiche relevant werden [87].

Vier zentrale Normungsbedarfe werden identifiziert:

- Definitionen und regulative Kriterien,
- Evaluierung von Safety-Konzepten und Standards,
- Förderung von Safety Assurance Cases,
- Safety bei autonomen Systemen.

Letzteres betrifft insbesondere algorithmische Entscheidungen zu Risiken und Unsicherheiten, während ethische Fragen nicht normierbar sind [89].

Sechs Handlungsempfehlungen werden gegeben:

- Entwicklung eines Konformitätsbewertungs- und Zertifizierungsprogramms,
- Aufbau von Dateninfrastrukturen und Qualitätsstandards,
- Berücksichtigung des Menschen im gesamten KI-Lebenszyklus,
- Vorgaben zur Konformitätsbewertung lernender Systeme (z. B. in der Medizin),
- Entwicklung sicherer KI-Anwendungen in der Mobilität,
- Übergreifende Datenstandards und dynamische Modellierungsverfahren. [88]

Fazit zur aktuellen Regelwerkssituation

Die Normungsroadmap zeigt, dass Ende 2022 erheblicher Bedarf zur Bewertung von KI-Systemen bestand. In Deutschland und der EU arbeiten Normungsgremien an entsprechenden Regelwerken, jedoch verzögert sich die Fertigstellung bis Mitte 2026 – knapp vor Inkrafttreten des AI-Acts. Die Verzögerung resultiert aus der Komplexität der Thematik sowie fehlenden geeigneten Regelungen für KI. Trotz unzureichender Standards sind bereits KI-gesteuerte Produkte mit hohem Gefährdungspotenzial auf dem Markt, darunter hochautomatisierte Fahrzeuge, autonome Gabelstapler und Drohnen. Die Sicherheitsbewertung erfolgt meist über aufwendige Tests oder klassische Sicherheitsmechanismen ohne KI-Einfluss. Um KI-Systeme regulatorisch abzusichern, entstehen neue Zertifizierungsansätze, etwa durch das AI-Lab des TÜVs. Wesentliche Aspekte sind die Qualität der Trainingsdaten, die Nachvollziehbarkeit der Programmierung und die Dokumentation des Entwicklungsprozesses. Besonders für ethisch sensible Anwendungen ist eine Zertifizierung zentral. Zudem wird an Methoden zur Nachvollziehbarkeit von KI-Entscheidungen (XAI) gearbeitet. Die Kombination mit deterministischen Algorithmen könnte neue Ansätze zur funktionalen Sicherheit von KI-Systemen ermöglichen.

Zusammenfassung der Arbeiten je Partner

DFKI (Leitung):

- Unterstützung bei der Auswahl eines geeigneten Anwendungsfalles für KI-basierte Safety-Evaluationen mittels XAI.
- Aufbau eines Demonstrators zur kollaborativen Werkzeugübergabe eines autonomen Roboterarms und einem Menschen.
- Entwicklung eines KI-basierten Algorithmus zur Generierung von Griffpositionen für unterschiedliche Werkzeuge als integralen Bestandteils des Werkzeugwechsels.
- Entwicklung eines Konzept-Layers für die Architektur eines neuronalen Netzwerkes zur Nachvollziehbarkeits-Analyse mittels Konzept-Understanding.
- Erprobung des Anwendungsfalles und Beratung bei der Einschätzung von XAI-Ansätzen zur Bewertung der Personensicherheit im untersuchten Anwendungsfall.

TÜV:

- Analyse der Fräsmaschine in der ETA auf einen sicherheitsgefährdenden Eingriff durch die Nutzung von KI in der Maschinensteuerung.
- Auswahl des angepassten Anwendungsfall in Zusammenarbeit mit dem DFKI.
- Analyse der aktuellen Regelwerkssituation bei der Beurteilung der Personengefährdung autonomer Maschinen mit KI-integrierter Steuerung und Beurteilung der existierenden Standards zum Zutreffen auf den vorliegenden Anwendungsfall.
- Sicherheitstechnische Beurteilung des Anwendungsfalles einer kollaborativen Werkzeugübergabe.
- Einbringen der Erkenntnisse aus dem untersuchten Anwendungsfall in aktuelle Normierungsdebatten.
- Erarbeitung einer Einschätzung der weitergehenden Entwicklung der Normierungsbemühungen und eines Ausblicks auf dessen Effekte auf die Zulassung und den Betrieb von KI-integrierten Anwendungen.

- Einordnung von XAI-Ansätzen in den Kontext der Normierungsbemühungen um Sicherheitsbewertung von KI-gesteuerten Maschinen und Anlagen

Bosch:

- Teilnahme bei Vorbereitungen und Vorauswahl von Anwendungsszenarien
- Aufbereitung und zu Verfügungstellung von Unterlagen für Werkzeugmaschinen
- Unterstützung bei der Einordnung in das Umfeld der Fertigung

2.2.5. Arbeitspaket 2.5: Fehler- und Ausfallsicherheit des automatischen Datenflusses in datenbasierten Systemen

Arbeitspaket 2.5 betrachtet die funktionale Sicherheit der KI-basierten Automatisierung. Da das Projekt KI4ETA nicht ein zusammenhängender Prozess ist, den man in seiner Gesamtheit betrachtet, wurde das Beispiel einer Fräsmaschine vom Typ VLC 100GT der ETA-Fabrik gewählt. Im ersten Schritt wurde eine Gefährdungsbeurteilung für die Maschine durchgeführt, die im Folgenden vereinfacht wiedergegeben wird:

Bewertungskriterien

Nr.	Dokumentname	Stand	Autor
1	ISO 13849, DIN EN 62061, DIN EN 61508		

Übergebene Dokumente

Nr.	Dokumentname	Version	Datum	Autor
1	MES_Anbindung der EMAG Maschinen 01.02.2018			
2	EMAG-Maschinen_Energie-Modi_v5.xlsx			
3	Rexroth_Energy Efficiency Management_R911339228_05.pdf			
4	Energiebausteine EMAG Maschinen Definition MES Schnittstelle.pptx			

Technische Beschreibung

Im Rahmen des Projektes KI4ETA wird eine energetische Optimierung der Maschinenlaufzeiten in der ETA-Fabrik mit Hilfe von künstlicher Intelligenz angestrebt. TU Darmstadt erstellt hierfür eine umfangreiche KI-Plattform, welche langfristig in der Industrie Anwendung finden soll. Um die Interaktion zwischen der vorhandenen Technik und der neu entwickelten MES-Ebene zu analysieren, werden hier exemplarisch die EMAG Maschinen vom Typ VLC100 GT und VLC 100 näher betrachtet. Die Maschinen verfügen über eine Steuerung des Herstellers Bosch Rexroth AG. Steuerung und Anwendersoftware wurden CE Konform realisiert.

Steuerungskonzept

Die Sicherheit der Maschine wird mit Hilfe einer fehlersicheren Steuerung implementiert. Entsprechende Sensoren und Frequenzumrichter mit sicherer Trennung sorgen durchgängig für eine sichere Signalverarbeitung. Die technologieabhängigen Betriebsprogramme werden von einer Standard-SPS ausgeführt. Eine übergeordnete Teilautomatik steuert den Zustand der Maschinen. Diese als

Zustandsautomat realisierte Teilsteuerung empfängt Befehle von dem Bedienpanel und schaltet zwischen den Betriebsarten: Bereit, Betrieb, Stillstand und Standby um. Da es sich hier um einen technologieneutralen Zustandsautomat handelt ist dieses Bedienkonzept auf jede beliebige Maschine übertragbar. An dieser Stelle setzt der Eingriff der KI-Anwendung an. Mit Hilfe der RIL_4EEEnergyManagement.library des Herstellers werden sogenannte Energiebausteine verwendet um KI-gesteuert den Zustand der Maschine zu verändern. Der Eingriff findet rückwirkungsfrei, außerhalb der Sicherheitssoftware statt. Die Maschinensicherheit bleibt dadurch unverändert erhalten

Zusätzlich werden die Energiekontrollbausteine speziell an die einzelnen Maschinentypen angepasst. Im Betrieb der Maschinen können die Energiebausteine nur an definierten Programmpunkten aktiv werden. Diese Haltepunkte werden durch den Anwender am Bedienpanel definiert, um dem Produktionsprozess nicht zu stören. Zusammenfassend kann man sagen, dass die Maschinen nur in einem sicheren Betriebszustand durch das KI-Energiemanagement angehalten werden.

Fazit

Die Interaktion von maschinenseitigen Energiecontrolling und KI gestützten MES beeinträchtigt nicht die funktionale Sicherheit der EMAG-Maschinen. Der Maschinenschutz bleibt unverändert bestehen. Die Schnittstelle greift an vordefinierten Punkten, ist sicher und rückwirkungsfrei.

Im Weiteren wurde die Zuordnung der Sicherheitsfunktionen zu Schutzebenen betrachtet. Dies ergab, dass die Zuordnung der Schutzebenen entfällt, da die Risikobeurteilung keine Sicherheitsrelevanz der KI ergeben hat. Somit bleibt beim obigen Konzept das Schutzsystem des Maschinenlieferanten unverändert. Die CE-Zertifizierung der Maschine ist von der KI-Anwendung nicht betroffen. Für die KI-Anwendung werden also keine Sicherheitsanforderungen gestellt.

Generell ist die aktualisierte EU-Maschinenverordnung von 2023 zu beachten die jedoch keinen konkreten Anforderungen an die Sicherheit der KI-Anwendung für Fräsmaschinen formuliert. Da eine Risikobeurteilung der KI-Anwendung entfällt und die Sicherheit der Maschinen nicht verändert wurde entfällt auch das Review nach Detail Engineering. Auch die Entwurfsprüfung des Schutzsystems der KI-Anwendung entfällt, da im Rahmen der KI kein Schutzsystem implementiert wurde. So wird auch kein Validierungsplan erstellt da es kein Schutzsystem gibt welches erneut validiert werden muss.

In zukünftigen Anwendungen könnten aber durchaus Aufgaben der funktionalen Sicherheit im Rahmen der KI realisiert werden. Eine solche Aufgabenstellung erfordert eine quasideterministische Arbeitsweise der KI. Das System müsste mit Hilfe von Selbstdiagnose im Fehlerfall einen sichern Zustand annehmen. Ausgehend von der Annahme, dass bei Anwendung von sicheren Entwurfsmethoden, QS-Maßnahmen und entsprechender Cybersicherheit, der Lernprozess der KI die Sicherheit graduell erhöht, kann man in Anlehnung an DIN EN 61508 die Sicherheit der KI als Wahrscheinlichkeit von fehlerhaften Entscheidungen definieren.

Die funktionale Sicherheit (FuSi) eines KI-Systems deterministisch nachzuweisen, ist eine komplexe Aufgabe, insbesondere aufgrund der inhärenten Unsicherheiten und nicht-deterministischen Natur von KI-Algorithmen. Dennoch gibt es einige Ansätze, um die FuSi eines KI-Systems zu bewerten und zu überprüfen:

- **Simulation und Testen:** Durch Simulationen und umfangreiche Tests können verschiedene Szenarien und Randbedingungen untersucht werden, um die Leistung und Robustheit des KI-Systems zu bewerten. Dies umfasst sowohl die Validierung der Funktionalität als auch die Überprüfung auf potenzielle Sicherheitslücken oder Anfälligkeiten. An dieser Stelle kann der

Ansatz der DIN EN 61508 verfolgt werden und die Sicherheit des KI-Systems anhand des Anteils der gefährlichen, fehlerhaften Entscheidungen an der gesamten Anzahl der Entscheidungen berechnen. Ist die Anzahl der gefährlichen Entscheidungen, hinreichend gering und die Anzahl der Tests hinreichend groß (typischerweise 10T Arbeitsstunden) kann man eine bestimmte SIL-Tauglichkeit des Systems attestieren

- **Robustheitsbewertung:** Eine umfassende Bewertung der Robustheit des KI-Systems gegenüber verschiedenen Arten von Störungen, Angriffen und unvorhergesehenen Situationen kann Aufschluss über die Sicherheit des Systems geben. Dies umfasst die Bewertung der Robustheit gegenüber Angriffen, Datenverzerrungen und anderen Störungen.
- **Robustheitsbewertung:** Eine umfassende Bewertung der Robustheit des KI-Systems gegenüber verschiedenen Arten von Störungen, Angriffen und unvorhergesehenen Situationen kann Aufschluss über die Sicherheit des Systems geben. Dies umfasst die Bewertung der Robustheit gegenüber Angriffen, Datenverzerrungen und anderen Störungen.
- **Sicherheitsprüfungen:** Durchführung von Sicherheitsprüfungen im Bereich Cybersicherheit, um potenzielle Schwachstellen im System zu identifizieren und zu beheben. Dies umfasst die Bewertung der Sicherheit sowohl auf der Ebene der Softwareimplementierung als auch auf der Ebene der Systemarchitektur.
- **Zertifizierung und Compliance:** Einhaltung von Industriestandards und -richtlinien zur funktionalen Sicherheit von KI-Systemen. Dies kann die Zertifizierung nach internationalen Normen wie ISO 13849 für die funktionale Sicherheit von Maschinen oder IEC 61508/61511 für sicherheitsrelevante elektrische Systeme umfassen.
- **Dokumentation und Transparenz:** Eine umfassende Dokumentation aller Aspekte des KI-Systems, einschließlich seiner Funktionalität, Implementierungsdetails, Tests und Sicherheitsmaßnahmen, kann dazu beitragen, die Nachvollziehbarkeit und Transparenz des Systems zu gewährleisten.

Zusammenfassung der Arbeiten je Partner

TÜV Hessen (Leitung):

- Identifikation von relevanten Anwendungsfällen.
- Beurteilung der Fehler- und Ausfallsicherheit bei CuroCon
- Identifikation des Anwendungsfalls der Steuerung der VLC 100GT der ETA-Fabrik
- Gefahrenbeurteilung und Ausschluss einer direkten Gefährdung durch die Eingriffe an der VLC 100 GT
- Theoretische Betrachtung von Ansätzen zur Beurteilung der funktionalen Sicherheit eines KI-Systems

CuroCon:

- Absprachen über die geplanten Steuerungseingriffe der Versorgungstechnik und die daraus möglichen resultierenden Gefahren.
- Beurteilung und Ausschluss einer Gefahr für den Mensch, Maschinen oder die Umwelt am Gebäudemanagement bei CuroCon.

2.3. Teilprojekt 3: Energetische Transparenzschaffung & Monitoring

Automatisierte und standardisierte Lösungen zur energetischen Transparenzschaffung in der industriellen Produktion sind bisher weder in der Forschung noch in der Praxis verfügbar gewesen. Der Bedarf für Systeme zur Transparenzschaffung, die keine Fachkenntnisse voraussetzen, ist jedoch enorm. [90] [91] Das Ziel des Teilprojekts besteht in der zeitlich verkürzten und fachlich vereinfachten energetischen Bestandsaufnahme in industriellen Fabriken.




Abbildung 2.22: Maßnahmen zur Transparenzschaffung im komplexen Fabrikssystem.

Im Rahmen des Teilprojektes drei sollen KI-gestützte Assistenzsysteme erforscht werden, welche den Energiemanagementbeauftragten einerseits dabei unterstützen, die energetische Transparenz in Fabriken zu erhöhen, und andererseits kostenoptimale neue Messstellen vorschlagen. Zuerst wird mit Hilfe von Bilderkennungsalgorithmen ein erster Überblick über den Energiebedarf auf Anlagenebene geschaffen und weiterführende temporäre Messungen priorisiert, sowie bei deren Umsetzung unterstützt. Darauf aufbauend wird ein Expertensystem zur wirtschaftlichen Bewertung und Priorisierung von energetischen Messstellen erarbeitet. Hierfür werden u.a. virtuelle Messstellen generiert, die kostengünstig den Energiebedarf einer Maschine vorhersagen.

Tabelle 2.3: Arbeitspakete in Teilprojekt 3.

Energetische Transparenzschaffung & Monitoring		Beteiligte Partner
Teilprojektleitung: PTW		
AP 3.1	Aufbau eines KI-gestützten Tools zur ersten energetischen Übersichtsschaffung	PTW, DFKI, EJOT

AP 3.2	Automatisierte Identifikation von Leckagen und Energieeffizienzverlusten	DFKI, Mader
AP 3.3	Assistenzsystem zur Identifikation von Energieflüssen und Positionierung von Messeinrichtungen mittels AR	DFKI, Mader
AP 3.4	Generierung und Fehlerreduktion von virtuellen Messstellen mit selbstlernenden Monitoringalgorithmen	PTW, Entega, ÖKOTEC
AP 3.5	Generische Energiekennzahlbildung und Benchmarking	ÖKOTEC, atlan-tec, GreenDelta, EJOT
AP 3.6	Entwicklung von selbstlernenden Algorithmen zur KI-gestützten Messdatenauswertung	Software AG, Bosch, PTW
AP 3.7	Aufbau eines ganzheitlichen Expertensystems zur Messstellenplanung	PTW, atlan-tec

2.3.1. Arbeitspaket 3.1: Aufbau eines KI-gestützten Tools zur ersten energetischen Übersichtsschaffung

Bei der energetischen Transparenzschaffung wird in der Literatur zwischen Grob- und Feinanalyse unterschieden (vgl. [92]). Während die Grobanalyse das Ziel hat, vergleichsweise aufwandsarm Hauptverbraucher zu identifizieren, indem Informationen von Schaltplänen und Typenschildern erfasst werden, ist die darauffolgende Feinanalyse deutlich aufwändiger und kostenintensiver, da hier die Erhebung von Messdaten notwendig ist.

Ziel des Arbeitspaketes ist die Entwicklung eines KI-gestützten Tools für eine automatisierte Grobanalyse des Energiebedarfs einer Fertigung. Das in diesem Arbeitspaket erstellte Schaltplantool analysiert digitale Schaltpläne, wobei Maschinenkomponenten und deren elektrische Anschlussleistung auf Basis der in Schaltplänen enthaltenen Informationen, wie Symbole der einzelnen Komponenten und zugehörige Beschriftungen, über maschinelle Bilderkennung auf Grundlage von Convolutional Neural Networks (CNN) automatisiert identifiziert werden. Das Ergebnis der Analyse ist die Zusammenfassung der erkannten Informationen wie Elektromotorsymbole, Leistungs- und Funktionsdaten sowie Herstellerinformationen in einem Auswertungsbericht, der als PDF-Datei zur Verfügung gestellt wird und welcher als Grundlage für die Priorisierung weiterer Messungen und Maßnahmen (vgl. AP 4.4) herangezogen wird.

Als Anwendungsfall wurden die vorhandenen Typenschilder und Schaltpläne der Anlagen in der ETA-Fabrik ausgewählt. Von EJOT wurden außerdem Elektroschaltpläne einer Doppeldruckpresse zur Verfügung gestellt, die zur Validierung des Tools als auch als Demonstrator für die Arbeitsergebnisse am Ende des Projektes (vgl. AP 7.2) dienen.

Die Entwicklung des KI-gestützten Schaltplantools wurde zunächst mit einer eingehenden Literaturrecherche zum Stand der Technik der relevanten Themen Machine Learning und künstliche neuronale Netze, Normierung von Elektro- und Hydraulikschaltplänen sowie Bilderkennungsalgorithmen begonnen. Aufbauend darauf wurde ein Konzept für die zeitlich aufeinander abgestimmten Abläufe und Prozessreihenfolgen in Form eines Programmablaufplans erstellt. Außerdem wurden notwendige Bibliotheken und Algorithmen für die Programmiersprache Python ausgewählt. Abbildung 2.23 stellt den Programmablaufplan dar, welcher sich in die folgenden vier Phasen gliedert:

- Datenerfassung und -Verarbeitung: In einem ersten Schritt werden die Schaltpläne erfasst und konvertiert.
- Textbasierte Schaltplananalyse: PDF basierte Schaltpläne deren Inhalt textbasiert vorliegt, lassen sich einfach durchsuchen.
- Bildbasierte Schaltplananalyse: Zusätzlich findet eine Bilderkennung relevanter Symbole mittels künstlicher neuronaler Netze statt.
- Datenbereitstellung: Die erkannten Informationen werden in einer SQL-Datenbank gespeichert und für die weitere Verwendung (bspw. in AP 4.4) bereitgestellt.




Abbildung 2.23: Programmablaufplan des KI-gestützten Tools zur ersten energetischen Übersichtsschaffung.

Zur Validierung der Funktionalität wurden Elektroschaltpläne der ETA-Produktionslinie und der HR-6L Doppeldruckpresse von EJOT analysiert, welche im Folgenden genauer betrachtet wird.

Eine händische Identifikation der elektrischen Hauptverbraucher der HR-6L Doppeldruckpresse auf Komponentenebene im 215-seitigen Schaltplan würde zweifelsfrei viel Zeit beanspruchen. Das Schaltplantool hingegen bereitet die Ergebnisse innerhalb weniger Minuten auf, und stellt diese dem Nutzer übersichtlich in einer PDF-Auswertung und in einer SQL-Datenbank zur Verfügung. Auf diese Weise konnten alle Elektromotoren (vgl. Abbildung 2.24) der Fertigungsmaschine identifiziert und inklusive der Komponentenbezeichnung, Anschlussleistung, Nennstromstärke, Versorgungsspannung, möglicher Positionierung von Messklemmen sowie der jeweiligen Seitenzahl im Schaltplan vollautomatisiert zur Verfügung gestellt werden.

Bei kritischer Betrachtung der Ergebnisse ist jedoch festzuhalten, dass die Identifikationsgüte des Schaltplantools abnimmt, falls Schaltpläne nicht in Originalqualität zur Verfügung gestellt werden. Des Weiteren werden in Ausnahmefällen die standardisierten Schaltplansymbole, insbesondere bei älteren Schaltplänen, nicht konsistent genutzt, was die Bilderkennung erschwert.




Abbildung 2.24: Beispielhafte Darstellung des identifizierten Hauptantriebs im Schaltplan der EJOT HR-6L Doppeldruckpresse (links) sowie die Zusammenfassung der relevanten Information wie z. B. elektrische Anschlussleistung, Nennstromstärke und Versorgungsspannung im Auswertungsbericht (rechts).

Mit den Ergebnissen der Grobanalyse in der SQL-Datenbank kann eine Priorisierung der Verbraucher über die ABC-Priorisierung oder unter Berücksichtigung von Maschinenlaufzeiten über eine Anlagen-Verbrauchsmatrix erfolgen. Aufbauend darauf können Feinanalysen (vgl. AP 4.4) durchgeführt werden. Zu diesem Zweck und für die weitere Verwendung der Ergebnisse in anderen Arbeitspaketen (z. B. AP 3.3, AP 3.7, AP 4.4) wurde über die Anforderungen dieses Arbeitspakets in der Vorhabensbeschreibung hinaus ein Dashboard entwickelt, welches die Ergebnisse sowohl grafisch als auch tabellarisch in einer ABC-Analyse darstellt. Durch eine interaktive Eingabefunktion können zusätzlich Maschinenauslastungen und Laufzeiten berücksichtigt werden, wodurch eine Anlagen-Verbrauchsmatrix erstellt wird. Abbildung 2.25 und Abbildung 2.26 zeigen Ausschnitte des Dashboards.





Abbildung 2.25: Grafische Darstellung der ABC-Priorisierung der Komponenten der EJOT-Produktionsanlagen im Dashboard.



Anlagen-Verbrauchsmatrix tabellarisch

Power [kW]	id	Mögliche Bezeichnung	Matrix result	Massnahmen
18.5	3	HAUPTANTRIEB	I	High relevance for continuous metering
1.5	9	RAUCHABZUGSMOTOR	IV	Medium-low relevance for continuous metering
0.55	5		III	No relevance for continuous metering
0.55	10		III	No relevance for continuous metering
0.37	6	KÜHLMITTELPUMPE	IV	Medium-low relevance for continuous metering
0.37	8	SCHMIERMITTELPUMPE	IV	Medium-low relevance for continuous metering
0.25	4	ROLLENANTRIEB	IV	Medium-low relevance for continuous metering

Abbildung 2.26: Grafische und tabellarische Darstellung der Komponenten der EJOT-Produktionsanlagen in der Anlagen-Verbrauchsmatrix im Dashboard unter Berücksichtigung von Auslastung und Laufzeiten.

Zusammenfassung der Arbeiten je Partner

PTW (Leitung):

- Literaturrecherche zu neuronalen Netzen, Normierung von Elektro- und Hydraulikschaltplänen sowie Bilderkennungsalgorithmen
- Konzeptionierung und Umsetzung des KI-basierten Schaltplantools
- Validierung für Fertigungsmaschinen der ETA-Produktionslinie und für die von EJOT bereitgestellten Elektroschaltpläne der HR-6L Doppeldruckpresse
- Entwicklung eines Dashboards zur grafischen Darstellung und Weiterverwertung der Ergebnisse des Schaltplantools

DFKI:

- AP-übergreifende Kommunikation zur Bereitstellung der notwendigen Inhalte und Identifizierung der benötigten Energiedaten für die Visualisierung der Energieflüsse in AP 3.3

EJOT:

- Bereitstellung von Schaltplänen und Dokumentation zu ausgewählten Produktionsmaschinen (EJOT HR-6L Doppeldruckpresse)
- Bewertung des Transparenzschaffungsansatzes aus Sicht eines industriellen Anwenders

2.3.2. Arbeitspaket 3.2: Automatisierte Identifikation von Leckagen und Energieeffizienzverlusten

Im Rahmen des Arbeitspakets 3.2 des Teilprojekts 3 wurde ein autonomes System zur Detektion und Lokalisierung von Druckluftleckagen in Fabriken entwickelt. Ziel war es, eine effiziente energetische Bestandsaufnahme zu ermöglichen, die nicht nur Fachpersonal entlastet, sondern auch zeitaufwendige manuelle Prozesse erleichtert. Druckluft zählt zu den teuersten Energiequellen in der industriellen Produktion, wobei bis zu 30 % der erzeugten Druckluft durch Leckagen verloren gehen können [93].

- Localization and Measurement Phase: Die Daten aus der Erkennungsphase werden ausgewertet, um die exakte Position der Leckagen zu bestimmen.
- Data Deployment Phase: Die Ergebnisse werden in das digitale Umgebungsmodell integriert und über eine OPC-UA-Schnittstelle an die Energiemanagementplattform übertragen.




Abbildung 2.28: Die fünf Phasen der Suchstrategie.




Abbildung 2.29 a) Ergebnisse der Validierung der Messfähigkeiten des Sensors auf Entfernungen bis zu 4 Meter. B) Versuchsplan mit verschiedenen Abständen und Winkeln des Sensors zur Leckagestelle. c) Versuchsaufbau zur Messung mit dem Sensor mit umhüllendem Schalltrichter auf Stativ.

Im Zentrum der Leckageortung steht eine speziell entwickelte Anlage mit einem Ultraschallsensor, dessen Reichweite durch eine Verlängerung des Trichters auf bis zu vier Meter vergrößert werden konnte (siehe Abbildung 2.29). Der Sensor ist auf einem Pan-Tilt-System montiert, das eine präzise Ausrichtung ermöglicht. Unterstützt wird die Ultraschallsensorik durch einen Lidar-Sensor zur Abstandsmessung und

eine Kamera mit integriertem eigens nachtrainiertem YOLOv4-Algorithmus, die speziell für die visuelle Identifikation von Druckluftsystemen eingesetzt wird. Durch die Kombination dieser Technologien ist es gelungen, eine präzise und effiziente Leckageerkennung zu realisieren. Für die Navigation in komplexen Fabrikumgebungen wurde der NAV2-Stack von ROS2 eingesetzt. Spezialisierte Algorithmen sorgten für eine zuverlässige Hinderniserkennung und -vermeidung. Ein Sweep-Planungsansatz ermöglichte die strukturierte Erfassung von definierten Suchgebieten, die von Szenario-Experten auf den speziell entwickelten User-Interface-Tools markiert wurden, wie in Abbildung 2.30 zu sehen ist. Die erfassten Sensordaten werden während der Leckagesuche parallel ausgewertet, was sowohl die Datenerfassung als auch die Lokalisierung deutlich verbesserte.




Abbildung 2.30 (links) Visualisierte Umgebungskarte der ETA-Fabrik mit symbolischer Wegplanung zu und in zwei Suchpolygonen, (rechts) Legende.

Die Validierung des Systems erfolgte durch Tests in der ETA-Fabrik, der Technologie-Initiative SmartFactory KL e. V. und beim Unterauftragnehmer Mader GmbH & Co. KG. In allen Umgebungen konnte der Roboter vorab definierte Leckagen zuverlässig erkennen und lokalisieren. Besonders in der ETA-Fabrik, welche ein repräsentatives Fabriklayout nachbildet, wurde die Funktionalität des Systems umfassend getestet und nachgewiesen. In Abbildung 2.31 wird das Ergebnis des Validierungsversuchs bei Mader dargestellt.




Abbildung 2.31 (links) Visualisierung potenzieller Leckagen (Rote Punkte) in der Umgebungskarte, (rechts) Intensitätsdaten (sdt_value_mA).

Das System bietet Vorteile gegenüber herkömmlichem, heute standardmäßigem manuellem Verfahren:

- **Zeitersparnis** bei der Leckagesuche durch Einbringen von Expertenwissen anhand von Bereichen von Interesse und autonomer Erkundung.

- **Präzision** bei der Lokalisierung von Leckagebereichen durch Validierung einzelner Messwerte und Plausibilisierung der Leckage von verschiedenen Messpositionen.
- **Informationshandling** von Energieverlusten und CO₂-Emissionen durch zentralisierte Energiedaten und dadurch eine schnellere Einleitung von Gegenmaßnahmen.

Trotz pandemiebedingter Verzögerungen und Herausforderungen bei der Integration von Hard- und Software konnten alle wesentlichen Projektziele erfolgreich umgesetzt werden. Die Ergebnisse wurden bereits in einer wissenschaftlichen Publikation veröffentlicht und auf dem INFORMATIK FESTIVAL 2024 vorgestellt [94].

Zukünftige Arbeiten sollten sich darauf konzentrieren, das System weiterzuentwickeln, insbesondere:

- Skalierung für größere Fabrikumgebungen,
- Integration zusätzlicher Sensorik zur Erkennung weiterer Energieverluste und
- Implementierung von KI-gestützter Objekterkennung sowie Wissensgraphen zur Effizienzsteigerung.

Zusammenfassung der Arbeiten je Partner

DFKI (Leitung):

- Entwicklung der Suchstrategie und der Roboter- Navigation
- Systemintegration und Aufbau des ALF
- Evaluierung des Gesamtkonzepts

Mader GmbH & Co. KG (Unterauftragnehmer):

- Bereitstellung von Expertise, industrieller Testumgebung und Evaluierungsmöglichkeiten

2.3.3. Arbeitspaket 3.3: Assistenzsystem zur Identifikation von Energieflüssen und Positionierung von Messeinrichtungen mittels Augmented Reality (AR)

Fehler bei der Positionierung von Messgeräten sind in der Industrie keine Seltenheit. Prozessdaten und Energieflüsse sind "unsichtbar" und daher für die Mitarbeitenden nur schwer zu erkennen. AR-Lösungen können hier helfen. Das zu konzipierende AR-System kann mit einem intelligenten Endgerät (Smartphone, Tablet oder Datenbrille) genutzt werden, um einen Überblick über die Energieflüsse zu gewinnen. Zusätzlich werden geeignete Messstellen identifiziert und Informationen zur Arbeitssicherheit an Schaltschränken zur Verfügung gestellt.

Ziel des Arbeitspakets ist die Visualisierung der relevanten Messpunkte in einer Schaltanlage und Energieflussdaten durch AR mittels HoloLens/Tablet. Die Messstellenidentifikation durch Blick in die Schaltpläne ist eine mühsame Arbeit, die im Rahmen des Projektes automatisiert werden soll, um die zeitaufwändige manuelle Suche zu ersetzen. Im Prinzip ist es ein AR-basiertes Assistenzsystem, das über ein AR-Gerät wie eine HoloLens oder ein Tablet genutzt werden kann.

In der Phase der Anforderungsanalyse wurden Persona und Szenarien skizziert. Dabei wurden die Arbeitnehmer und Szenarien aus dem Projektvorschlag berücksichtigt. Später wurden je nach den impliziten und expliziten Anforderungen Mock-UI- und Anwendungsfunktionen identifiziert.

Es wurden Recherchen und Versuche für Augmented Reality (oder HoloLens-spezifisch - Mixed Reality) marker-basierte räumliche Anker durchgeführt. Die Anker dienen der Positionierung von

Augmentationsinhalten im Raum als Ergebnis von Erkennungseingaben. Der QR-Marker-Tracker von MRTK wurde in HoloLens 2 implementiert und getestet. Es war jedoch keine verlässliche Lösung im Hinblick auf die Leistung und Latenzzeit sowie die Nutzung für die weitere Anwendungsentwicklung. Später wurde das Vuforia SDK für das Marker-Tracking getestet und es funktionierte erfolgreich in der AR-Entwicklungsumgebung der Unity 3D-Engine.

Abbildung 2.32 zeigt die Struktur der AR-Anwendung, die aus Komponenten sowie ihren Entwicklungsablauf besteht. Wie erwähnt, war die Implementierung des Markers in die AR-Anwendung der erste Schritt. Nachdem die räumliche Verankerung durch Marker-Tracking hergestellt war, begann die Anwendungsentwicklung in der Simulationsumgebung von Unity3D. Die verschiedenen UI-Komponenten wurden erstellt und entsprechende Verhaltensskripte geschrieben. Die 2D- und 3D-Komponenten wurden aus den bereits vorhandenen CAD-Daten der Anlage erstellt oder importiert.




Abbildung 2.32: Komponenten der AR-Anwendung.

Das Sequenzdiagramm der Anwendung ist in Abbildung 2.33 dargestellt. In dem Diagramm sind die beiden Anwendungsfälle deutlich zu erkennen.




Abbildung 2.33: Sequenzdiagramm für die AR-Anwendungen.

Abbildung 2.34 und Abbildung 2.35 zeigen die Aufnahmen der AR-Applikation von der HoloLens in der Smart Factory KL an der PL4 Anlage. Mit einer auf Bilderkennung basierenden Marker-Tracking-Komponente werden den Nutzenden die AR-Inhalte, bestehend aus den Kontextinformationen wie Messstellen, Spannungswert, Bauteilbezeichnung und dem jeweiligen Schaltplan, angezeigt.




Abbildung 2.34: Markerbasierte AR-Anwendungsdemo in der Smart Factory KL auf dem Lager- und Montagemodul der PL4 Anlage.

Im Rahmen dieser Arbeit kann das AR-Assistenzsystem in Zukunft evaluiert und die Vorteile in quantifizierter Form nachgewiesen werden. Die Zeitersparnis und die kognitive Belastung der Werker können evaluiert werden.




Abbildung 2.35: Markerbasierte AR-Anwendungsdemo für Klimaraum (ETA-Fabrik).

Zusammenfassung der Arbeiten je Partner

DFKI (Leitung):

- Definition von Anwendungsfällen, Aufteilung der Aufgaben aus dem Projektantrag in zwei Anwendungsfälle
- Ausarbeitung von Personas und User Stories, um implizite und explizite Anforderungen besser zu definieren
- Design und Entwicklung des UI der AR-App in Unity3D
- Implementierung eines Vuforia AR Marker Trackers auf der HoloLens unter Verwendung der Unity3D
- Design und Entwicklung geeigneter Overlay-Objekte in Unity, die aus einer interaktiven Schnittstelle bestehen
- Datenabruf auf der HoloLens von der EnEffCo-Energiemanagement-Plattform über Python-Server und TCP-Sockets
- Realisierung der AR-Lösung für ein Produktion Level 4 Modul in der Smart Factory Kaiserslautern

2.3.4. Arbeitspaket 3.4: Generierung und Fehlerreduktion von virtuellen Messstellen mit selbstlernenden Monitoringalgorithmen

Hybride virtuelle Messstellen sind echtzeitnah ausführbare empirische Modellierungsansätze, um den (Nutz-) Energiebedarf eines vorliegenden Systems zu berechnen. Nach [95] lassen sie sich in einfache, faktorisierte sowie prozess- und zustandsbasierte virtuelle Energiemessstellen unterteilen. ÖKOTEC und

das PTW treiben parallel empirische Modellierungsansätze voran, um einerseits den Energiebedarf von Maschinen ohne Datenschnittstelle zu modellieren und andererseits, um schwer messbare Einflussgrößen zur Bestimmung von Energieeffizienzkennzahlen über Modelle und Algorithmen abzuleiten und Zustandsräume abzuschätzen, in denen sich diese Anlagen befinden.

Anwendungsfall PTW

Seitens PTW wurde ein selbstlernender Service entwickelt, welcher basierend auf mobilen temporären Energiemessungen eine virtuelle Energiemessstelle generiert. Umgesetzt wurde das Verfahren nach dem methodischen Vorgehen des CRISP-ML(Q) an den fünf Fertigungsmaschinen der ETA-Prozesskette. Die unten genannten Ergebnisse und weitere Details zum Energiemonitoring mittels virtueller Energiemessstellen sind in einer Dissertation [96] veröffentlicht.

Bei der mobilen Erfassung von Energie- und Zustandsdaten kommt das *ETA-Edge-Lense* zum Einsatz (siehe Abbildung 2.36). Die Evaluation des mobilen **Datenerfassungskonzepts** verdeutlicht, dass die optische Zustandsdatenerfassung bei allen Fertigungsmaschinen, deren SPS-Module über Status-LEDs verfügen, unabhängig von der Verfügbarkeit maschinenseitiger Datenschnittstellen und unabhängig vom IT-Netzwerk des Unternehmens, anwendbar ist. Weiterhin ist der händische Implementierungsaufwand des ETA-Edge-Lense gering. Zudem konnte im Rahmen einer Marktstudie gezeigt werden, dass die größten Steuerungshersteller des europäischen Markts ausschließlich digitale I/O-Module mit Status-LEDs vertreiben, wodurch Übertragbarkeit und Anwendbarkeit gewährleistet sind. Des Weiteren wurde gezeigt, dass die Datenerfassung-, Verarbeitung- und Bereitstellung über das ETA-Edge-Lense zuverlässig und präzise funktioniert. Unter 300 zufällig ausgewählten Fotos je Fertigungsmaschine wurden lediglich 0,6 % der LED-Signale falschpositiv- und 0,0 % falschnegativ klassifiziert, weshalb eine nachvollziehbare und hochgenaue Datengrundlage seitens der LED-Zustandssignale generiert wird [96].




Abbildung 2.36: Konzept der temporären Energie- und Zustandsdatenerfassung (links) und Foto des ETA-Edge-Lense im Schaltschrank (rechts) (Bildquelle: [96]).

Im Rahmen der **Evaluation der Datenvorverarbeitung** veranschaulicht eine Sensitivitätsanalyse der Modelleingangssignale, dass insbesondere die Zustandssignale der energieintensivsten Aggregate relevant für die virtuellen Energiemessstellenmodelle sind. Zudem werden oft Prozesssignale einbezogen, um den dynamischen Anteil des Lastgangs genauer abzubilden. Die Sensitivitätsanalyse hilft dem betrieblichen Energiebeauftragten dabei, die Prognoseergebnisse der virtuellen Energiemessstellenmodelle retrospektiv nachzuvollziehen.

Bei der *Evaluation der virtuellen Energiemessstellenmodelle* wurde dargelegt, dass sich sowohl LED-Zustandsdaten als auch maschineninterne Steuerungsdaten zur Modellbildung des Lastgangs einer Fertigungsmaschine eignen. Hierbei wird häufig eine bessere Genauigkeit bei der Modellbildung mit dynamischen Prozesssignalen erreicht als mit LED-Zustandsdaten. Der Leistungsbedarf aller fünf untersuchten Fertigungsmaschinen konnte, zumindest über eine der beiden verfügbaren Datenquellen, mit einem $\text{NRMSE}_{99-1\%}$ unter 8,8 % modelliert werden, was einem NRMSE_R von 8 % bzw. 4,7 % entspricht (siehe Abbildung 2.37). Da ein ganzheitlicher Ausbau der energetischen Transparenz aktuell primär an den Kosten physischer Energiemesstechnik scheitert und hochgenaue Energiebedarfsinformationen für zahlreiche Anwendungsfälle nicht erforderlich sind, erfüllt die erzielte Genauigkeit der virtuellen Energiemessstellen in vielen Fällen die Datenqualitätsanforderungen des betrieblichen Energieinformationsmanagements [96].




Abbildung 2.37: Zeitverläufe der gemessenen und modellierten Wirkleistung der Fertigungsmaschinen der ETA-Prozesskette. Hierbei wird zwischen Modellen unterschieden, die mit SPS-Daten und mit LED-Zustandsdaten trainiert wurden. Des Weiteren wird jeweils darunter der Betriebsmodus in Form eines Balkendiagramms ausgewiesen. (Bildquelle: [96]).

Die Evaluation der **Anwendung** der virtuellen Energiemessstellenmodelle demonstriert, dass die Zielgrößen innerhalb weniger Sekunden berechnet und an ein Energiemanagementsystem übermittelt werden können.

Virtuelle Energiemessstellen können vielseitig im Energiemanagement eingesetzt werden, haben jedoch auch Limitationen, die ausführlich in [96] beschrieben sind. Demnach ist der Einsatz physischer

Energiemessstellen nach wie vor für die Überwachung der Energiequalität und für externe Abrechnungen notwendig. Zudem sind physische Energiemessstellen zu bevorzugen, wenn häufige Änderungen der produktionstechnischen Einflussfaktoren, wie beispielsweise das Produktionsprogramm, zu erwarten sind. Demnach eignet sich der Ansatz primär für das Energiemonitoring in der Varianten-, -Serien- und Massenfertigung-.

Anwendungsfall ÖKOTEC

Der Anwendungsfall von ÖKOTEC und dem assoziierten Partner Energieering war die Nutzung von Machine Learning-Ansätzen, um das Verhalten der Komponenten eines Kühltowers zu beschreiben und zu trainieren, um im späteren Verlauf des Projekts (vgl. AP 4.5) den Betrieb hinsichtlich der Energieeffizienz und der Energiekosten zu optimieren. In diesem Arbeitspaket lag das Zielstellung in zwei Bereichen:

- Die Verknüpfung der beiden Bereiche Kälteerzeugung durch Kältekompressoren und Kälteverteilung in den Kühlräumen durch die gemeinsame nicht gemessene Größe der Kältemenge
- Modellierung von dynamischen Temperaturveränderungen mittlerer Kühlraumtemperaturen über 192-384 Zeitschritte (je 15min) in die Zukunft unter Berücksichtigung von Einflussfaktoren

Die Nutzung und Modellierung der nicht gemessenen Kältemenge als virtuelle Messstelle scheint auf den ersten Eindruck sehr sinnvoll, da sie den Strombedarf und den Wirkungsgrad der Kälteerzeugung sowie die Temperaturveränderungen in den Kühlräumen kombiniert. Dazu müssen alle zur Erklärung der Daten relevanten Einflüssen erfasst werden.

Die Temperatur in den Kühlräumen ist aufgrund der Mittelwertbildung aus verschiedenen Messensoren indirekt auch ein virtueller Datenpunkt, aber er kann konkret berechnet werden. Die Besonderheit bzw. Notwendigkeit der Modellierung liegt hier jedoch eher in der Fortschreibung der Temperatur für einen definierten Zeitraum in die Zukunft als Erwartungswert. Hier werden Algorithmen benötigt, die u.a. dynamisch Veränderungen gegen einen Grenzwert berücksichtigen. Je höher Temperaturen gegenüber der Außentemperatur werden und je größer die Differenz der Raumtemperatur zur Warenkerntemperatur im Kühlraum wird, desto geringer wird die zeitliche Temperaturveränderung. Zudem ist die Warenkerntemperatur selbst nicht gemessen und muss als Temperatur aus zurückliegenden Kühlraumtemperaturen abgeschätzt werden.

ÖKOTEC hat mit dem assoziierten Partner Energieering das IT-Konzept für die Installation der Software EnEffCo® im Kühltower in Heppenheim durchgeführt. Beide Partner waren vor Ort, um sich einen Eindruck des zu betrachtenden Systems und der aktuellen Steuerungslogik der Anlagenkomponenten sowie der relevanten Datenpunkte auf die Betriebsweise der Anlage zu machen. Das Messstellenkonzept wurde finalisiert.

Im Anschluss hat ÖKOTEC beim Partner Energieering nun die Installation der Software EnEffCo abgeschlossen. Mit den Mitarbeitern vor Ort wurde das Gateway für den Zugriff auf die Realdaten am Standort im lokalen Netzwerk eingerichtet. Es wurden etwa 500 Datenpunkte der Kompressoren (Kälteerzeugung) sowie des Verteilsystems und im Verbrauchsbereich (u.a. Lüfter und Verdampferventile sowie Temperaturen in Kühlzonen) im Zeitintervall von 1 min aufgenommen. In einem weiteren Schritt mussten die Daten verifiziert und plausibilisiert werden. Bei einem Teil der Daten mussten Definitionen der Importschnittstellen nachgearbeitet werden. Im Anschluss konnten dann erste detaillierte Analysen des Anlagenverhaltens und der Steuer- und Regelungsstrategie erstellt werden. Auf

Basis der Auswertungen ist die Systemdefinition und die Modellbildung im Rahmen einer erweiterten Kennzahlensystematik erfolgt, die auch Systemzustände und weitere technische Informationen und Restriktionen für die Erweiterungen im AP 4.5 enthält.




Abbildung 2.38: Vereinfachtes Modell der Kälteverbundanlage.

Mit Hilfe historischer und aktueller Daten von Kühlraumtemperaturen- und Verdichtern der Verbundkälteanlage hat ÖKOTEC eine erste Modellierung von Lastgängen der Kälteerzeugung vorgenommen. Dabei wurden bestehende Verfahren der Regressionsanalyse verwendet. Diese werden vorerst als Benchmark zur Nutzung weiterer Verfahren der Modellierung virtueller Messstellen verwendet. Mittels Workshops wurden weitere Verfahren der nichtlinearen Parameteridentifikation entwickelt, um auf Zusammenhänge zwischen den vorhandenen Daten und der nicht messbaren Kältemenge zu schließen. Diese Verfahren wurden als Demonstrator programmiert und testweise zur Parametrierung in EnEffCo® zur Verfügung gestellt.

Add-On Service Definition		
Name	ParameterID1_VZ_Kühlen	
Aktivierungs-Status	Inaktiv	
Datei-Pfad (.exe)	PI\ParameterEstimationAddOn.exe	
Der Pfad ist relativ zum EnEffCo-Service:	☒	
WCF-Port	2205	
Benutzer	eneffcosystemadmin	
Kennwort	*****	
	Testen	
Test-Ergebnis		
First opened(UTC):		
Last failed(UTC):		
Last opened(UTC):		

Konfigurierung		
Name	Wert	Typ
☒ DependentVariableDP	UD_130_HEP_MR_Raumtemp. VZ_Mittel	Text
☒ Formula	[UD_130_HEP_MR_Raumtemp. VZ_Mittel]= \$coeff_WU\$*[UD_130_HEP_MR_Rau	Text
☒ From	05-05-2023	Text
☒ Step	900	Int
☒ To	21-05-2023	Text
☒ IndependentVariables		Array
☒ 1	UD_130_HEP_MR_VZ_LK_gesamt_bin	Text
☒ 2	UD_130_HEP_MR_VZ_LK_gesamt_binC	Text
☒ 3	UD_130_HEP_MR_Raumtemp. VZ_Mittel-1	Text
☒ Parameters		Array
☒ 1	coeff_LK1	Text
☒ 2	coeff_LK2	Text
☒ 3	coeff_WU	Text

Abbildung 2.39: Nichtlineares Parametrierungsmodell zur Bewertung der Temperaturveränderung in den Kühlräumen.

Alle Verfahren konnten plausible und akkurate Parametrisierungsergebnisse liefern, was durch eine darauffolgende Simulation anhand historischer Daten gezeigt werden konnte. Die Ergebnisse auf der Modellierung waren exakt genug um diese für eine weitere Betriebsoptimierung (AP 5.3) zu verwenden. Im weiteren Verlauf wurde die Bewertung um Zustandsgrößen erweitert, da das zu optimierende System nicht über kontinuierliche Wertebereiche, sondern über die Wahl von unterschiedlichen Betriebszuständen (AP 4.5) gesteuert werden muss.




Abbildung 2.40: Simulation der Temperaturveränderungen in den Kühlräumen.

Im Rahmen der Entwicklungen wurde festgestellt, dass die Nutzung der Kältemenge als Bezugswert keine plausiblen Ergebnisse liefert, da keine Messdaten zum Modelltraining zur Verfügung standen und auch die Kälteverluste des Kühlraums sowie der Wärmeeintrag durch wärmere Waren nicht quantifiziert werden kann. Zudem mussten auch auf der Seite der Kälteerzeugung der nicht quantifizierbare Wirkungsgradverlust durch Teillastbetrieb nicht mehr modelliert werden, da das Ziel eines energieeffizienten Betriebs bei Betriebsoptimierung darin liegt, nach Möglichkeit immer die Zahl der Kompressoren und der Zahl der Kühlstellen im Kühlraum so zu wählen, dass alle Kompressoren auf der Niederdruck- und Hochdruckstufe immer in Volllast laufen. Damit konnte der Einfluss der Kälteerzeugung auf die Temperaturveränderungen sowie der Strombedarf der Kompressoren durch die Zahl der aktiven Kühlstellen und der Zahl der Kompressoren modelliert werden. Diese direkte Verknüpfung konnte die Simulationsergebnisse noch einmal verbessern.

Zusammenfassung der Arbeiten je Partner

PTW (Leitung):

- Konzeptentwicklung des virtuellen Energiemessstellenansatzes

- Entwicklung und Evaluation der brownfield-kompatiblen Zustandsdatenerfassung mit dem ETAEdge-Lense.
- Evaluation der notwendigen Datengrundlage mittels einer Sensitivitätsanalyse
- Training und Evaluation der virtuellen Energiemessstellen sowohl für maschinendatenbasierte und LED-zustandsdatenbasierte virtuelle Energiemessstellen für alle Maschinen der ETA-Prozesskette
- Echtzeitnahe Anwendung der virtuellen Energiemessstellenmodelle
- Veröffentlichung der Ergebnisse in Dissertation von Sossenheimer [96]

Entega:

- Austausch mit den beteiligten Forschungspartnern zur Anwendbarkeit bei Industriekunden
- Austausch mit den beteiligten Forschungspartnern zu virtuellen Messstellen und Non-Intrusive Load Monitoring (NILM)
- Evaluation der industriellen Einsatzfähigkeit und Limitationen aus Sicht eines Energieversorgers und Auditors

ÖKOTEC:

- Erstellung Systembeschreibung und Messkonzept
- Installation der Software EnEffCo®
- Anbindung der Datenpunkte und erste Auswertungen
- Konzept und Entwicklung von Parametrisierungsmethoden
- Parametrisierung und Simulation der Kälterzeugung und Temperaturänderungen in den Kühlräumen

2.3.5. Arbeitspaket 3.5: Generische Energiekennzahlbildung und Benchmarking

Bisherige Ansätze zur Erfassung von Kennzahlen bestehen in der Regel aus Flussgrößen für Aufwand, Nutzen und Einflussgrößen. Darauf werden typischerweise Formeln oder Regressionen angewendet, um Kennzahlen zu generieren. Diese Herangehensweise stößt bei komplexeren Zusammenhängen von Anlagen schnell an ihre Grenzen. Zudem lässt sie auch nicht zu, dass Kennzahlen aus optimierten Sollwerten über eine bestmögliche Anlagenkonfiguration bewertet werden können.

Daher wurden in einem ersten Schritt mögliche Anwendungen von Kennzahlen systematisch untersucht und strukturiert. Für den Energiekennzahlengenerator wurde eine Softwareumgebung mit Integrationsmöglichkeit in die Softwarearchitektur von EnEffCo® konzeptioniert. ÖKOTEC orientiert sich dabei an einem 3-Ebenen-Ansatz, in dem Objekte bzw. Anlagensysteme definiert, mit Modellen und Datenstrukturen verknüpft und in einem konfigurierten Prozess ausgeführt werden können.

Die generische Kennzahlensystematik baut auf Funktionalitäten, die in der Software EnEffCo® verfügbar sind auf und entwickelt diese nach den spezifischen Anforderungen weiter. Dazu gehören die Abbildung bzw. Definition von Anlagen bzw. Systemen, die Zuordnung von Metadaten und Restriktionen und Nebenbedingungen (z.B. Zustandsbedingungen), die Abbildung von Bilanzräumen und Zielfunktionen sowie die Erweiterung um Funktionsmodelle zu ML-basierten Berechnungsalgorithmen, aus denen dann Kennzahlen aggregiert und Benchmarking aufgebaut werden können.

Das Konzept des Energiekennzahlengenerators wurde beschrieben und aktuell für verschiedene Anwendungen evaluiert. Parallel wurde das Programmierkonzept zur Umsetzung eines Demonstrators erarbeitet. Für die relevanten Funktionsmethoden hat ÖKOTEC eine Methodenlandkarte erarbeitet und eine Shortlist an Methoden zur Eingrenzung erstellt.

Für eine Anwendung in Bereichen der Prozessindustrie und der ressourcenbasierten Bewertungsansätze für die generische Kennzahlenbildung wurden auch Konzepte mit atlan-tec sowie Green Delta diskutiert und abgestimmt.

Ein relevanter Arbeitsschritt war neben Abbildung der Daten und Zeitreihen auch die weitere Einbindung von Zusammenhängen, Wechselwirkungen, Zustände und Restriktionen, um komplexe Systeme modellieren zu können. Es gibt nun eine Vielzahl von vordefinierten Attributgruppen, mit denen Anlagenkomponenten definiert werden können. Es ist auch möglich, einer Anlage weitere Attribute als Untergruppen zuzuordnen. Mit den Attributgruppen können zudem Relationen zwischen den Anlagenkomponenten oder Verweise zwischen Anlagen und Energieflüssen in den Bilanzgleichungen hergestellt werden.

Attribut-Gruppen Zugehörigkeit bearbeiten		
Name	Titel	Zugehörig
(Global)		☒
Adresse	Adresse	☐
Lastgangauswertung	Lastgangauswertung	☐
Bus	Bilanzgleichung	☐
Storage	Speicher	☐
Supply	Erzeuger	☐
Optimization Problem	Optimierungsproblem	☐
Cyclicly Scheduled Optimization Problem	Zyklisch ausführbares Optimierungsproblem	☐
Added Capacity Measure	Kapazitätserweiterung	☐
Added Efficiency Measure	Effizienzmaßnahme	☐
Added Input	Input von Anlage	☐
Constraint	Nebenbedingung	☐
Parameter	Parameter	☐
Free Variable	Freie Variable	☒
Directory	Ordner	☐
IP EMS	IP EMS	☐
Consumer	Verbraucher	☐
Direct input	Direkt angeschlossener Input	☐
Directly connected consumer	Direkt angeschlossener Verbraucher	☐
Expanded Constraint	Constraint nach Zeitschritt	☐
Switching constraint	Schaltbegrenzung	☐
Added Output	Output zu Anlage	☐
Ignore	Ignoriere Anlage	☐
Slack variable	Hilfsvariable	☐
Übernehmen		Abbrechen

Abbildung 2.41: Auswahl an Attributgruppen zu Konfiguration von Anlagenkomponenten.

Der methodische Ansatz, um Kennzahlen zu berechnen, ist nicht vorgegeben. Es können einfache formelbasierte Berechnungen, aber auch gleichungssystembasierte Optimierungsverfahren, Model Predictive Control-Ansätze oder weitere Machine Learning-Prozesse sein.




Abbildung 2.42: Definition von Anlagen in einem definierten Anlagensystem und Zuordnung von Attributgruppen.

Das Programmierkonzept zur Erweiterung der EnEffCo-Funktionalitäten beinhaltet die folgenden Aspekte:

- Erweiterung der Anlagensystematik und der dazugehörigen Attributgruppen um weitere Attributgruppen, in denen Datenstrukturen wie Wechselwirkungen, Zustände und Restriktionen, etc. konfiguriert werden können
- Entwicklung von einem Interface, in das Modelle zur Berechnung der Kennzahlen eingebunden werden können und der Anlagensystematik zugeordnet werden
- Eine Umgebung, in der Ausführungsparameter definiert werden, mit denen eine Demonstration von Anwendungsfällen durchgeführt werden kann.

Die notwendigen Programmierarbeiten wurden umgesetzt und somit ein Demonstrator für die generische Energiekennzahlenbildung erzeugt. EnEffCo® ist nun befähigt, Definitionen zu Anlagen und definierten Anlagensystemen zu hinterlegen und deren Zusammenhänge zu beschreiben. Diese Informationen werden unabhängig von der jeweiligen Methode der Kennzahlenbildung definiert und gespeichert. Das System kann beliebig komplex sein. Modelle zur Berechnung von Kennzahlen können auf diese Systemdefinition und den zugeordneten Daten zugreifen und je nach Zielsetzung die Kennzahlen erzeugen bzw. Werte berechnen, die wiederum zu Kennzahlen aggregiert werden können. Die Modelle beziehen ihre Informationen aus den System- bzw. Anlagendefinitionen. Die Abbildung der Anlagensysteme und deren Datenstrukturen erfolgt im Definitionsbereich von EnEffCo®. Auswertungen der Ergebnisse sind dann im bestehenden Auswertungs- und Dashboardbereich möglich.

Add-On Service Definition

Name: UD_130_HEP_OPTframework_Modell

Aktiv: ☒

Vorlagenname: UD_HEP_OPTframe_tmpl_new

Mandant:

Benutzer: EnEffCoSystemAdmin

Zugeordnete Anlage (Drag & Drop Anlage von Liste auf der linken Seite)

Einstellungen zum Ausführungs-Rhythmus

Name der Gruppe: (default)

Wiederholung: Täglich

Tägliche Ausführungszeit: 05:00

Intervall: 1

Jetzt ausführen

Konfigurierung

Name	Wert	Typ	Regel	Kommentar
InstallationCode	UD_HEP.EKG.MH0m	Text	Optional	Hierarchical code of the installation which is the entry point of the optim
WriteLog	☐	Bool	Required	True / False
Timezone	W. Europe Standard Time	Text	Optional	Timezone for the entered dates.
MipGap	1E-05	Double	Optional	Relative mip gap
TimeLimit	3600	Int	Optional	Time limit in seconds (integer)
Sleep	30	Int	Optional	Sleep between runs (for multiple runs)

Logbuch

Abbildung 2.43: Definition der Ausführungsparameter des Energiekennzahlengenerators.

Ein typisches Energiekennzahlenmodell, wie in AP3.4 analysiert, besteht aus Systemkomponenten (Abbildung von Einzelsystemen zur Erzeugung, Wandlung, Speicherung oder Verbrauch), Modellierungsbedingungen (zusätzliche Restriktionen wie Temperaturgrenzen, Einflussfaktoren auf das Energiekennzahlenmodell und Bewertungsparameter, Umrechnungsfaktoren z.B. zur Abbildung des Kühlturms als Energiespeicher), Systembilanzen (typischerweise Energieflüsse zwischen den Komponenten und externen/internen Aufwänden und Nutzen) sowie Variablen, die wählbare Zustände oder daraus resultierende Systemeffekte darstellen. All diese Beziehungen werden mittels Eigenschaften bzw. Attributen konfiguriert (z.B. Einführung von Kosten für Energieflüsse bzw. Penalties bei Überschreitungen oder auch Effizienzfaktoren bei Energieumwandlungen). Jeder Anlagenkomponente werden Eigenschaften und Konfigurationsmöglichkeiten zugeordnet. In die Konfiguration können auch vorausgegangene Berechnungen als Restriktionen oder aber Startwerte hinterlegt werden, z.B. können Koeffizienten durch Parametrierungsalgorithmen aus der Zustandsmodellierung dynamisch und kontinuierlich berechnet und verwendet werden.

Zusammenfassung der Arbeiten je Partner

ÖKOTEC (Leitung):

- Ableitung eines softwarebasierten Konzepts für den Kennzahlengenerator aus den definierten Anforderungen der erweiterten Kennzahlensystematik
- Literaturrecherche zur Erweiterung der Lösungsansätze um KI-gestützte Methoden
- Konzeptionierung erster Ansätze für Softwarearchitektur und für generischen Kennzahlengenerator
- Programmierarbeiten zur Entwicklung des Energiekennzahlengenerators
- Testen der Modellierung (Simulation und Optimierung) mit dem Energiekennzahlengenerator auf Basis der Modellparametrierung aus AP 3.4 und dem Datenmodell der Kälteverbundanlage

GreenDelta:

- Identifizierung der bestgeeigneten Methode zur Bewertung der Ressourceneffizienz auf der Grundlage festgelegter Kriterien (u. a. Ressourcenabdeckung, Datenverfügbarkeit, Zuverlässigkeit)

- Koordination mit ÖKOTEC für die Einarbeitung der Grundlagen für die Bewertung der Ressourceneffizienz im Kennzahlensystem
- Untersuchung der Umsetzung des Indikators im Kennzahlensystem

EJOT:

- Bereitstellung maschinenbezogener Energiedaten aus der Produktion

atlan-tec:

- Anpassungen der Kennzahlensystematik
- Auswahl von Methoden zur zeitlichen Zuordnung von Daten aus kontinuierlichen Prozessen
- Implementierung einer Datenbank für Daten aus Batch- und kontinuierlichen Prozessen

2.3.6. Arbeitspaket 3.6: Entwicklung von selbstlernenden Algorithmen zur KI-gestützten Messdatenauswertung

Ziel des AP 3.6 war es, energetisch relevante Produktionsdaten zu erfassen und eine automatische Auswertung durchzuführen, welche Betriebszustände, Regelungsstrategien und Schichtmodelle vorhersagen kann. Die Auswertung soll mithilfe von ML-Algorithmen erfolgen. Zusätzlich soll im Vorfeld eine Plausibilitätsprüfung der Messdaten vorgenommen werden.

Die Messdatenaufnahme findet zum einen in der ETA-Fabrik statt sowie zu einem späteren Zeitpunkt bei Bosch im Werk Schweinfurth (Bosch Rexroth AG). Dazu wurde eine Cumulocity IoT Instanz an der ETA-Fabrik installiert, welche über die gängigen Protokolle (OPC UA und MQTT) Produktionsdaten erhalten kann. Ausgewählt zur Analyse der Produktionsdaten wurden die Werkzeugmaschinen, die sich derzeit in der ETA-Fabrik befinden (EMAG VLC 100 GT, EMAG VLC 100 Y).

In einem Workshop zur Definition der Anforderungen an die Datenbank (MS 3.6.1) wurde mit PTW und Bosch vereinbart, dass möglichst alle Daten über OPC UA erfasst und über Cumulocity in den DataHub exportiert werden sollen. Neben den Messdaten sollen ebenfalls die Metadaten der Produktionsmaschinen (z. B. Herstellername) erfasst werden. Bei dem DataHub handelt es sich um eine Datenbank, welcher exportierte Cumulocity-Daten in einem Dateiserver (NAS = netzgebundener Speicher) archiviert. Der Zugriff kann mithilfe des Dremio-Clients durch SQL-Abfragen erfolgen (siehe Abbildung 2.44). Entsprechend soll auch der Zugriff durch andere Arbeitspakete auf die Datenbank gewährleistet werden.




Abbildung 2.44: Darstellung der Produktionsdatenspeicherung in der Cumulocity IoT Edge.

Als Grundlage der Arbeiten zur Vorhersage der Maschinenzustände wurde eine am PTW im Vorfeld durchgeführte Masterarbeit verwendet, die anhand des Leistungsbedarfs drei Maschinenzustände mittels ML-Algorithmen erkennen kann. In einer durch die Software AG betreute Bachelorarbeit wurde diese Idee dahingehend erweitert, dass nun bis zu fünf Zustände an zwei Maschinen erkannt werden. Außerdem wurde die Erkennungsrate verbessert und ein flexibles Zeitfenster gewählt, sodass die Maschinenzustände in deutlich weniger als einer Minute anstatt der ursprünglichen 15 Minuten erkannt werden. Das ML-Modell wurde im PMML-Standard exportiert und kann direkt in der am PTW installierten IoT-Plattform Cumulocity verwendet werden. In einer Projektarbeit wurden die Python-Skripte in die Cumulocity eigene Notation umgeschrieben, so dass man nun die Modelle auch direkt in der IoT-Plattform ausführen kann, was zu einer schnellen Erkennung und Visualisierung der Zustände führt.

Mithilfe des vom PTW konzipierten ML-Services, wird der aktuelle Maschinenzustand bestimmt, der dann im Dashboard angezeigt wird. Diese werden durch die Kreise in der oberen Mitte in Abbildung 2.45 symbolisiert. Im unteren Teil Abbildung 2.45 von sieht man die zeitliche Abfolge der Zustandswechsel und im Kuchendiagrammen die Häufigkeit der einzelnen Zustände in bestimmten Intervallen.



Abbildung 2.45: Cumulocity Dashboard zur Visualisierung der Maschinenzustände.

Zusätzlich wurde auch nach Absprache zwischen der Software AG und dem PTW ein Vorschlagswesen zur Energieoptimierung implementiert, das Empfehlungen dazu ausgibt, welche Komponenten abgeschaltet oder in einen anderen Zustand versetzt werden können.

Seitens PTW wurde der Service zur Erkennung unterschiedlicher Maschinenzustände an Werkzeugmaschinen um die automatische Identifikation von Prozessabläufen an Einkammer-Reinigungsanlagen erweitert. Weiterhin ermöglicht der Service den Energiebedarf und die Betriebszeiten der automatisch identifizierten Zustände und Prozesse innerhalb des Messzeitraums auf längere Zeiträume zu extrapolieren. Der Erkennungsservice kann somit als Werkzeug zur Abschätzung potenzieller Energieeinsparungen genutzt werden.

Aufbauend auf dem Ziel der Generalisierung wurde das durch die OPC Foundation erstellte OPC-UA Informationsmodell mit Fokus auf Energie analysiert. Im Ergebnis ist das seit August 2022 vorliegende Modell geeignet die relevanten Zustandsdaten zu ermitteln und den Cumulocity Microservice als Basis zu nehmen. Jedoch ist bei den meisten Bestandsmaschinen eine Nachrüstung der dafür benötigten OPC UA Server technisch schwer realisierbar und zumindest wirtschaftlich nicht abbildbar. Falls es durch eine nicht kompatible Einstellung des OPC-Servers an der Maschine zu einer Fehlfunktion kommt, ist zur Gewährleistung der Synchronisierung der Messdatenverarbeitung und -bewertung (Beobachtbarkeit) eine Erweiterung der SPS-Funktionalität erstellt worden. Somit kann im NC-Code mittels M-Funktionen direkt der Maschinenzustand eingestellt werden. Für Werkzeugmaschinen ist prinzipiell der NC-Code als eine der zentralen Sollwertvorgaben geeignet, der die nötigen Zustände und Informationen bereitstellt. Bei der Implementierung auf Basis eines Zustandsautomaten wurde auf die Einhaltung von sinnvollen Transitionen geachtet und eine Abhängigkeit von den Maschinenzuständen eingearbeitet.

Zusammenfassen kann festgestellt werden, dass nun sicher wirksame Methoden zur Zustandserkennung von Werkzeugmaschinen oder Maschinen mit SPS vorliegen.

Zusammenfassung der Arbeiten je Partner

Software AG (Leitung):

- Durchführung des Workshops zur Definition von Anforderungen an die Datenbank
- Anwendung bereits entwickelter und neuer ML-Modellen zur Erkennung von Maschinenzuständen. Die Maschinenzustände und -übergänge wurden in einem Dashboard visualisiert.
- Das Vorschlagswesen wurde in Cumulocity als Dashboard integriert

Bosch:

- Unterstützung bei der Definition von Maschinenzustände
- Abgleich der Maschinenzustände an Werkzeugmaschinen mit den weiter genutzten Petri-Netzen
- Analyse von Informationsmodellen und Erweiterung einer Bestandsmaschine für die Gewährleistung der Synchronisierung der Messdatenverarbeitung und -bewertung

PTW:

- Aufnahme von Messdaten innerhalb der Produktionswoche in der ETA-Fabrik
- Erarbeitung eines Konzepts zur automatisierten Erkennung von Maschinenzuständen durch Algorithmen des maschinellen Lernens
- Unterstützung bei Anwendung von Algorithmen zur Erkennung von Maschinenzuständen
- Service zur automatischen Erkennung eingesetzter Betriebsstrategien, Schätzung jährlicher Betriebszeiten in Python implementiert und validiert
- Lieferung der Wissensbasis für das Vorschlagswesen zur Energieoptimierung

2.3.7. Arbeitspaket 3.7: Aufbau eines ganzheitlichen Expertensystems zur Messstellenplanung

Ergebnisse von dritter Seite

Eine umfangreiche Literaturrecherche, welche in [96] veröffentlicht wurde, stellte zahlreiche Ansätze zur Energiebedarfsmodellierung gegenüber. Jedoch werden diese nicht in praxistaugliche Messstellenkonzepte überführt. Zudem sind bisherige empirische Modellierungsansätze ausnahmslos inkompatibel mit industriellen Fertigungsmaschinen ohne Datenschnittstelle, was den Transfer in die Industrie stark hemmt.

Arbeitsergebnisse

In diesem AP wird ein Expertensystem zur Messstellenplanung entwickelt, welches eine Umsetzung der in den vorhergehenden APs entwickelten Lösungen unterstützt und ausführlich in [96] beschrieben ist. Hierfür werden die Ergebnisse aus TP 3 aufgegriffen und in ein hybrides Energiemessstellenkonzept überführt, welches physische und virtuelle Energiemessstellen kombiniert einsetzt, um die Energieflustransparenz insbesondere auf Maschinen- und Komponentenebene signifikant und kosteneffizient verbessert.

Das hybride Energiemessstellenkonzepts ist nach dem methodischen Vorgehen des CRIPS-ML(Q) aufgebaut und ist in Abbildung 2.36 dargestellt. Die Umsetzung der jeweiligen Phase des CRISP-ML(Q) erfolgt unter Berücksichtigung typischer Umsetzungshemmnisse, wie einer unzureichenden Datenverfügbarkeit auf Maschinenebene, und beschränkt sich auf Fertigungssysteme der Massen-, Serien- und Variantenfertigung.

In der Phase des *Geschäfts- und Datenverständnis* werden die Ziele des Unternehmens für die Strategiefelder des betrieblichen Energiemanagements definiert und die Verbraucher werden nach energetischer Relevanz priorisiert, wofür das in AP 3.1 entwickelte Schaltplantooll genutzt wird. Danach folgt eine mobile *Datenerfassung* von Energie-, LED-Zustands- und Steuerungssignalen, welche zeitsynchron über einen mehrtägigen Zeitraum aufgezeichnet werden. Bei der Installation des Energiemessgeräts im Schaltschrank können die Assistenzsysteme aus AP 3.2 genutzt werden. Um die Status-LEDs der analogen und digitalen Ein- und Ausgangsmodule der SPS abzufilmen, und in boolesche Zustandssignale umzuwandeln, kommt- das *ETA-Edge-Lense* zum Einsatz (siehe AP 3.4). Hierdurch können zahlreiche maschineninterne Signale, wie beispielsweise die Betriebszustände sämtlicher von der SPS geregelter Aggregate, erfasst und aufgezeichnet werden. Dies ermöglicht die Skalierung des Konzepts auf Fertigungsmaschinen, die steuerungsseitig über keine Datenschnittstelle verfügen.

Die Phasen der *Datenvorverarbeitung*, *Modellbildung* und *Evaluation* wurden automatisiert über ein AutoML-Verfahren umgesetzt. Falls die Genauigkeit des antrainierten Modells den vorab definierten Datenqualitätsanforderungen entspricht, erfolgt die kommunikationstechnische Freigabe der relevanten Modelleingangsgrößen über die Steuerung oder über ein Edge-Gerät, welches mit der Steuerung verbundenen ist. Innerhalb weniger Sekunden berechnet die echtzeitnahe *Anwendung* der virtuellen Energiemessstellenmodelle eine oder mehrere Zielgrößen aus den bereitgestellten Modelleingangsgrößen.

Damit die Validität der virtuellen Energiemessstellen während der Nutzungsdauer sichergestellt ist, wird deren Prognosegüte im Rahmen der *Überwachungs- und Wartungsphase* zyklisch evaluiert. Hierbei wird die Änderung des geschätzten Prognosefehlers je Fertigungsmaschine über die Messwerte eines physischen Sensors, welcher auf Produktionslinienebene installiert ist, berechnet. Mithilfe dieser Kennzahl kann der Concept Drift eines virtuellen Energiemessstellenmodells frühzeitig erkannt und einzelnen Maschinen zugeordnet werden. Somit können Energieverantwortliche beispielsweise Anpassungen des Fertigungsprozesses, welche nicht im Trainingsdatensatz abgebildet wurden und die Modellierungsgüte negativ beeinträchtigen, rechtzeitig erkennen und das betroffene virtuelle Energiemessstellenmodell nachtrainieren.




Abbildung 2.46: Programmbaufplan des hybriden Messstellenkonzepts mit den dazugehörigen Phasen des CRISP-ML(Q) in grün mit regulärem und korrekktivem Prozessablauf, dargestellt als durchgezogener bzw. gestrichelter Pfeil [96].

Die Evaluation des Konzepts zur *Sicherstellung der Langzeitvalidität* ermöglicht eine frühzeitige Identifikation eines Concept Drifts, indem die Änderung des geschätzten Prognosefehlers je Maschine zyklisch berechnet und überwacht wird. Somit kann die Validität der virtuellen Energiemessstellen über deren Nutzungsdauer gewährleistet werden. Ferner erleichtert die Reduktion der Komplexität auf eine Kennzahl mit deren grafischer Datenaufbereitung die Nachvollziehbarkeit der Modellüberwachung und die Vermittelbarkeit des Konzepts.

Um das *Kostenreduktionspotenzial* zu bewerten, werden die Kostenbestandteile eines physischen und virtuellen Energiemessstellenkonzeptes quantifiziert und verglichen. Hierfür wurde u. a. eine Marktstudie zu den Einkaufskosten physischer Energiemesstechnik durchgeführt und eine detaillierte Auflistung erforderlicher Arbeitsschritte zur Bestimmung der erforderlichen Personalkosten erstellt. Die Implementierungskosten des Energiemessstellenkonzeptes der fünf Fertigungsmaschinen der ETA-Prozesskette inklusive der energieintensivsten Komponenten, lassen sich durch den Einsatz virtueller Energiemessstellen, verglichen mit den Kosten eines physischen Energiemonitorings auf Komponentenebene, um 66,3 % reduzieren. Bei einem reinen Monitoring auf Maschinenebene ergibt sich eine Reduktion der Implementierungskosten von 41,5 %. Hinsichtlich des Break-Even-Points der nutzungsdauerbezogenen Kosten, beträgt die Mindestnutzungsdauer der virtuellen Energiemessstellen bei reinem Monitoring auf Maschinenebene 724 Tage (1,98 Jahre) und bei Einbeziehung der Komponentenebene 309 Tage (0,85 Jahre). Falls die Validität einer virtuellen Energiemessstelle nicht über diesen Zeitraum aufrechterhalten werden kann, sind physische Energiezähler zu bevorzugen.




Abbildung 2.47: Gegenüberstellung der Implementierungskosten eines virtuellen bzw. physischen Energiemessstellensystems auf Maschinenebene (links) sowie auf Maschinen- und Komponentenebene (rechts) über der Anzahl jährlich vermessener Maschinen [96] .

Da das in diesem Arbeitspaket erarbeitete Energiemessstellenkonzept, Energiedaten in ein Energiemanagementsystem einspeist, können diese Daten u.a. zur Kennzahlberechnung genutzt werden. Somit lassen sich auch die Ergebnisse von AP 3.5 aufgegriffen und integrieren.

Partnerspezifische Übersicht der Arbeiten

PTW (Leitung):

- Konzeption eines hybriden Messstellenkonzeptes, welches Vorschläge für Energiemessstellen unter Berücksichtigung der Vorarbeiten in TP 3 generiert
- Umsetzung und Erprobung des Messstellenvorschlagsystems an den Fertigungsmaschinen der ETA-Fabrik
- Durchführung von Marktstudie zu den Einkaufskosten physischer Energiemesstechnik
- Evaluation des wirtschaftlichen Einsparpotenzials des hybriden Energiemessstellensystems mit physischen Energiemessstellensystemen, welche stationär installierte Sensorik verwenden

atlan-tec:

- Zusammenstellung von Anforderungen an virtuelle Sensoren in der Prozessindustrie

2.4. Teilprojekt 4: Datenbasierte Modellerstellung, -parametrierung & Auswertung

Um ein Fabrikssystem energetisch optimal zu betreiben, sind zum einen Modelle für Condition Monitoring und Predictive Maintenance der Produktionsmaschinen erforderlich. Zum anderen müssen kontinuierlich Ineffizienzen im System aufgedeckt und durch geeignete Maßnahmen behoben werden. Weiterhin sind Simulations- oder Prognosemodelle der einzelnen Erzeuger und Verbraucher eine essenzielle Grundlage, um ein Fabrikssystem energetisch zu optimieren. Simulationsmodelle können verwendet werden, wenn die Datenbasis für die Prognose nicht ausreichend ist. Sie bieten eine gute Möglichkeit zur Abschätzung von Energieverbräuchen. Aus diesem Grund wird in diesem Teilprojekt sowohl die Erstellung von Condition Monitoring und Predictive Maintenance Modellen als auch die Parametrierung von Simulationsmodellen anhand von Messdaten sowie die automatische Erstellung von Prognosemodellen betrachtet. Um die Potenziale von Lastprognosen für verschiedene Optimierungsanwendungen auch in der Industrie auszuschöpfen, soll in diesem Teilprojekt eine Anwendung entwickelt werden, welche es dem Nutzer erlaubt, Lastprognosen (elektrisch, thermisch, pneumatisch, chemisch) einfach und automatisiert für verschiedene Systemgrenzen und Prognosehorizonte ohne erforderliches Expertenwissen im Bereich Data Science zu erstellen.




Abbildung 2.48: Messdatenerfassung und Modellbildung für die Nutzung von KI-basierten Methoden.

Hierfür wird in AP 4.1 zunächst ein Datenvorverarbeitungsmodul entwickelt, welches die in der Datenbank gespeicherten Daten automatisch für weitere Datenverarbeitungsschritte vorbereitet, sodass diese zur Modellerstellung verwendet werden können. In AP 4.2 wird eine Anwendung entwickelt, welche es Anwendern ermöglicht einfach und intuitiv für verschiedene Systeme Lastprognosen für verschiedene Prognosehorizonte zu erstellen. Hierbei wird auf AutoML Verfahren zurückgegriffen, welche die Auswahl der Algorithmen zur Datenvorverarbeitung und Prognose sowie dessen Parametrierung durch eine intelligente Vorauswahl auf Basis von bereits entwickelten Modellen für verschiedene Systeme vereinfacht. Im AP 4.3 wird ein Framework entwickelt, welches es erlaubt, automatisiert die Parametrierung von Simulationsmodellen anhand von Messdaten vorzunehmen. In AP 4.4 wird ein KI-gestütztes Vorschlagswesen aufgebaut, welches automatisiert Energieeffizienzpotenziale sowie die Maßnahmen anhand von bereits untersuchten Datensätzen vorschlägt. In AP 4.5 werden Modelle zur Zustandsüberwachung und der prädiktiven Wartung erstellt und in AP 4.6 wird die Übertragbarkeit von Modellen auf ähnliche Anwendungsfälle untersucht. Somit wird es beispielsweise möglich, dass vorkonfigurierte und angelernte Modelle, die vom Maschinenhersteller mitgeliefert werden, auf andere Maschinen übertragen werden.

Tabelle 2.4: Arbeitspakete in Teilprojekt 4.

Datenbasierte Modellerstellung, -parametrierung & Auswertung		Beteiligte Partner
Teilprojektleitung: PTW		
AP 4.1	Entwicklung eines Datenvorverarbeitungs-Moduls	PTW, DFKI, etalytics
AP 4.2	Aufbau eines automatisierten Prognoseframeworks mittels Auto-Machine Learning zur Lastprognose und Datenvorverarbeitung	PTW, DFKI, Entega, EJOT, etalytics
AP 4.3	Datenbasierte Simulationsmodell-Parametrierung	PTW, DFKI
AP 4.4	KI-gestütztes Vorschlagswesen für Energieeffizienzmaßnahmen	PTW, Evonik, etalytics
AP 4.5	Condition Monitoring und Predictive Maintenance als Mehrwert für Energiedatenerhebung	EJOT, DFKI, Bosch, etalytics, ÖKOTEC
AP 4.6	Übertragbarkeit von datenbasierten Modellen über Transfer Learning	DFKI, Bosch, EJOT

2.4.1. Arbeitspaket 4.1: Entwicklung eines Datenvorverarbeitungs-Moduls

Als Basis für das AP 4.1 und 4.2 wurden im Zeitraum vom 27.10. bis zum 27.12.2021 Versuche zur Datengenerierung am Produktionssystem der ETA-Fabrik durchgeführt. Dabei kamen die beiden Werkzeugmaschinen, die beiden Reinigungsmaschinen, der Härteofen sowie die erforderliche Versorgungstechnik zum Einsatz.

Ziel des AP 4.1 ist die Entwicklung eines Datenvorverarbeitungsmoduls, welches Rohdaten für nachgelagerte Machine-Learning-Anwendungen nutzbar macht. Das Datenvorverarbeitungsmodul wurde am Anwendungsfall der Lastprognose entwickelt, welcher in AP 4.2 näher vorgestellt wird. Die Algorithmen und das Vorgehen sind allerdings auf weitere Regressions-Lernaufgaben übertragbar.

Zur Vorbereitung des Datenvorverarbeitungsmoduls wurden zunächst auf Basis der Vorarbeiten aus früheren Projekten (PHI-Factory, SynErgie) geeignete Datenvorverarbeitungs-Algorithmen ausgewählt und mit den KI-Experten des DFKI abgestimmt. Die Algorithmen orientieren sich am Cross-Industry Standard Process for Machine Learning (CRISP-ML) zur Erstellung von Machine-Learning-Modellen und bilden folgende Phasen der Datenvorverarbeitung ab:

- Datenbereinigung
 - Ausreißer
 - Fehlende Werte
- Skalieren und Normalisieren
- Feature Engineering
- Feature-Auswahl

Eine Aneinanderreihung spezifischer Algorithmen aus diesen Bereichen, üblicherweise in der gezeigten Reihenfolge, bildet die sogenannte Datenvorverarbeitungs-Pipeline. Diese wird von den Rohdaten durchlaufen, bevor sie im Lernalgorithmus für die eigentliche Lernaufgabe eingesetzt werden können. Teile oder die Gesamtheit der Datenvorverarbeitungs-Pipeline können variable Parameter enthalten, die im Rahmen des Hyperparameter-Tunings zusammen mit den Modell-Hyperparametern des Lern-

Algorithmus optimiert werden. Die Datenvorverarbeitungspipeline wurde als eigene Klasse nach dem Vorbild der weitverbreiteten *scikit-learn (sklearn)*-Pipeline umgesetzt. Die implementierten Algorithmen für die genannten Phasen sind in Tabelle 2.5 aufgelistet.

Tabelle 2.5: Liste der geeigneten Datenvorverarbeitungsalgorithmen nach Datenverarbeitungsphase.

Phase	Algorithmen
Datenbereinigung: Ausreißer	• Hampel-Filter
Datenbereinigung: Fehlende Werte	• Entferne Features mit mehr als X % fehlenden Werten • Fehlende Werte ersetzen: ○ Fester Wert (Mittelwert, Median) ○ Dynamischer Wert (letzter Wert, nächster Wert, Interpolierung) • Kalman Filter • K Nearest Neighbors Imputer
Skalieren und Normalisieren	• StandardScaler (Mittelwert=0 und Standardabweichung=1) • RobustScaler (Median=0 und Quartile=1) • MinMaxScaler (Fester Bereich) • MaxAbsScaler (Skalierung mit Maximalwert) • Normalizer (Normalisierung mit L1/L2-Norm)
Feature Engineering	• Polynomielle Features • Zeitverschobene Features • Rollierender Mittelwert/Standardabweichung • Kalender-Features • Ableitung • Aufteilung in Trend, Saisonalität, Rauschen • Fourier-Transformation • Auto-Klassifikation • Convolutional Neural Network
Feature-Auswahl	• Modell-basiert (Feature-Wichtigkeits-Score oder rekursive Feature-Eliminierung) • Kennzahl-basiert: ○ Varianz ○ Variance Inflation Factor ○ Pearson Korrelation • Principal Component Analysis

Neben der Erstellung und Wartung der Algorithmen für die Datenvorverarbeitung in Python innerhalb der Preprocessor Klasse, wurde die Datenvorverarbeitung innerhalb eines neuronalen Netzes näher untersucht. Durch die Integration der Datenvorverarbeitung innerhalb eines neuronalen Netzes lassen sich kompakte und schnell ausführbare Datenverarbeitungspipelines bilden. Hierzu wurden zunächst die im Folgenden aufgelisteten Verarbeitungsschritte für die Untersuchung ausgewählt:

- SimpleImputer (bereitgestellt von scikit-learn)
- KNNImputer (bereitgestellt von scikit-learn)
- MinMaxScaler (bereitgestellt von scikit-learn)
- StandardScaler (bereitgestellt von scikit-learn)
- Normalizer (bereitgestellt von scikit-learn, layer Variante bereitgestellt von Keras)
- HampelOutlierFilter (bereitgestellt von ETA)
- CyclicDateTimeFeatures (implementiert auf Basis von [97])
- PolynomialFeatures (bereitgestellt von scikit-learn)
- SelectFromModel (bereitgestellt von scikit-learn)

Zur Evaluierung der Versuche wurden zwei Baselines auf Basis der zwei Neuronaler Architektur Suche (NAS) Algorithmen TinyEvo und AutoKeras (siehe AP 4.2) ohne Datenvorverarbeitung für den Anwendungsfall der Lastprognose der Fußbodenheizung in der ETA-Fabrik umgesetzt. Bei der Versuchsdurchführung wurden verschiedene Kombinationen der oben aufgelisteten Vorverarbeitungsschritte in Kombination mit den zwei NAS-Algorithmen anhand der Metriken Mean Absolut Error (MAE) und Mean Squared Error (MSE) evaluiert. Weiterhin wurde die Umsetzbarkeit als integrierte Preprocessing-Layer im neuronalen Netz bewertet.

Die besten Ergebnisse haben die Kombination von KNNImputer, DatetimeFeatures, PolynomialFeatures, MinMaxScaler und SelectFromModel mit dem TinyEvo erzielt (Best MAE 0,019; -53,4% ggü. Baseline). Diese Kombination ist jedoch nicht als integrierte Preprocessing-Layer umsetzbar (KNNImputer als lokale Methode und SelectFromModel können nicht umgesetzt werden). Die beste umsetzbare Kombination besteht aus SimpleImputer, DatetimeFeatures und MinMaxScaler mit dem TinyEvo, wobei die DatetimeFeatures nur einen sehr geringen Mehrwert bieten (Best MAE: 0,021; -48,8% ggü. Baseline). Weiterhin haben die Ergebnisse gezeigt, dass der TinyEvo generell besser abschneidet als AutoKeras, insbesondere bei weniger Data Preprocessing. Grund dafür ist, dass komplexere Schichten ausgewählt wurden (Gated Recurrent Units (GRU)), während bei AutoKeras nur Dense Layers genutzt werden können. Daher kann TinyEvo ohne zusätzliches Feature Engineering bereits sehr gute Prognosegüten erreichen.

Zusammenfassend haben die Versuche folgendes ergeben. Die Kombination von einfachem Preprocessing mit einem komplexen neuronalen Netz (GRU-Schichten) zeigt eine der besten Prognosegüten. Zusätzliches grundlegendes Feature Engineering (Polynom-Features, Datetime-Features) kann die Güte nicht signifikant verbessern, macht die Datenverarbeitungs-Pipeline aber deutlich komplexer.

Zusätzlich wurde der Einfluss der Konvertierung von Modellen zu ONNX auf die Inferenzzeit untersucht. Zum Vergleich der Inferenzzeit wurden SimpleImputer und MinMaxScaler als Preprocessing-Methoden verwendet und als integrierte Layer mit einer vorgelagerten sklearn-Pipeline verglichen. Als Estimator wurde jeweils das gleiche Netz verwendet. Grundsätzlich ist die Konvertierung von neuronalen Netzen mit integriertem Preprocessing zu ONNX etwas einfacher als die zusätzliche Konvertierung einer Preprocessing-Pipeline. Die Ergebnisse zeigen, dass ONNX-Modelle deutlich geringere Inferenzzeiten haben und weniger Arbeitsspeicher benötigen als nicht konvertierte Modelle. Daher ist die einfache Konvertierbarkeit durch integriertes Preprocessing eine wichtige Modelleigenschaft. Im Vergleich zwischen integriertem Preprocessing und sklearn-Pipeline schneidet die sklearn-Pipeline etwas besser ab (etwas schnellere Inferenz, gleicher RAM-Bedarf).

Zusammenfassung der Arbeiten je Partner

PTW(Leitung):

- Durchführung von Versuchsreihen zur Datengenerierung
- Sammlung geeigneter Datenvorverarbeitungs-Algorithmen und Abstimmung mit dem DFKI
- Teilweise Umsetzung der ausgewählten Algorithmen in der etaML-lib, einer für diesen Themenbereich selbst entwickelten Python-Bibliothek
- Versuchsdurchführung zur Evaluierung der Datenvorverarbeitung innerhalb eines neuronalen Netzes
- Evaluierung der Inferenzzeit bei ONNX Konvertierung

DFKI:

- Beratung bei der Auswahl von Methoden und Kenngrößen für das Datenvorverarbeitungsmodul

etalytics:

- Implementierung und kontinuierliche Weiterentwicklung einer Preprocessor-Klasse als Erweiterung der klassischen sklearn Pipeline
- Mitwirkung an der Entwicklung und Wartung der spezifischen Datenvorverarbeitungsmodule, einschließlich der Definition von Methoden zur effektiven Verarbeitung von Eingangsdaten für Machine Learning-Modelle
- Spezifikation von Anforderungen der Endnutzer an die Datenvorverarbeitung innerhalb einer smarten Energiemanagementplattform
- Weiterentwicklung und Anpassung des bestehenden Systemidentifikationstools, um es als Erweiterung des sklearn Pipeline Standards für die spezifischen Anforderungen des Projekts einzusetzen, mit Fokus auf die definierten Benutzeranforderungen
- Unterstützung bei der praktischen Implementierung und Testung von Datenverarbeitungsmethoden

2.4.2. Arbeitspaket 4.2: Aufbau eines automatisierten Prognoseframeworks mittels Auto-Machine Learning zur Lastprognose und Datenvorverarbeitung

Ziel dieses Arbeitspakets ist die Entwicklung eines Verfahrens zur automatisierten Generierung von ML-Pipelines für Prognosefragestellungen im industriellen Kontext. Durch den Einsatz von AutoML-Methoden wird die Erstellung datenbasierter Prognosemodelle teilautomatisiert, wobei Algorithmen mit der besten Prognosegüte ausgewählt werden. Im Gegensatz zu bestehenden AutoML-Frameworks wird nicht nur die Modellerstellung, sondern der gesamte ML-Prozess optimiert. Das Verfahren wird speziell für industrielle Energiesysteme ausgelegt und unterstützt Anwendungen wie die Vermeidung von Lastspitzen und die Betriebsoptimierung von Anlagen.

Dazu wurden zunächst Versuche zur Datengenerierung in der ETA-Fabrik durchgeführt. Um diese Daten im Rahmen des Arbeitspakets 4.2 nutzen zu können, wurden die erfassten Daten analysiert und aufbereitet. Dazu wurden die Daten einer Datenqualitätsverifizierung unterzogen. Im Rahmen dessen wurden statistische Eigenschaften der erfassten Informationen sowie die Anzahl der fehlenden Werte ermittelt. Im ersten Schritt wurden für die weitere Verarbeitung alle Features ausgeschlossen, die mehr

als 10 Prozent fehlende Werte hatten oder eine Standardabweichung von 0 aufwiesen. Im nächsten Schritt wurden die Minimal- und Maximalwerte der einzelnen Features betrachtet und fehlerhafte Datensätze ausgeschlossen. Weiterhin wurden die erfassten Daten auf Ausreißer mit der Median Absolute Deviation (MAD) Methode untersucht und falls vorhanden ausgeschlossen. Die verbleibenden fehlenden Werte wurden im letzten Schritt imputiert. Bei der Berechnung der fehlenden Werte wurde für die einzelnen Systemgrenzen unterschiedlich vorgegangen. Für die Datensätze der Produktionsmaschinen wurden die fehlenden Werte mit dem Median des jeweiligen Features in Abhängigkeit des jeweils vorliegenden Zustandes der Maschine (*off*, *standby*, *operational* und *working*) ersetzt. Für das Produktionssystem wurden die Datensätze wochenweise analysiert und die fehlenden Werte in Abhängigkeit des Typs der Information ersetzt. Für Features des Typs Bool wurden die fehlenden Werte mit dem Median des jeweiligen Features ersetzt. Für die verbleibenden Features wurden die fehlenden Werte interpoliert. Die fehlenden Werte des Regressanten (die elektrische Leistung der Maschinen oder des Produktionssystems) wurden nicht imputiert. In diesem Fall wurden die Zeilen mit fehlenden Werten gelöscht. In einem weiteren Schritt wurde die Konsistenz der Lastzeitreihen geprüft. Zum einen wurden die Zeitreihen auf Abweichungen zwischen verschiedenen Messpunkten geprüft (z. B. separate Messung der BHKW vs. Einspeisung am Netzanschlusspunkt in Zeitfenstern ohne Verbrauch). Zum anderen wurden Abweichungen zwischen Summenmesspunkten und den entsprechenden Einzelmessungen analysiert, um den Einfluss nicht separat gemessener Verbraucher auf die Gesamtlast abschätzen zu können.

Zur Umsetzung der Lastprognose in der ETA-Fabrik wurden zunächst Anforderungen und Voraussetzungen an das Framework aufgelistet. Tabelle 2.6 fasst diese zusammen:

Tabelle 2.6: Ermittelte Anforderungen an das Prognoseframework (vgl. [98]).

Typ	Nr.	Anforderung
Funktionale Anforderungen	FR-1	Anwendbar für komplexe, nicht-lineare, stochastische Systeme: Der Ansatz soll sich für die Vorhersage des elektrischen Stromverbrauchs von Produktionssystemen eignen Systemen, die sich aus einer Vielzahl komplexer, interagierender Maschinen und Anlagen mit teilweise nichtlinearer Dynamik sowie stochastischen Störgrößen zusammensetzen.
	FR-2	Geeignet für vielfältige Demand Response (DR) Maßnahmen: Der Ansatz sollte die Anwendung der meisten DR-Maßnahmen ermöglichen. Der Vorhersagehorizont, die Auflösung und die Häufigkeit sollten entsprechend gewählt werden.
	FR-3	Multi-Step Vorhersage: Der Ansatz sollte für die Vorhersage mehrerer Zeitschritte geeignet sein.
	FR-4	Integration von allen relevanten Informationen: Der Ansatz muss geeignet sein, um alle potenziell wertvollen Informationen zu integrieren. Erwähnenswerte Datenquellen in diesem sind der Produktionsplan und die Wettervorhersage.
	FR-5	Hierarchische Struktur: Der Ansatz sollte geeignet sein, die hierarchische Hierarchie des Energiesystems, das aus mehreren Teilsystemen (Maschinen und Anlagen).
	FR-6	Gesteigerte Nutzerfreundlichkeit durch die Nutzung von automatisiertem maschinellen Lernens (AutoML): Der Ansatz sollte AutoML-Techniken verwenden, um die Benutzerfreundlichkeit zu erhöhen und das erforderliche Fachwissen in der Datenwissenschaft zu minimieren.
	FR-7	Übertragbar: Generell sollte der Ansatz auf verschiedene Anwendungsumgebungen (verschiedene Energiesysteme oder Produktionssysteme) übertragbar sein. Maßnahmen. Daher muss der Ansatz auf verschiedene Anwendungsumgebungen, Prognosehorizonte, Auflösungen und andere Nutzenergien übertragbar sein.

	FR-8	Echtzeitfähigkeit: Die Berechnungszeit für ein Bündel von Prognosewerten aus dem entwickelten Modell in der Einsatzphase muss kleiner sein als der erste Prognosewert.
Voraussetzungen	V-1	Daten Verfügbarkeit: Wichtige Systemzustände der verschiedenen Systeme (Betriebszustände, Leistung, Temperaturen und Drücke) können durch Mess- und Regeltechnik (M&R) erfasst werden.
	V-2	Kommunikationsfähigkeit: Alle Datenpunkte können über IKT an einen digitalen Knotenpunkt (z. B. einen Computer) übertragen und dort ausgewertet werden.
	V-3	Kommunikationsleistungsfähigkeit: M&R muss für die Anforderungen geeignet sein und mit mindestens der exakten Auflösung messen, die für die Prognose benötigt wird (Prognosevorlaufzeit).
	V-4	Fertigungstyp: ML-Methoden sind nur für die Fertigungsarten der Massen- oder Serienproduktion geeignet. Eine Prognose kann nur dann auf der Grundlage eines datengesteuerten Ansatzes entwickelt werden, wenn die Produktion über einen längeren Zeitraum konstant ist.

Nach der Ermittlung der funktionalen Anforderungen wurde diese im nächsten Schritt in technische Anforderungen des zu entwickelnden Ansatzes übersetzt. Tabelle 2.7 enthält die abgeleiteten technischen Anforderungen.

Tabelle 2.7: Übersetzung der funktionalen Anforderungen in technische Anforderung des Prognose Frameworks (vgl. [98]).

Funktionale Anforderungen			Technische Anforderungen	
FR-1	Anwendbar für komplexe, nicht-lineare, stochastische Systeme		TR-1	Nutzung von ML und Deep Learning Verfahren
FR-2	Geeignet für vielfältige DR Maßnahmen		TR-2	Vorhersagehorizont von 4 Stunden mit einer Vorhersagehäufigkeit von 10 Sekunden
FR-3	Multi-step Vorhersage		TR-3	Drei Multi-output Modelle decken den Vorhersagehorizont von 4 Stunden ab
FR-4	Integration von allen relevanten Informationen		TR-4	Nutzung von Deep Learning Algorithmen
FR-5	Hierarchische Struktur		TR-5	Adaptierter Bottom-up Ansatz
FR-6	Gesteigerte Nutzerfreundlichkeit durch die Nutzung von AutoML		TR-6	Nutzung von NAS Verfahren
FR-7	Übertragbar		TR-7	Nutzung des System-Identifikations-Tools
FR-8	Echtzeitfähigkeit		TR-8	$t_{\text{Berechnung, Ausführung}} \leq 10$ Sekunden

Hinsichtlich der technischen Anforderung TR-1, wurden zunächst eine Analyse der für die Prognoseaufgabe vielversprechenden Modellarchitekturen zur automatisieren Feature Extraktion sowie für die Prognose von Zeitreihendaten durchgeführt. Dabei wurden die folgenden Algorithmen identifiziert:

- Convolutional Neural Networks (CNN) können automatisch lernen wertvolle Informationen aus Rohdaten zu identifizierten, extrahieren und ableiten. Für die Prognoseaufgabe werden eindimensionale CNNs verwendet.
- Long Short-Term Memory (LSTM) und Gated Recurrent Unit (GRU) Networks sind Arten von rekurrenten Netzen, welche automatisiert kurz- und langfristige zeitliche Abhängigkeiten in der Eingangssequenz lernen.

Hinsichtlich der technischen Anforderung TR-2 wurde zur Abdeckung von vielfältigen DR-Maßnahmen ein Prognosehorizont von 4 Stunden mit einer Vorhersaghäufigkeit von 10 Sekunden festgelegt.

Zur Erfüllung der funktionalen Anforderung der Multi-Step Prognose TR-3 gibt es fünf verschiedene Ansätze. Diese sind in zwei grundsätzliche Kategorien zu unterteilen: Methoden, die jeden Prognoseschritt als individuelles Prognoseproblem behandeln (Single Output Ansätze) oder als ein Prognoseproblem (Multi Output Ansätze). Da die Multi Output Ansätze i.d.R. besser abschneiden als die Single Output Ansätze [99], wurden sich auf die Multi Output Ansätze beschränkt. Die oben ausgewählten Algorithmen können für eine Multi-Output Prognose verwendet werden.

Da der Informationsbedarf über den Prognosehorizont von 4 Stunden nicht konstant ist, wurde der *Direct Multi-Input Multi-Output* (DIRMO) Ansatz ausgewählt. Dieser unterteilt den Prognosehorizont in multiple Teilbereiche und nutzt ein Modell für jeden Teilbereich. Daher werden zur Abdeckung des Vorhersagehorizontes von 4 Stunden drei DIRMO Modelle verwendet (siehe Tabelle 2.8). Das erste Modell deckt den Prognosehorizont von 15 Minuten ab mit einer zeitlichen Auflösung der Prognosegröße von 10 Sekunden (kurzfristiges Modell). Das zweite Modell erweitert den Prognosehorizont auf 30 Minuten mit einer zeitlichen Auflösung der Prognosegröße von dem rollierenden Durchschnitt einer Minute (mittelfristiges Modell). Das dritte Modell erweitert den Prognosehorizont auf vier Stunden reduziert dafür weiter die zeitliche Auflösung der Prognosegröße auf den rollierenden Durchschnitt von 15 Minuten (langfristiges Modell). Alle drei Modelle haben allerdings eine zeitliche Auflösung der Einflussfaktoren von 10 Sekunden, sodass ebenfalls alle 10 Sekunden ein neues Bündel an Prognosewerten für alle drei Modelle erzeugt wird.

Tabelle 2.8: Charakteristiken der entwickelten Vorhersagemodelle.

	Modell 1	Modell 2	Model 3
Vorhersagehorizont	$h = 15 \text{ min}$	$15 \text{ min} < h \leq 30 \text{ min}$	$30 \text{ min} \leq h \leq 4 \text{ h}$
Zeitliche Auflösung der Zielgröße	10 s	1 min	15 min
Zeitliche Auflösung der Vorhersage	10 s	10 s	10 s

Hinsichtlich der technischen Anforderung TR-6 wurde im Projekt eine Analyse von verschiedenen Neuronaler Architektur Suche (NAS) Algorithmen durchgeführt. Dabei wurden die folgenden Algorithmen untersucht:

- Autokeras [100]
- Enas [101]
- Neuro-Cell Based Evolution [102]
- TinyEvo [103]

Die vier Algorithmen wurden mit einer einfachen Multi-Task Lasso Regression sowie einem Random Search verglichen. Zur Evaluation wurden 5 Datensets verwendet. Abbildung 2.49 zeigt die Ergebnisse dieser Evaluation. Abbildung 2.49 zeigt, dass der TinyEvo Algorithmus in 4 der 5 Datensätze am besten abschneidet. Weiterhin wurden die vier Algorithmen hinsichtlich der Kriterien

- Güte,
- Rechendauer,

- Einfachheit der Nutzung und
- Robustheit

bewertet. Tabelle 2.9 fasst diese Bewertung zusammen. Da der TinyEvo Algorithmus am besten abschneidet, wurde dieser für die Implementierung im Prognosetool ausgewählt.




Abbildung 2.49: Vergleich des MAE der verschiedenen NAS Algorithmen für die verschiedenen Datensets [103].

Tabelle 2.9: Bewertung der NAS Algorithmen (++ sehr günstig; + günstig; - ungünstig; -- sehr ungünstig).

Algorithmus	Güte	Rechendauer	Einfachheit der Nutzung	Robustheit
TinyEvo	++	++	+	++
Autokeras	+	++	++	-
ENAS	-	+	-	-
Neuro-cell based Evolution	--	--	+	+

Weiterhin wurde im Projekt ein Vorgehen zur Integration vorliegender Informationen über die Zukunft, wie z. B. der Produktionsplan oder auch Wetterprognosen entwickelt (FR 4). Traditionelle Verfahren der Prognose erlauben es leider nicht, diese Informationen zu verwenden. Daher werden bisher in der Forschung diese Features, obwohl diese sehr wertvolle Informationen enthalten, zur Modellentwicklung nicht verwendet. Der Grund dafür liegt in der Art der Informationen. Beim Produktionsplan liegen für jede Maschine und jeden Vorhersageschritt die Information vor, welches Produkt gefertigt wird. Diese Information muss zur Verarbeitung in einem Regressionsproblems in ein Bool Feature umgewandelt werden. Für Maschinen, die zur Herstellung verschiedener Produkte m verwendet werden, ist der Produktionsplan für n Prognoseschritte in Tabelle 2.10 dargestellt. Hierbei kann pro Zeitschritt und Maschine jeweils nur ein Produkt produziert werden. Die Summe über die Zeilen (auf Maschinenebene) ist damit stets eins. Betrachtet man den Datensatz an historischen Informationen, so wird pro Zeile (Zeitschritt) n Prognoseschritte prognostiziert. Damit wird pro Zeile der historischen Daten der Produktionsplan wie in der Tabelle unten dargestellt zugeordnet. Da damit die Dimensionen der historischen und zukünftigen Informationen nicht übereinstimmen, können diese nicht problemlos

miteinander kombiniert werden. Es gäbe die Möglichkeit diese Information in einem klassischen Regressionsproblem zu integrieren, indem pro Zeitschritt und pro Produkt ein Bool Feature erzeugt wird. Dies führt allerdings mit steigender Anzahl der Vorhersageschritte und zunehmender Anzahl an Produkten sehr schnell zu einem Datensatz mit sehr vielen Bool Features, die zum größten Teil null sind. Zum Beispiel müssten bei einem Prognosehorizont von 15 Zeitschritten und 3 Produkten bereits 45 Features erzeugt werden. Dies führt zu einem Datensatz der ungeeignet für Machine Learning Probleme wird, da man dort auf Datensätze die lediglich Nullen und Einsen enthalten verzichten sollte.

Tabelle 2.10: Struktur des Produktionsplans für die Verwendung im Vorhersageproblem

	Produkt 1	Produkt 2		Produkt m
Prognoseschritt 1	1	0	0	0
Prognoseschritt 2	0	1	0	0
....	0	0	0	0
Prognoseschritt n	1	0	0	0

Um dieses Problem zu lösen, wurde das Vorgehen in Abbildung 2.50 entwickelt, dass es erlaubt diese Informationen zu integrieren. Dabei werden in einem ersten Schritt im Modelltraining die historischen Informationen und die Informationen über den Prognosehorizont getrennt. Die historischen Informationen durchlaufen dann zunächst einen Deep Learning basierten Feature Extraktions- und Transformationsprozess mittels dem diese Informationen auf die gleiche Struktur gebracht, wie der Produktionsplan. Dieser Prozess hat als Output eine bis viele (diese Anzahl gilt es zu optimieren) an neuen Matrizen mit neuen Features (sogenannte Feature Maps ζ). Die Anzahl an neu gefunden Features δ gilt es ebenfalls im Prozess zu optimieren. Die Anzahl der Zeilen der Feature Maps entspricht den Prognoseschritten des Modells h . In der gleichen Weise liegen ebenfalls die Zukunftsdaten vor. Diese haben eine beliebige Anzahl an Features φ und so viele Zeilen wie Prognoseschritte. Damit können im nächsten Schritt diese Informationen aneinandergehängt werden. Die so neu entstanden Feature Maps durchlaufen als nächsten Schritt einen weiteren Deep Learning basierten Feature Extraktionsprozess und anschließend die eigentliche Lernaufgabe. Bei der in Abbildung 2.50 unter *Modell trainieren* dargestellte Architektur handelt es sich um ein großes neuronales Netz mit verschiedenen Funktionsbereichen, die es auszugestalten gilt. Hierzu wurde im Projekt mit Hilfe der drei in TR-1 identifizierten Algorithmen drei Konzepte zur Umsetzung des Ansatzes entwickelt und evaluiert (siehe Abbildung 2.51):

- **Konzept 1:** Ein eindimensionaler CNN Layer wird in beiden Feature Extraction Stufen verwendet.
- **Konzept 2:** Eine Kombination aus einem LSTM und eindimensionalen CNN wird in der ersten Feature Extraction Stufe und ein eindeimensionales CNN in der zweiten Stufe verwendet.
- **Konzept 3:** LSTM und GRU wird in der ersten und zweiten Feature Extraction Stufe verwendet. Um mehrere Feature Maps zu verarbeiten nutzt die zweite Stufe als ersten Prozess noch ein CNN layer.

Die drei Konzepte wurden in einer Vorstudie untersucht. Da der TinyEvo Algorithmus keine CNNs enthält, wurden in der Voruntersuchung neben dem TinyEvo Algorithmus der *Neuro Cell Based Evolution* (NCBE) Algorithmus getestet. Konzept 1 und 2 wurden mit NCBE und Konzept 3 mit *Tiny Evo* evaluiert. Tabelle 2.11 enthält die Ergebnisse der Vorstudie. Aufgrund der besseren Performance von Konzept 3 mit Tiny Evo wurde dieses Konzept zur Entwicklung der Lastprognose der ETA-Fabrik ausgewählt.







Abbildung 2.50: Übersicht der Struktur zur Einbindung des Produktionsplans in das Regressionsproblem (vgl. [98]).



a: Konzept 1.



b: Konzept 2.



c: Konzept 3.

Abbildung 2.51: Entwickelte Konzepte zur Integration von Informationen über den Vorhersagehorizont (vgl. [98]).

Tabelle 2.11: Ergebnisse der Vorstudie zur Architekturauswahl (vgl. [98]).

	Train MAE (W)	Train MAE (W)
Konzept 1 & NCBE	707	808
Konzept 2 & NCBE	500	748
Konzept 3 & Tiny Evo	131	137

Hinsichtlich der technischen Anforderung TR-5, wurde ein adaptierter Bottom-up Ansatz ausgewählt, bei dem sowohl für die einzelnen Produktionsmaschinen (Hauptverbraucher) als auch das Produktionssystem ein Prognosemodell erstellt wird. Die Ergebnisse der Prognosemodelle auf Maschinenebene fließen dabei als Information über den Prognosehorizont in das Prognosemodell auf Produktionssystemebene. Abbildung 2.53 zeigt den hierarchischen Aufbau des Ansatzes. Damit wurden für die ETA-Fabrik in Summe 18 Prognosemodelle erzeugt. Ein kurzfristiges, mittelfristiges und langfristiges Modell pro Produktionsmaschine (5 Stück) und für das Produktionssystem.

Zur Sicherstellung der Übertragbarkeit TR-7 wurde das Prognoseframework flexibel hinsichtlich verschiedener Anwendungsumgebungen, Vorhersagehorizonte, zeitliche Auflösung der Eingangsdaten sowie der Prognosegröße sowie der Auswahl der Prognosegröße umgesetzt. Dazu wurde das bereits bestehende Systemidentifikationstool erweitert.

Auf Basis dieser Anforderungen wurden die 18 Modelle mit verschiedenen Hyperparametern antrainiert. Die besten Ergebnisse der Prognosemodelle sind in Abbildung dargestellt. Eine ausführliche Auswertung der Ergebnisse sowie Auflistung der verwendeten Hyperparameter ist in [98] zu finden.

Hinsichtlich der technischen Anforderung der Echtzeit TR-8 besteht die Anforderung, dass die benötigte Zeit zur Ausgabe des Bündels an Prognosewerten des antrainierte Prognosemodell in der Anwendung kürzer ist als der nächste Prognoseschritt. In diesem Falle also die Berechnungszeit kleiner als 10 Sekunden ist. Für alle Modelle wurden daher die Inferenz Hardware evaluiert. Das Modell mit den höchsten Anforderungen diesbezüglich stellt das kurzfristige Vorhersagemodell des Produktionssystems dar. Dieses benötigt 3,5 Sekunden zum Berechnen der 90 Vorhersagewerte, sodass die Anforderung erfüllt ist.



Abbildung 2.52: Relativer Mean Absolut Error für Trainings- und Testdaten der entwickelten Modelle.




Abbildung 2.53: Hierarchische Struktur des Prognoseansatzes (vgl. [98]).

Das entwickelte Framework zur Integration der Informationen über den Prognosehorizont sowie der TinyEvo Algorithmus zur Optimierung der neuronalen Netz Architektur wurden in das datenbasierten Modellierungsframework des PTWs integriert.

Zum Abschluss des Arbeitspaketes 4.2 seitens PTW wurde das datenbasierte Modellierungsframework sowie die Ergebnisse aus AP 4.1 an den Daten von EJOT angewendet. Hierbei wurden zwei Versuchsreihen mit unterschiedlicher zeitlicher Auflösung der Zielgröße und des Prognosehorizontes durchgeführt. Zum einen wurde der rollierende Durchschnitt von einer Minute für die nächste Stunde als Zielgröße verwendet und zum anderen der rollierende Durchschnitt von 15 Minuten für den Prognosehorizont von vier Stunden. Für diese zwei Versuchsreihen wurden verschiedene Versuche hinsichtlich der verwendeten Datenvorverarbeitung auf Basis der Ergebnisse von Arbeitspaket 4.1 durchgeführt. Diese sind in Tabelle 2.12 aufgelistet. Die besten Ergebnisse für die zwei Versuchsreihen sind grün hervorgehoben. Die Ergebnisse zeigen (wie auch schon in den Versuchen in AP 4.1), dass der TinyEvo Algorithmus die besten Ergebnisse mit der *einfachsten* Datenvorverarbeitung in Form von Skalierung und Imputation von fehlenden Werten erzielt. Dies ist nicht ungewöhnlich, da neuronale Netze nicht immer eine komplexere Vorverarbeitung benötigen, insbesondere bei Verwendung von Algorithmen zur Neuronalen Architektursuche (NAS) – wie z.B. TinyEvo.

Tabelle 2.12: Ergebnisse aus den Versuchen zur Prognose der EJOT-Daten

Zielgröße	Datenvorverarbeitung	MAE	MSE
Rollierender Durchschnitt von 1 Minute; Horizont 1 h	Scaling + Imputing only	8.92	164.05
	Scaling + Imputing + Rolling mean 30s all features	15.00	582.48
	Scaling + Imputing + added feature "hour"	18.23	585.34
Rollierender Durchschnitt von 15 Minute; Horizont 4 h	Scaling + Imputing only	13.08	298.60
	Scaling + Imputing + Rolling mean 1 minute all features.	1214.71	64038.28

Als Forschungsergebnis wurde in Arbeitspaket 4.1 und 4.2 ein automatisiertes Prognoseframeworks mittels Auto-Machine Learning zur Lastprognose und Datenvorverarbeitung entwickelt und validiert. Um den praktischen Einsatz des Frameworks in realen Produktionsumgebungen zu validieren, wird das Framework anhand eines Anwendungsfalls in der ETA-Fabrik angewendet. Die Umsetzungen in der ETA-Fabrik sind im Teilprojekt 7.6 verortet, weshalb an dieser Stelle die Anwendung nicht beschrieben wird. Die Ergebnisse der Anwendung sind entsprechend im Abschlussbericht im Abschnitt zu Teilprojekt 7.6 zusammengefasst.

Zusammenfassung der Arbeiten je Partner

PTW (Leitung):

- Definition von Anforderungen an Prognosemodelle
- Analyse, Auswahl, Implementierung und Evaluierung von NAS Algorithmen
- Entwicklung, Implementierung und Evaluierung von verschiedenen Modellarchitekturen zur Integration von Informationen über die Zukunft

- Entwicklung und Evaluierung von Lastprognosen für das Produktionssystem der ETA-Fabrik nach hierarchischem Ansatz
- Integration des entwickelten Frameworks zur Integration der Informationen über den Prognosehorizont sowie des TinyEvo Algorithmus zur Optimierung der neuronalen Netz Architektur in das datenbasierten Modellierungsframework
- Entwicklung der Prognosemodelle für die bereitgestellten Daten von EJOT

DFKI:

- Unterstützung der Partner auf Anfrage

etalytics:

- Evaluieren der Integration von neuronalen Netzen über den ONNX-Standard in das etaONE Backend
- Sammlung von Anforderungen an das Modellierungsframework der smarten Energiemanagementplattform
- Wartung des Systemidentifikationstool sowie Weiterentwicklung anhand der gesammelten Anforderungen

EJOT:

- Bereitstellung von Daten zu Energieverbrauch und Produktionsauslastung eines Werkes

ENTEKA:

- Analyse und Aufbereitung der ETA-Daten zur Lastprognose,
- Analyse und Aufbereitung der Daten eigener Beispielkunden,
- Implementierung eigener Prognosetools auf Basis verschiedener Machine-Learning-Verfahren,
- Schnittstelle zur Übertragung der ETA-Daten implementiert und erfolgreich getestet.

2.4.3. Arbeitspaket 4.3: Datenbasierte Simulationsmodell-Parametrierung

Simulationsmodelle bilden das physikalische Verhalten von Systemen in Modellen ab. Um ein valides Modell zu erhalten, sind die Komponenten des Simulationsmodells so zu wählen und parametrieren, dass das Modellverhalten das dynamische Verhalten des realen Systems nachbildet. Während sich die Auswahl der Komponenten des Simulationsmodells für technisch ähnlich aufgebaute Systeme bisweilen ähnelt, sodass auf entsprechende Bibliotheken für den jeweiligen konkreten Einsatzzweck zurückgegriffen werden kann, muss die Parametrierung für jeden Anwendungsfall individuell erfolgen. Daher wurden in diesem Arbeitspaket Verfahren untersucht, welche die Parametrierung von Simulationsmodellen vereinfachen und teilweise automatisieren können.

Für die Untersuchungen in diesem Arbeitspaket wurden Daten in der ETA-Fabrik aufgezeichnet und Modelle der Produktionsanlagen in der ETA-Fabrik erstellt. Da für die Arbeiten in Teilprojekt 5 verschiedene Typen von Modellen mit unterschiedlichen Ein- und Ausgangsgrößen benötigt werden, wurden in diesem Arbeitspaket mehrere Varianten untersucht.

Modelle für die Fabriksteuerung

Ziel der Modellierung war in diesem Fall eine Abschätzung der Leistungsaufnahme entsprechend des Energiemodus, in dem sich die Maschine zum jeweiligen Zeitpunkt befindet. Dabei wurde sowohl die

elektrische als auch die thermische Leistungsaufnahme berücksichtigt. Als Parameter fließen daher neben dem Energiemodus auch die Temperatur der Fabrikhalle mit in das Modell ein. Die Berücksichtigung der thermischen Leistung ist wichtig für die spätere Kopplung der Modelle mit der Optimierung der Versorgungstechnik in Arbeitspaket 5.4 (siehe Abschnitt 2.5.4).

Die durchgeführten Versuche wurden genutzt, um sowohl Trainingsdaten als auch Testdaten für die Modelle zu generieren. Abbildung 2.54 stellt ein beispielhaftes Ergebnis mit den Testdaten dar. Dabei wird deutlich, dass die Modelle die elektrische Leistung im Durchschnitt besser abbilden können als die thermische Leistung [104]. Dies kann unter anderem mit Herausforderungen bei der Messung der thermischen Daten an den Maschinen zusammenhängen, da insbesondere die Temperaturmessungen recht große Messfehler aufweisen, während für die Berechnung der thermischen Leistung die Differenz zwischen zwei aufeinanderfolgenden Messwerten sehr relevant ist [104].

Insgesamt kann das dargestellte Modell jedoch den Energieverbrauch der Produktion gut vorhersagen – der Vorhersagefehler bei der Gesamtenergie lag bei ca. 6.5 %, was für die Durchführung der Produktionsplanung in AP 5.2 ausreichend ist [104].




Abbildung 2.54: Testdaten für die Maschine EMAG Y im Vergleich mit den Vorhersagewerten [104].

Verfahren zur Sensitivitätsanalyse und automatischen Parametrierung komplexer Simulationsmodelle

- In AP 4.3 wurde seitens des PTWs zudem eine Methode zur automatisierten Parametrierung komplexer Simulationsmodelle entwickelt.
- Diese gliedert sich in eine Sensitivitätsanalyse, nach der die einflussreichsten Simulationsparameter auf einen frei wählbaren Simulationsausgang ermittelt werden und eine anschließende Parameteridentifikation der ermittelten einflussreichsten Parameter.
- Die Sensitivitätsanalyse wurde anhand einer Simulation aus dem Vorprojekt PHI-Factory entwickelt und validiert.




Abbildung 2.55: PI-Evaluation (System aus PhiFactory, 100 × 1 Tag, verschiedene Parameterkombinationen (Indizes)). Es zeigt sich eine deutliche Abnahme des Fehlers der Temperaturverläufe nach der Parameteridentifikation (PI), s. [105]

- Anschließend wurde sie auch für das Simulationsmodell der thermischen Versorgungstechnik der ETA-Fabrik eingesetzt. Hierbei zeigte sich, dass die Sensitivitätsanalyse zwar sinnvoll erscheinende Parameter auswählt, diese aber bei einer anschließenden Parameteridentifikation nur einen geringen Einfluss auf die Simulationsgüte aufwiesen.
- Die Parameteridentifikation lieferte dementsprechend bei einer manuell durchgeführten Parameterauswahl ein besseres Ergebnis. Jedoch gab es auch bei der Parameteridentifikation des ETA-Fabrik Systems verbleibende Probleme. Viele der Parameterwerte wurden an den vorgegebenen Grenzwerten identifiziert, was ein Hinweis auf eine zu restriktive Grenzsetzung ist. Im Projekt wurden feste Grenzwerte von $\pm 20\%$ um die initialen Parameterwerte gewählt.
- In zukünftigen Untersuchungen sollten diese Grenzwerte dynamisch und individuell angepasst werden.
- Die im Projekt entwickelten Methoden bieten jedoch eine gute Grundlage und die notwendigen Verbesserungen lassen sich vergleichsweise aufwandsarm implementieren.

Zusammenfassung der Arbeiten je Partner

PTW (Leitung):

- Eine allgemeine Methode zur globalen Sensitivitätsanalyse und Parameteridentifikation wurde entwickelt und in Python umgesetzt

- Implementierung einer energiegerechten Produktionsplanung und Veröffentlichung in Dissertation Grosch [104]
- Abschluss einer Masterthesis mit Übertragung und Erprobung der Forschungsansätze von Grosch auf einen weiteren Anwendungsfall bei Bosch
- Weitergabe von Anlagenmodellen der ETA-Fabrik an das DFKI zur Aktualisierung und Verbesserung der Modellierungsgenauigkeit sowie geplante Evaluation zusätzlicher Modellierungsarten zur weiteren Verbesserung der Modellgüte der Produktionsanlagen-Modelle

DFKI:

- Absprache zu und Austausch von geeigneten Simulationsmodellen aus der ETA
- Übertragung und Erprobung der energetischen Simulation der Produktionsanlagen der ETA
- Hybride KI-basierte Last-Disaggregations-Ansätze zur Systemidentifikation und Simulationsparametrierung am Beispiel einer Kammerreinigungsmaschine erprobt und in [106] veröffentlicht

2.4.4. Unterstützung Arbeitspaket 4.4: KI-gestütztes Vorschlagswesen für Energieeffizienzmaßnahmen

Im Rahmen dieses Arbeitspakets wurde ein KI-gestütztes Vorschlagswesen zur Identifikation von geeigneten Energieeffizienzmaßnahmen für verschiedene Produktionsanlagen aufgebaut. Dabei baut dieses Arbeitspaket auf den Ergebnissen des Teilprojekts 3 auf. Die Zielstellung des Antrages wurde hierbei durch die Forderung nach einer Anwendbarkeit auf unterschiedliche Maschinentypen erweitert. Durch das KI-gestützte Vorschlagswesen sollen Betreibende solcher Anlagen auf Grundlage von Mess- und Metadaten in die Lage versetzt werden, aufwandsarm und ohne tiefgreifendes Expertenwissen energetische Ineffizienzen und zugehörige Maßnahmen zu identifizieren. Das Konzept wurde im Rahmen dieses Arbeitspakets auf mehrere Anlagen erfolgreich angewendet und in wissenschaftlichen Publikationen der Öffentlichkeit zur Verfügung gestellt.

Im Folgenden ist exemplarisch die Anwendung an Kammerreinigungsanlagen innerhalb der ETA-Fabrik ausgeführt, die in [107] publiziert ist. Der Bearbeitungsprozess der Bauteilreinigung innerhalb von Kammerreinigungsanlagen besteht aus den vier Schritten: Spülen, Trocken, Entladen bzw. Beladen und Sonstiges. Als Sonstiges werden nicht spezifizierte Ereignisse bezeichnet, wie z. B. Pausen zwischen den anderen drei Schritten. Das Expertensystem verfügt über eine Wissensbasis, die Expertise über den Bearbeitungsprozess in Form der durchlaufenen Prozessschritte beinhaltet. Dadurch wird das Expertensystem in die Lage versetzt, die vier Prozessschritte automatisiert anhand des elektrischen Lastprofils durch maschinelles Lernen zu erkennen (siehe Abbildung 2.56). Der Aufwand der Analyse durch Fachexperten entfällt somit an dieser Stelle. Zudem sind Regeln hinterlegt, die auf Basis definierter Kennzahlen Energieeffizienzpotenziale identifizieren und geeignete Maßnahmen ableiten und zur Umsetzung vorschlagen.




Abbildung 2.56: Analysiertes Lastprofil einer Kammerreinigungsanlage durch das Expertensystem.

Nach der automatisierten Erkennung der einzelnen Prozessschritte werden Merkmale, wie z. B. Prozesszeiten und Energiebedarfe extrahiert, die schließlich zur Berechnung von Energieleistungskennzahlen genutzt werden. In diesem Anwendungsbeispiel dauert der Spülvorgang in Summe deutlich länger als die anderen Prozessschritte und benötigt innerhalb des Beobachtungszeitraums die meiste Energie. Das Expertensystem stellt für das Spülen ein Energieeinsparpotenzial von 0,5 kWh fest, das durch eine zeitliche Verkürzung der Prozessdauer erreicht werden kann. Als Referenz dient dabei der kürzeste Spülvorgang im dargestellten Zeitraum. Auch bei den restlichen Prozessschritten kann auf die gleiche Weise der Energiebedarf verringert werden. Durch eine zeitliche Optimierung der vier Bearbeitungsschritte Spülen, Trocknen, Ent- bzw. Beladen und Sonstiges kann laut Expertensystem in Summe rund 11 % der elektrischen Energie eingespart und der Produktionsprozess um etwa 23 % verkürzt werden. Das Anwendungsbeispiel verdeutlicht, dass Expertensysteme einen wichtigen Beitrag dazu leisten können, die Analyse von Messdaten, das Quantifizieren von Energieeffizienzpotenzialen und das Ableiten adäquater Energieeffizienzmaßnahmen in produzierenden Unternehmen zu unterstützen.

Zudem wurde das Konzept in der ETA-Fabrik an einer Durchlaufreinigungsanlage [108] erfolgreich erprobt. In der Industrie konnte bei Pirelli durch den Einsatz am Beispiel eines Stempelkneters und der Maßnahme des Hydraulikölwechsels eine Energiekosteneinsparungen von 2,67 kWh pro Zyklus erreicht werden. Das bedeutet für das betroffene Unternehmen eine monetäre Einsparung von rund 27 000 € pro Jahr und entspricht einer Amortisationszeit von etwa zwei Monaten [109]. Seitens Evonik wurde zudem ein Schema erarbeitet, dass auf Grundlage von Eingangsdaten wie der Hydraulikaufgabe (statisch/ dynamisch), des Verlustmechanismus (mechanisch/ volumetrisch) und der verwendeten Ventile (Proportionalventile/ Stellwegeventile) eine energetisch vorteilhafte Viskositätsklasse für das Hydrauliköl vorschlägt [109].

Zusammenfassung der Arbeiten je Partner

PTW (Leitung):

- Erstellung eines Konzepts für das Vorschlagswesen
- Aufnahme von Messdaten an Maschinen in der ETA-Fabrik
- Implementierung der Vorschlagswesen in Python
- Mitwirkung bei Veröffentlichung von Ergebnissen

Evonik:

- Versuchsdurchführung und Messungen an Anlagen mit unterschiedlichen Hydraulikölen
- Auswertung der Versuche und Ableitung von Empfehlungen für Hydrauliköle
- Mitwirkung bei Veröffentlichung von Ergebnissen

etalytics:

- Definition von Rahmenbedingungen zur Einbindung des KI-gestützten Vorschlagswesens in der Programmierungsumgebung der smarten Energiemanagementplattform

2.4.5. Arbeitspaket 4.5: Condition Monitoring und Predictive Maintenance als Mehrwert für Energiedatenerhebung

Das Ziel des Arbeitspakets bestand in der Erstellung von Condition Monitoring und Predictive Maintenance Modellen unter Einbezug von Energiemessstellen zur Reduzierung von Ausschuss und somit einer (energie- und ressourcen-) effizienteren Produktion.

Datenlabelung während der Produktion bei Massenfertigung

Bei der Realisierung der angesprochenen Modelle können sowohl „supervised“ als auch „unsupervised“ Modellarchitekturen zum Einsatz kommen. Das Training eines supervised Modells benötigt allerdings gelabelte Daten. Um beide Ansätze zu untersuchen, wurde hierzu ein Konzept der Datenlabelung während der Produktion aufgestellt und umgesetzt.

Aufgrund der hohen Produktionsgeschwindigkeit stellte die Labelung aufgenommener Daten eine Herausforderung dar. Das Konzept einer intervallweisen Prüfung der produzierten Teile berücksichtigt den aktuellen Prüfstandard bei EJOT und wäre somit auch für spätere produktive Realisierung umsetzbar.

In Folge der Prüfung setzt der Werker einen Status und „quittiert“ die Messung. Wird die Datenaufnahme beendet, erfolgt automatisch eine Labelung der gespeicherten Datenpakete. Datenpakete, deren Status aufgrund eines Statuswechsels unbekannt sind, werden aussortiert.

Datenaufnahme und Analyse der Datenqualität

Um eine entsprechende Datengrundlage aufzubauen, wurden mehrere Produktionstage genutzt. Insbesondere wurden Fehler künstlich herbeigeführt. Hierbei erwies sich das entwickelte Labelingtool als praktikabel und effizient.

Unter Verwendung der aufgezeichneten Daten erfolgte eine Analyse hinsichtlich der Datenqualität sowie Plausibilität in Zusammenarbeit mit internen Prozessexperten. Hierbei wurde eine gute Qualität der Kraftverlaufsmessungen festgestellt. Allerdings ergab sich, dass die vorliegenden Energiedaten aufgrund mehrerer Faktoren nicht zur Verwendung geeignet sind. Die wichtigsten Faktoren hierbei waren die unzureichende Datenqualität sowie keinerlei erkennbare Anhaltspunkte innerhalb der Daten auf vorliegende Werkzeugeffekte.

Preprocessing

Auf Grundlage dieser Erkenntnisse erfolgte die Konzeptionierung und Umsetzung des Preprocessings. Die größte Herausforderung hierbei war der Umgang mit den variablen Datenmengen einer Messung in

Abhängigkeit von der Produktionsgeschwindigkeit. Es wurde schließlich ein Down Sampling beschlossen.

Software & Modelle

Darauf aufbauend wurden mehrere KI-Modelle trainiert und getestet. Die Umsetzung einer Anomalie-Detektion lieferte hier die besten Ergebnisse.

Die entwickelte Software ist so konzipiert, dass ihr Einsatz unabhängig von den benötigten Prozessschritten zur Herstellung eines Produktes ist. Ebenso wurde ein Frontend geschaffen, welches die Echtzeitvisualisierung der Kraftverläufe und anderer produktionsspezifischer Kenngrößen ermöglicht. Dies sorgt für Transparenz hinsichtlich der Entscheidungen des KI-Modells.

Die Software wurde an der Maschine erprobt. Hierbei wurde softwareseitig der in Abbildung 2.57 dargestellte Workflow umgesetzt. Der grau hinterlegte Bereich stellt hierbei den aktuell existierenden Standard-Produktionsprozess dar. Die eingehenden Rohdaten werden aggregiert und in zwei Schritten vorverarbeitet. Nach einer Anzahl N produzierter Teile erfolgt eine Qualitätsprüfung durch den Werker, wobei er das Ergebnis qualifizieren muss. Parallel zum Standardproduktionsprozess werden die Rohdaten für spätere Analyse- und Entwicklungszwecke und die allgemeinen vorverarbeiteten Daten für das Modelltraining abgespeichert (grün hinterlegter Bereich).

Werden die produzierten Teile als „Gut“ qualifiziert, wird das Modelltraining angestoßen. Existiert für den produzierten Artikel bereits ein Modell, erfolgt hier ein Transfer Learning. Wichtig hierbei ist, dass auch dies parallel zum Standardproduktionsprozess erfolgt und somit kein Maschinenstillstand hervorgerufen wird. Ist das Modell einsatzbereit, wird dieses freigegeben. Nach der Freigabe findet die KI-basierte Evaluierung statt.




Abbildung 2.57: EJOT-Workflow zur Einbindung von KI-Modellen in den Produktionsprozess.

Ergebnisse

Die Validierung der Bauteilqualitätsalgorithmen lieferte zufriedenstellende Ergebnisse. So konnte in mehreren Fällen der Werkzeugverschleiß eine gesamte „Verschleißstufe“ früher detektiert werden als mit den bisherigen Überwachungsverfahren. Dies bestätigte sich an beiden Beispielmachines.

ÖKOTEC hat in AP 3.4 auf Basis des entwickelten Anwendungsfalls der Modellierung einer Verbundkälteanlage Machine Learning-basierte Methoden (inkl. der Bewertung zustandsbasierter Einflussvariablen) entwickelt und getestet, um das Anlagenverhalten von Teilsystemen der Erzeugung und Verteilung zu modellieren und miteinander zu kombinieren. Einige Einflussfaktoren, die auf die Systeme wirken, lassen sich wie die Fahrweise der Kühlstellen in den Kühlräumen nur als

Zustandsvariablen beschreiben. Diese Zustände und deren Wirkung müssen einerseits im Modell berücksichtigt und trainiert werden und andererseits auch in der zukunftsorientierten Betriebsoptimierung eingebunden werden.

Die Parametrierung der Modelle und die Datenstruktur im Energiekennzahlengenerator aus dem AP 3.5 wurde im AP 4.5 um einen Modellansatz erweitert, der den Einsatz der Verbundkälteanlage unter verschiedenen möglichen Zuständen in der Zukunft bestimmen kann, um hier optimierte Betriebskonzepte bewerten zu können. Dabei spielt insbesondere das Verhalten der Kombination aus den Zuständen der Verdichter und der Verdampfer/Kühlstellen in den Kühlräumen für die Einstellungen der Temperaturhysterese eine Rolle. Die Zielstellung ist die Modellierung definierter Einstellungen, um die Zustände planbar zu machen sowie die zeitliche Planung der Zustände unter der Bedingung der Einhaltung relevanter technischer Betriebsrestriktionen (z.B. Temperatur der Kühlkette) und Optimierung der Energiekosten.

Zudem zielten diese Ansätze von Zustandsdaten auch bei einer Mustererkennung darauf, nicht quantifizierbare Einflussfaktoren bzw. nicht planbare Einflussfaktoren auf das Energiekennzahlenmodell durch Muster oder Trends bewertbar zu machen. Damit soll die Validität des Modells erhöht werden und die Ergebnisse der Modellberechnung verbessert werden. Nicht quantifizierbare Einflussfaktoren sind vor allem die Warenbewegungen im Kühllager und deren Aufteilung auf die Kühlzonen. Weitere nicht gemessene Einflüsse sind alle Stromverbraucher am Standort außer den Verdichtern, die direkt oder indirekt mit dem Kühlprozess und den Zuständen der Verbundkälteanlage in Verbindung stehen. Es wurden unterschiedliche Ansätze getestet, die Warenbewegungen in ihren zeitlichen Wirkungen auf das Temperaturmodell betrachten. Als robust hat sich lediglich herausgestellt, dynamische Einflüsse auf die Kühllagertemperaturen gewichtet mit mittelfristigen und kurzfristigen Einflüssen zu parametrieren. In einem weiteren Versuch sollte der Reststrombedarf am Standort neben den Verdichter als Hauptverbraucher modelliert werden. Als einziger Einfluss sind hier jedoch nur die Zustände der Verdichter selbst bekannt, die nicht Teil der Reststrombedarfs sind, jedoch teilweise Einfluss haben. Hier konnte durch Mustererkennung gezeigt werden, dass eine zeitlich aufgelöste Modellierung im 15-Minuten-Intervall eines Restportfolios von Anlagen und Verbrauchern wie Pumpen, Lüfter, Rückkühler, Beleuchtung, Verwaltung etc. sehr gut möglich ist. Die Ergebnisse wurden dann im weiteren Verlauf im AP 5.3 demonstriert.

Zusammenfassung der Arbeiten je Partner

EJOT (Leitung):

- Aufstellung und Umsetzung eines Konzepts zur Datenlabelung während der Produktion
- Nutzung mehrerer Produktionstage zur Datenaufnahme
- Künstliche Herbeiführung von Fehlern zur Datenerfassung
- Analyse und Beurteilung der Datenqualität und Plausibilität in Zusammenarbeit mit internen Prozessexperten
- Konzeptionierung und Umsetzung des Preprocessings
- Training und Testen mehrerer KI-Modelle
- Umsetzung einer Anomalie-Detektion
- Entwicklung einer Software, die unabhängig von den Prozessschritten zur Herstellung eines Produktes einsetzbar ist

- Schaffung eines Frontends zur Echtzeitvisualisierung der Kraftverläufe und anderer produktionsspezifischer Kenngrößen
- Erprobung der Software an der Maschine
- Durchführung von Transfer Learning bei bereits existierenden Modellen

Bosch

- Unterstützung der Untersuchungen zur Übertragbarkeit von Condition Monitoring und Predictive Maintenance Modelle auf andere Maschinen

DFKI

- Unterstützung der Erstellung eines digitalen Zwillings für die EJOT Maschinen

ÖKOTEC

- Analyse der möglichen Zustandsvariablen und Selektion der relevanten Daten
- Erweiterung der Machine Learning-Ansätze um die Modellierung von Zuständen
- Nutzung des zustandsbasierten Lernens auch für das Modelltraining mit nicht quantifizierbaren Einflussfaktoren

2.4.6. Arbeitspaket 4.6: Übertragbarkeit von datenbasierten Modellen über Transfer Learning

Im Rahmen dieses Arbeitspakets wurde die Übertragbarkeit von datenbasierten Modellen über Transfer Learning untersucht, um den Einrichtungprozess neuer Anlagen effizienter zu gestalten und den Betrieb durch maschinelles Lernen zu optimieren. Derzeit erfordert die Parametrierung einer neuen Anlage einen erheblichen zeitlichen und ressourcenintensiven Aufwand sowie ein hohes Maß an Expertenwissen. Dies führt dazu, dass Maschinen während der Einrichtung nicht produktiv genutzt werden können, wodurch wertvolle Produktionszeit und Energie verloren gehen.

Ein vielversprechender Ansatz zur Bewältigung dieser Herausforderung besteht in der Wiederverwendung bereits bestehender, vortrainierter Machine-Learning-Modelle, die auf ähnliche Anlagen oder Komponenten übertragbar sind. Transfer Learning ermöglicht es, Modelle mit großen Trainingsdatensätzen und hoher Rechenleistung vorzubereiten und anschließend mit geringeren Datenmengen für eine spezifische Zielmaschine anzupassen. Dadurch lassen sich Zeitaufwand und Ressourcenbedarf erheblich reduzieren. Ziel war ein bereits entwickeltes Predictive-Maintenance-Modell, das im Arbeitspaket 4.5 von EJOT erstellt und trainiert wurde, auf eine andere Maschine mit ähnlicher Konfiguration zu übertragen. Diese Übertragung ist besonders wichtig für den industriellen Einsatz, da neue Maschinen in der Regel nicht über ausreichend Daten verfügen, um ein Machine-Learning-Modell von Grund auf neu zu trainieren. Durch den Einsatz von Transfer Learning und Docker-Containern konnte ein effizienter Ansatz realisiert werden, der die Vortrainierung eines Modells auf einer Maschine ermöglicht und dieses Modell als Grundlage für eine neue Maschine mit ähnlichen Betriebsparametern nutzt.




Abbildung 2.58: Transfer Learning Pipeline.

Wie in Abbildung 2.58 dargestellt, sind die wichtigsten Schritte dieses Prozesses die folgenden:

- **Analyse und Vergleich der Maschinenkonfigurationen**
Sicherstellung, dass das Modell von der ersten Maschine (Quelle) auf die zweite Maschine (Ziel) übertragbar ist.
- **Erstellung eines Docker-Containers**
Um das Modell sowie die benötigte Umgebung einfach übertragbar zu machen.
- **Bereitstellung des vortrainierten Modells**
Integrieren des gespeicherten Modell-Checkpoints im Container.
- **Anpassung des Modells für die Zielmaschine**
Nutzung der vorhandenen Betriebsdaten der Zielmaschine für die Fine-Tuning.
- **Test und Validierung des transferierten Modells**
Evaluierung der Performance auf der neuen Maschine.

Analyse und Vergleich der Maschinenkonfigurationen

Bevor das vortrainierte Predictive-Maintenance-Modell auf eine neue Maschine übertragen wird, ist es essenziell, die technischen und betrieblichen Unterschiede zwischen der Quellmaschine (auf der das Modell ursprünglich trainiert wurde), und der Zielmaschine (auf der das Modell nun eingesetzt werden soll), zu analysieren. Dabei müssen mehrere Faktoren geprüft werden. Zunächst wird untersucht, welche Sensoren in beiden Maschinen verbaut sind, ob die Datenformate und Abstraten identisch sind oder ob Anpassungen vorgenommen werden müssen. Anschließend wird geprüft, ob Unterschiede in den Betriebsbedingungen vorliegen, beispielsweise in Bezug auf Geschwindigkeit oder Temperaturen, und ob diese Unterschiede durch das Modell ausgeglichen werden können oder eine zusätzliche Nachbearbeitung der Daten erforderlich ist. Das Ziel dieser Analyse ist es, sicherzustellen, dass das Modell mit minimalen Anpassungen erfolgreich auf der neuen Maschine eingesetzt werden kann. Falls signifikante Unterschiede bestehen, sollte das Modell mit zusätzlichen Daten der neuen Maschine feinjustiert werden.

Erstellung eines Docker-Containers

Um das Modell und die gesamte benötigte Umgebung einfach und flexibel zwischen Maschinen übertragbar zu machen, wurde ein Docker-Container verwendet. Ein Docker-Container bietet mehrere Vorteile:

- Es ermöglicht eine plattformunabhängige Ausführung, sodass das Modell auf jeder Maschine mit Docker lauffähig ist, unabhängig vom Betriebssystem oder installierten Abhängigkeiten.
- Zudem gewährleistet es eine standardisierte Umgebung, in der alle benötigten Softwarepakete, Bibliotheken und Konfigurationen einheitlich vorhanden sind, wodurch Inkompatibilitäten vermieden werden.
- Docker erleichtert die Bereitstellung, da das Modell mit wenigen Befehlen auf einer neuen Maschine gestartet werden kann. Der Docker-Container enthält ein vorkonfiguriertes Betriebssystem mit allen benötigten Paketen und Bibliotheken, das vortrainierte Modell, das als Basis für die Zielmaschine dient, eine Schnittstelle zur Verarbeitung von Sensordaten der Zielmaschine sowie Skripte für die Feinjustierung, falls notwendig.

Bereitstellung des vortrainierten Modells

Das Predictive-Maintenance-Modell, das ursprünglich auf der Quellmaschine entwickelt und trainiert wurde, wird als Modell-Checkpoint gespeichert. Ein Checkpoint enthält die trainierten Gewichte und Parameter des Modells, sodass es nicht von Grund auf neu trainiert werden muss. Die Bereitstellung des Modells im Docker-Container erfolgt in mehreren Schritten. Zunächst wird das Modell in einem standardisierten Format gespeichert, beispielsweise als „.pth-Datei“ oder „.h5-Datei“. Anschließend wird der gespeicherte Modell-Checkpoint in das Arbeitsverzeichnis des Docker-Containers kopiert, sodass er beim Start des Containers verfügbar ist. Schließlich wird das Modell beim Start des Containers automatisch geladen und für die Inferenz bereitgestellt, sodass es ohne erneutes Training sofort auf einer neuen Maschine eingesetzt werden kann.

Anpassung des Modells für die Zielmaschine

Da es Unterschiede zwischen der Quell- und der Zielmaschine geben kann, muss das Modell gegebenenfalls durch Fine-Tuning an die neue Umgebung angepasst werden. Dies geschieht in mehreren Schritten. Zunächst werden Sensordaten der Zielmaschine erhoben, um die Modellgenauigkeit zu überprüfen. Anschließend werden diese Daten mit den Originaldaten der Quellmaschine verglichen, um mögliche Abweichungen zu identifizieren. Falls Abweichungen auftreten, wird das Modell entsprechend angepasst. Falls ausreichend Daten vorhanden sind, wird das Modell mit den Sensordaten der neuen Maschine weitertrainiert, um spezifische Unterschiede zu berücksichtigen. Dabei wird überprüft, ob eine vollständige Neuanpassung erforderlich ist oder ob Transfer Learning genutzt werden kann, indem nur die letzten Schichten des Modells nachtrainiert werden, während die vorherigen Schichten unverändert bleiben.

Test und Validierung des transferierten Modells

Nachdem das Modell auf der neuen Maschine bereitgestellt und gegebenenfalls angepasst wurde, muss es validiert werden, um sicherzustellen, dass es die erwartete Leistung erbringt. Die Validierung erfolgt in mehreren Schritten. Zunächst werden Sensordaten der Zielmaschine durch das Modell verarbeitet und die Vorhersagen mit realen Ereignissen verglichen. Anschließend wird die Modellgenauigkeit anhand von Fehlerkennzahlen bewertet. Falls die Vorhersagen stark von den Erwartungen abweichen,

wird geprüft, ob zusätzliche Anpassungen erforderlich sind. Schließlich wird das Modell über einen bestimmten Zeitraum im realen Betrieb getestet, um seine Zuverlässigkeit zu validieren.

Zusammenfassung der Arbeiten je Partner

DFKI (Leitung):

- DFKI hat gemeinsam mit EJOT die Modellkonfiguration, das Datenformat und die Maschinenkonfigurationen analysiert, um die Übertragbarkeit des Predictive-Maintenance-Modells sicherzustellen. Die Sensordaten und Betriebsbedingungen der Maschinen wurden ebenfalls analysiert, um Unterschiede festzustellen und die erforderlichen Anpassungen vorzunehmen.
- DFKI hat eine Transferpipeline definiert, die alle erforderlichen Schritte für die Modellanpassung und das Nachtraining umfasst.
- DFKI hat eine Docker-basierte Umgebung entwickelt, um das Modell und seine Abhängigkeiten in einer standardisierten Form bereitzustellen. Das Predictive Maintenance Modell, das von EJOT im Arbeitspaket 4.5 trainiert wird, wurde für die notwendigen Konfigurationen berücksichtigt.

Bosch:

- Fachliche Unterstützung und Prüfen der Übertragbarkeit zwischen unterschiedlichen Maschinen

EJOT:

- Modelltraining und Transfer Learning bei vorhandenen Modellen
- Erfolgreiche Validierung der Bauteilqualitätsalgorithmen
- Ausstattung einer weiteren Maschine mit benötigter Sensorik
- Transfer des gewonnenen Wissens auf andere Maschinen

2.5. Teilprojekt 5: Ganzheitliche Betriebsstrategieoptimierung




Abbildung 2.59: Datenfluss zwischen Anlagenpool und zentralem Optimierer zur Bestimmung optimierter Betriebsstrategien.

Die Recherche innerhalb des Projektantrags zeigte, dass eine Lösung zur Optimierung komplexer energetischer Systeme bisher für die Industrie nicht zugänglich ist, obwohl hierfür in der Forschung bereits viele Ansätze erfolgreich getestet wurden. Um die Lücke zwischen Theorie und Praxis zu schließen, wurden in diesem Teilprojekt einfache und automatisierte Optimierungslösungen für sowohl die Produktionsanlagen als auch die Versorgungstechnik entwickelt, um eine schnelle Implementierung ohne Expertenwissen zu ermöglichen. Zusammengefasst ist das Ziel des Teilprojekts, Energieeinsparungen durch automatisierte, optimale Betriebsführung zu erzielen, indem die Anwendung neuester Optimierungsstrategien vereinfacht und automatisiert wurden. Im Teilprojekt wurden mit der zentralen und dezentralen Optimierung über mathematische Programmierung, Deep Reinforcement Learning und der Optimierung durch Heuristiken Ansätze verfolgt, die jeweils für unterschiedliche Anwendungsfälle geeignet sind.

Tabelle 2.13: Arbeitspakete in Teilprojekt 5.

Ganzheitliche Betriebsstrategieoptimierung		Beteiligte Partner
Teilprojektleitung: PTW		
AP 5.1	Energieeffiziente und -flexible dezentrale Steuerung von Anlagen auf Komponentenebene	PTW, Bosch, IMS
AP 5.2	Energieeffiziente und -flexible Fabriksteuerung	PTW, Bosch
AP 5.3	Energieeffiziente und -flexible Fabrikversorgung (Betriebsoptimierung Versorgungstechnik)	PTW, etalytics, IMS, CuroCon, ÖKOTEC
AP 5.4	Kombinierte Anwendung in Simulation und Forschungsfabrik	PTW, IMS, etalytics
AP 5.5	Vergleich verschiedener Lösungsverfahren nach Anwendungsfall	DFKI, PTW, IMS

2.5.1. Arbeitspaket 5.1: Energieeffiziente und -flexible dezentrale Steuerung von Anlagen auf Komponentenebene

Im Rahmen des Arbeitspaketes wurden die energieeffiziente und energieflexible Optimierung des Betriebs einzelner Anlagen in der ETA-Fabrik und bei Bosch Rexroth für verschiedene Anwendungsfälle entwickelt. Neben einzelnen Produktionsanlagen (Reinigungsmaschine, 5-Achsbearbeitungszentrum, Linearschleifmaschine) wurden auch Verbundsysteme von Produktionsanlagen (zwei Werkzeugmaschinen im DC-Verbund, zwei Reinigungsmaschinen) sowie Anlagen der Versorgungstechnik (Hybrides Speichersystem) untersucht. Die Ergebnisse der einzelnen Anwendungsfälle werden im Folgenden erläutert.

Für alle Anwendungsfälle wurden im ersten Schritt Modelle erstellt und parametrisiert. Hierzu wurden sämtliche Produktionsanlagen der ETA-Fabrik über mehrere Wochen betrieben, um eine Datengrundlage für die Modellparametrisierung zu erhalten. Zusätzlich wurden Messungen der elektrischen Leistung an einzelnen Anlagen vorgenommen, um damit die Modelle dieser Anlagen noch zu verfeinern.

- Energieflexibler Betrieb der Reinigungsmaschine MAFAC KEA

In der ETA-Fabrik wurde die energieflexible Optimierung der Reinigungsmaschine MAFAC KEA umgesetzt. Hierzu wurde ein cyber-physisches Produktionssystem entwickelt, bestehend aus einem Simulationsmodell der Anlage, der Maschine selbst, mit ihrem OPC UA Datenmodell, einem Python-Optimierungsalgorithmus, der die Maschine ansteuert und einem Kommunikationsframework in Python, das den Datenaustausch zwischen den drei Einheiten Maschine, Simulation und Optimierung ermöglicht.

Das Dymola-Simulationsmodell der Anlage wurde im Rahmen einer studentischen Arbeit [110] entwickelt und bildet das thermische Verhalten sowie den elektrischen Energieverbrauch der Anlage ab. Im Rahmen von Versuchen an der echten Anlage wurde dieses Modell parametrisiert. Die Tankheizung der Reinigungsmaschine kann über OPC UA von außerhalb der Maschine aus dem Netzwerk der ETA-Fabrik geschaltet werden.

In einer ersten Version wurde die Tankheizung zunächst abhängig von einem fiktiven, angenommenen Strompreis geschaltet: Wenn der Strompreis unter einer festen Preisschranke liegt, also günstig ist, wird die Tankheizung angeschaltet. Mit der Simulation wird die Tanktemperatur für in zwei Minuten prognostiziert. Sollte die Tanktemperatur in der Simulation über einen kritischen Wert steigen, schaltet der Algorithmus die Tankheizung nicht ein. Falls die Simulation ergibt, dass die Tanktemperatur nicht zu heiß wird, wird eingeschaltet. Im weiteren Projektverlauf wurde der einfache Algorithmus durch einen aufwendigeren Optimierungsalgorithmus ersetzt, der nicht nur die nächsten zwei Minuten, sondern einen längeren Zeitraum betrachtet.

Die Modellierung der Reinigungsanlage erfolgte in einem einfachen, stückweise linearen mathematischen Optimierungsmodell. Das Optimierungsmodell wurde im AP 5.2 entwickelten eta_utility Framework zusammen mit einem energieflexiblen Algorithmus implementiert. Zur Ansteuerung wurde dabei auf das im Arbeitspaket 2.1 entwickelte OPC UA Datenmodell zurückgegriffen.

Das Datenmodell ermöglicht das Ausführen der Demand Response Maßnahmen *Prozess pausieren* und *Energie inhärent* speichern. Dazu wurde die Steuerung objektorientiert komplett neu programmiert und wieder in Betrieb genommen. Hierzu erfolgten mehrere Betriebstests.

Die Interaktion von Datenmodell und Optimierungsmodell konnte im Rahmen mehrere Versuche erfolgreich getestet werden. Hierfür wurde das eta_utility Framework auf einem Notebook installiert, um das Optimierungsmodell als Teil eines rollierend ausgeführten Model Predictive Control (MPC) Algorithmus einsetzen zu können. Das Notebook fungierte hier als Edge-Device, das direkt im Hallennetzwerk der ETA-Fabrik eingebunden wird und somit am Rande des Netzwerkes der Reinigungsmaschine agierte. Abbildung 2.60 zeigt die Ergebnisse des Versuches. Oben ist der Strompreis (energy price) und die elektrische Leistung (Power consumption) aufgezeichnet. In der Mitte ist dargestellt in welchem Reinigungsschritt (machine state) sich die Maschine gerade befindet und ob sie gerade pausiert (interruption state) wird. Es gibt die vier Zustände Operational, Pause (interruption), Reinigung (cleaning) und Trocknung (drying). Das unterste Diagramm zeigt den Zustand der Tankheizung (tank heater state) und den Istwert der Tanktemperatur (tank temperature) in schwarz sowie die 200 Sekunden Prognose des Optimierungsmodells (temperature prediction) in grau.




Abbildung 2.60: Steuerungversuch der Reinigungsanlage MAFAC KEA.

Der Strompreis (im obersten Diagramm) ändert sich in diesem Beispiel alle 5 Minuten. Nach 5 Minuten wird der Preis negativ. Durch die mathematische Optimierung wird die Maschine die ersten ca. 4 Minuten pausiert, bevor der Reinigungsprozess beginnt. Im 5 Minutenintervall mit negativen Preisen wird außerdem die Tankheizung eingeschaltet.

Mit dem Versuch konnte die Interaktion der Modelle sowie die Implementierung und Ausführung eines Algorithmus auf einem Edge Device erfolgreich gezeigt werden. Außerdem wurden die Optimierungsmaßnahmen damit erfolgreich an einer Einzelanlage durchgeführt. Die Ergebnisse dieses Anwendungsfalls wurden im Rahmen von drei Konferenzbeiträgen [111, 112, 113], sowie einer Journalveröffentlichung [114] publiziert und waren maßgeblicher Bestandteil einer Dissertation [115].

- Erweiterung der Produktionskette der ETA Fabrik um die Fertigung von Steuerscheibenrohlingen an einem 5-Achsbearbeitungszentrum im TEC Lab

Im Rahmen dieses Arbeitspakets wurde auch die Möglichkeit zur Erweiterung der Prozesskette zur Fertigung der Steuerscheibe untersucht, die in der ETA-Fabrik hergestellt wird. Bisher wurden die Rohlinge für die Steuerscheibe als Gussteile aus Italien bezogen, grundsätzlich ist aber auch eine Fertigung am PTW denkbar, nämlich mithilfe des Bearbeitungszentrums C32U dynamic von Hermle. Diese wurde im Rahmen des Arbeitspaketes 2.1 an die IoT-Plattform Cumulocity angeschlossen. Der Grundgedanke dabei war, die Maschine über diese Plattform anhand von Informationen, die über den aktuellen Strompreis aus dem Internet bezogen werden, starten zu können. So sollte eine Kostenoptimierung erfolgen, indem die Maschine dann produziert, wenn der Strom günstig ist. Gleichzeitig sollte aber immer gewährleistet sein, dass genügend Rohlinge zur Verfügung stehen.

Der Rohling einer Steuerscheibe wurde erfolgreich in einer CAM-Operation (Computer Aided Machining) am 5-Achs-Bearbeitungszentrum gefertigt (siehe Abbildung 2.61). Die Fertigung ließ sich digital in den virtuellen NC-Kernen abbilden. Eine simulationsbasierte Bilanzierung des Bedarfs der Maschine an elektrischer Energie war allerdings nicht ohne weiteres möglich. Dazu bräuchte es eine integrierte Abtragssimulation, die die Kräfte beim Zerspanen berechnet, die Reibung in den Achsen modelliert und die Leistung der Nebenaggregate miteinbeziehen kann, was den Rahmen dieses Anwendungsfalls übersteigt.

Zielführender ist ein messdatenbasierter Ansatz. In diesem Zusammenhang wurde die betrachtete Maschine während der Bearbeitung der Steuerscheibe umfangreich vermessen. Hierfür kamen zwei Messkoffer der ETA-Fabrik zum Einsatz, die jeweils in der Lage sind sieben Aggregate mit 3-Phasen-Wechselstrom zu vermessen. Zusätzlich wurde die Druckluftmenge erfasst und für die Bilanzierung berücksichtigt. Weiterhin flossen Hilfsstoffe, wie KSS und Schmiermittel sowie der Werkzeugverschleiß in die Rechnung ein. Die entsprechenden CO₂-Äquivalente wurden der *ecoinvent*-Datenbank entnommen. Aus den Untersuchungen ergibt sich eine Menge von etwa 7 kg CO₂-Äquivalent für die Fertigung eines Steuerscheibenrohlings. Der Bearbeitungsvorgang dauert etwa eine halbe Stunde. Natürlich ist dieser Prozess in der Praxis nicht geeignet, um den Rohling in ausreichender Stückzahl und mit vertretbarem Ressourceneinsatz herzustellen. Die Fertigung an dem Bearbeitungszentrum steht stellvertretend für andere Fertigungsprozesse, die allerdings am PTW nicht abgebildet werden können. Die Wahl des Fertigungsprozesses ist allerdings in diesem Falle zweitrangig, da nach der exakten Bilanzierung eine Verringerung des CO₂ Wertes erreicht werden soll. Dies soll unter Zuhilfenahme des aktuellen Strompreises und der IoT-Plattform Cumulocity geschehen.




Abbildung 2.61: In 5-Achs-Bearbeitungszentrum gefertigter Steuerscheibenrohling.

Um die Reduzierung des CO₂ Wertes zu erreichen, wurde eine Strategie erarbeitet, wie mit Hilfe der Plattform einzelne Aggregate während der Bearbeitung gezielt geschaltet werden können. Es wurde dazu mittels der *UAE*Expert-Software geprüft, ob ein sog. R-Parameter auf der Steuerung der Maschine geändert werden kann. Dieser Test war erfolgreich, sodass mittels logischer Abfragen im NC-Code der Maschine über einen R-Parameter beispielsweise der Späneförderer geschaltet werden kann. Dieser muss nicht bei jeder Fräsoperation aktiv sein; stattdessen kann der Betrieb in Zeiten eines günstigen Strompreises (mit einem hohen Anteil erneuerbare Energien) verschoben werden. Die Cumulocity-Plattform unterstützt das Schreiben von OPC UA Variablen auf die Steuerung. Dies geschieht über einen Microservice.

- Modellierung der Linearschleifmaschinen bei Bosch Rexroth mit Petri-Netzen

Die Arbeiten zur Erstellung von Modellen der Produktionsanlagen bei Bosch Rexroth umfasste ein Software-in-the-loop-System, das auch animierte Bewegungen als Simulation enthält. Es erfolgte die Einbindung von SPS-Funktionen in den digitalen Zwilling und die Validierung.

Als Modellierungsstrategie wurden dabei Petri-Netze erprobt. Der Vorteil der Petri-Netze ist die einfache Abbildung ereignisdiskreter Systeme. Bei genauer Betrachtung der Fertigungssystem stellt sich diese Annahme als grob vereinfachend dar. Es handelt sich um ein gemischtes System aus wertekontinuierlich (z.B. Energiebedarf der Hauptspindel – Zeitkonstante im Bereich $< 31,25 \mu s \rightarrow$ Stromregler) und wertediskreten Daten (Grundlast der Maschine– Zeitkonstante im Bereich $> 20 ms \rightarrow$ SPS Taktzeit). Da jedoch nicht die einzelne Bearbeitung, sondern ein produziertes Werkstück (Zeitkonstante im Bereich $> 2 min$) und dessen Qualität betrachtet werden soll, ist diese Vereinfachung möglich. Als Systemklasse kann ein zeitbewertetes ereignisdiskrete System angenommen werden. In Abbildung 2.62 ist eine grundlegende Konfiguration aufgezeigt. Die wesentlichen Zustände ($p_1 = \text{Aus}$, $p_2 = \text{Hochlauf}$, $p_3 = \text{Warten}$, $p_4 = \text{Bearbeiten}$, $p_5 = \text{Warten auf Werkzeugwechsel}$, $p_6 = \text{Werkzeugwechsel}$) werden durch Schalten der zugehörigen Transitionen t_1 bis t_8 gewechselt. Das Schalten erfordert einen Marker bzw. Punkte im vorgelagerten Zustand bzw. Speicher ($R_1 = \text{Maschinenbediener}$, $R_2 = \text{Rohteil}$, $R_3 = \text{Werkzeugabnutzungsvorrat}$) und einen noch freien Platz im nachfolgenden Speicher oder Zustand ($R_4 = \text{Platz}$) für fertige Werkstücke. Die jeweiligen Zustände (p_1 bis p_6) müssen noch um den Zustand des Energiebedarfes erweitert werden. Des Weiteren bedarf es der entsprechenden Parameter und Schaltbedienungen.




Abbildung 2.62: Grundlegendes Petri-Netz für die Beschreibung einer Bearbeitungsmaschine (Systemgrenze gestrichelt) mit unterschiedlichen Zuständen.

- Lastspitzenglättung an den Werkzeugmaschinen im DC-Verbund in der ETA Fabrik

Am PTW wurde im Rahmen einer studentischen Arbeit [116] erfolgreich eine Lastspitzenglättung im Verbundbetrieb der beiden Werkzeugmaschinen EMAG Y und EMAG GT erreicht. Die Maschinen stellen im Verbund eine Steuerscheibe für ein hydraulisches Aggregat her. Abbildung 2.63 ist der Versuchsaufbau mit den beiden EMAG-Maschinen schematisch dargestellt. In der Darstellung ist außerdem ein DC-Schaltschrank zu sehen, der die Wechselrichter der jeweils 5 Achsen der Maschinen mit elektrischer Energie in Form von Gleichspannung versorgt.




Abbildung 2.63: Versuchsaufbau der EMAG Y und EMAG GT im Verbundbetrieb in der ETA-Fabrik [116].

Um die Lastspitzenglättung durchführen zu können, wird während des Betriebs die Lastaufnahme der Maschinen aufgezeichnet. Dies geschieht entweder über die Informationen, die die Wechselrichter der

Maschinenachsen bereitstellen oder über Messklemmen. In Abbildung 2.64 ist die Position der Messklemmen im DC-Schaltschrank gezeigt.




Abbildung 2.64: Topologie des DC-Schaltschranks und Position der Messklemmen [116].

An der Stelle (a) in Abbildung 2.64 befindet sich eine feste Messtelle der Firma Janitza vom Typ UMG604 mit einer Messunsicherheit von 0,4 %, die die Eingangsleistung des DC-Schaltschranks misst. An den Stellen (b) wurden mobile Messklemmen eingesetzt, um die gemeinsame Leistung der Nebenaggregate aufzunehmen, sowie die des Versorgungsgeräts, das die 3-Phasen-Wechselspannung in eine Gleichspannung wandelt. Ebenfalls mit mobilen Klemmen wird die Leistung der Bremseinheiten gemessen, die die rekuperierte Energie der Werkzeugmaschinen in thermische Energie umwandeln, wenn die dort platzierten Kondensatoren diese Energie nicht vollständig aufnehmen können. Zuletzt sind an den Stellen (c) 2 Klemmen QI-POWER-485 fest installiert, die die jeweilige Gesamtleistung der Achsen einer Maschine aufnehmen. Sie haben einen Messbereich von 0,25-50 A DC bzw. 0-1000 V bei einem relativen Fehler von <0,5 %. Die Zwischenkreisspannung beträgt 750 V. Mit den Klemmen kann der ganze Leistungsbereich der Werkzeugmaschinen abgedeckt werden.

In der durchgeführten Arbeit wurde eine Lastspitzenglättung erreicht, indem verhindert wurde, dass Lastspitzen in beiden Maschinen gleichzeitig auftreten. Dies wurde durch das Pausieren lastintensiver NC-Schritte der EMAG Y erreicht. Die Betriebsmodus der EMAG GT blieb davon unberührt. So konnte eine Reduktion des Spitzenstrombedarfs um 29 % erreicht werden.

Um die Reduktion der gemeinsamen Spitzenlast mittels NC-Warteschritt umsetzen zu können, wurden in einem ersten Schritt die Lastverläufe der beiden Maschinen mit den NC-Schritten für den jeweiligen Bearbeitungsvorgang korreliert. Dadurch ist bekannt, welche Schritte besonders lastintensiv sind. NC-Code und Lastverläufe wurden mittels OPC UA ausgelesen. Diese besonders lastintensiven Schritte wurden bei der EMAG Y pausiert, falls sie gleichzeitig mit Lastspitzen der EMAG GT auftreten würden.

Dazu wurde ebenfalls mittels OPC UA ein Warteschritt in den NC-Code der EMAG Y eingefügt. Die Lastspitzen treten so nun nicht mehr gleichzeitig, sondern nacheinander auf.

Mit der beschriebenen NC-Schritt-Pausierung konnte eine Lastspitzenreduktion erreicht werden, die nur einen geringfügigen Einfluss auf die Maschinenverfügbarkeit hat. Es wurde allerdings nur das Pausieren der EMAG Y untersucht und nicht zusätzlich die Möglichkeit des Pausierens der EMAG GT. Des Weiteren ergaben sich Einschränkungen durch die eher geringen Abtastraten der Lastverläufe von 10 Hz. Die Spitzenlasten schwankten, weil die tatsächliche Lastspitze teilweise zwischen zwei Abtastpunkten lag.

- Hybrides Speichersystem für Lastspitzenglättung am Hauptanschluss der ETA Fabrik

Im Rahmen des Anwendungsfalls zum hybriden Speicher wurden neue Betriebsstrategien untersucht, insbesondere das Peak-Shaving mittels verschiedener Algorithmen. Abbildung 2.65 zeigt die oberste Ebene des Modells des hybriden Speichersystems. Innerhalb der Subblöcke befinden sich detaillierte Strukturen bis hin zur präzisen Abbildung der Betriebsparameter.




Abbildung 2.65: Modellierung des hybriden Energiespeichers in Matlab.

Der gelb hinterlegte Block stellt das Modell der Batterie dar. Die physikalischen Zusammenhänge wurden entsprechend [117] modelliert, während die Kennfelder der Widerstände und Kapazitäten aus [118] übernommen wurden. Das Modell des Schwungmassenspeichers basiert auf der Arbeit von Schneider [119]. Die zugehörigen Kennfelder wurden mithilfe der Finite-Elemente-Methode (FEM) gemäß [120] ermittelt und in das Modell integriert. Alle Parameter, die während des Betriebs optimiert werden können, sind als Ein- und Ausgänge zugänglich – auch nach dem Export als Functional Mock-up Unit (FMU). Um die Modellgenauigkeit weiter zu verbessern und Abweichungen zum realen System zu minimieren, wurde untersucht, ob sich der Offset zwischen Messdaten und Simulationsergebnissen durch ein neuronales Netz (NN) korrigieren lässt. Dafür wurden sowohl Feedforward- als auch LSTM-Netze getestet, wobei LSTM-Netze die besseren Ergebnisse erzielten. Tabelle 2.14 zeigt die berechneten Fehlermetriken (RMSE) für Modelle mit und ohne neuronale Netze zur Offset-Kompensation. Eine signifikante Verbesserung konnte jedoch nicht festgestellt werden. Gleichzeitig führte die Integration der neuronalen Netze zu einem deutlich höheren Rechenaufwand. Aufgrund dieser Nachteile wurde der Ansatz im weiteren Projektverlauf verworfen.

	RMSE ohne NN	RMSE mit NN
Leistung BESS	1,5393 kW	1,4202 kW
SoC BESS	0,1202 %	0,0542 %
Leistung KESS	4,0464 kW	0,9743 kW
SoC KESS	0,0303 %	0,0193 %

Tabelle 2.14: RMSE bei der Abbildung des Offsets zwischen realen Messdaten und der Simulation des hybriden Speichers durch neuronale Netze.

Ein großes Argument für die Kombination Schwungmassenspeicher und Batterie ist die Verlangsamung der Batteriealterung, weshalb auch diese im Modell abgebildet werden sollte. Dabei wurde zwischen kalendarischer Alterung, die auch bei Nichtbenutzung der Batterie auftritt, und zyklischer Alterung, die durch Lade- und Entladezyklen verursacht wird, unterschieden. Um eine geeignete Modellierungsgrundlage zu finden, wurden zwei etablierte Alterungsmodelle analysiert. Das erste Modell, entwickelt von Schmalstieg et al. [121], beschreibt sowohl Kapazitätsverluste als auch Widerstandszunahmen auf Basis experimenteller Daten. Es berücksichtigt die Auswirkungen von Temperatur und Ladestand auf die Batteriealterung, nutzt jedoch keine detaillierte Abbildung der Lade-Rate als Einflussfaktor. Das zweite Modell, vorgestellt von Smith et al. [122], kombiniert datengetriebene und physikalische Ansätze und berücksichtigt explizit die Lade-Rate (C-Rate) als zusätzliche Einflussgröße. Da dieses Modell eine bessere Übereinstimmung mit den betrachteten prismatischen Zellen (50 Ah) des untersuchten Speichersystems zeigte, fiel die Wahl auf dieses Modell.

Die Implementierung des Alterungsmodells erfolgte in der Simulationsumgebung Matlab/Simulink. Dabei wurden als Eingangsgrößen die Zelltemperatur, der aktuelle Ladestand (SOC) sowie der Zellstrom verwendet. Die Berechnung der Alterung wurde in zwei Schritte unterteilt: Die kalendarische Alterung wurde kontinuierlich über die Zeit erfasst, indem der Einfluss von Temperatur und SOC auf die Alterung mathematisch beschrieben wurde. Die zyklische Alterung hingegen wurde anhand von Ladezyklen, Entladetiefe (DOD) und Lade-Rate bestimmt. Dabei wurde ein empirischer Ansatz gewählt, der aus experimentellen Testdaten ableitbare Alterungsmechanismen beschreibt. Durch die Kombination beider Alterungskomponenten wurde schließlich die relative Gesamtkapazität nach Alterung [122] berechnet und in das bestehende Speichermodell integriert.

- Multiagentensystem mit Produktionsmaschinen

Im Rahmen des Projekts wurde ein Konzept zur Koordination mehrerer optimierter Produktionsmaschinen erarbeitet und teilweise umgesetzt. Es wurde eine Literaturrecherche durchgeführt, bei der keine vergleichbaren Arbeiten identifiziert wurden. Im Anschluss wurde folgender Anwendungsfall definiert: Agentenbasierte Betrachtung der Reinigungsmaschine MAFAC KEA sowie der Schleifmaschine EMAG GT mit dem Ziel der Koordination über die kostenoptimale Verwendung der in der ETA-Fabrik verfügbaren Erzeugung der geplanten PV-Anlage sowie der Blockheizkraftwerke. Zur Umsetzung wurde ein Kommunikationsframework auf Basis von ZeroMQ implementiert, welches eine Simulation der PV-Anlage mit der bereits existierenden Demand Response Optimierung der MAFAC KEA, sowie mit einer Bedarfsprognose der EMAG GT kommunikativ verbindet. Im Anschluss wurde mit der Implementierung der einzelnen Agenten begonnen. Während der Bearbeitung traten jedoch Probleme bei der Integration der Energie-Verfügbarkeit in die Optimierung auf. Durch die Integration der Verfügbarkeit in die mathematische Optimierung der KEA wurde das Optimierungsproblem komplexer,

und weiterführende Untersuchungen zur Lösbarkeit dieses Problems dauern an. Aus diesem Grund konnten die Arbeiten zu MS 5.1.7 nicht im Projektzeitraum abgeschlossen werden, und werden nun in einem Folgeprojekt verankert.

Zusammenfassung der Arbeiten je Partner

PTW (Leitung):

- Implementierung eines Demand Response Datenmodells in der Steuerung der MAFAC KEA
- Erarbeitung eines Konzepts zur Lastspitzenglättung im DC-Verbund und Umsetzung an den Werkzeugmaschinen in der ETA-Fabrik inklusive Durchführung von Versuchen zur Lastspitzenglättung an den Werkzeugmaschinen
- Erarbeiten des energieoptimierten Betriebs eines Hermle Bearbeitungszentrums für die Herstellung des Rohlings der Steuerscheibe
- Erarbeitung eines Konzepts und Aufbau eines cyber-physischen Systems zur energieflexiblen Optimierung der Reinigungsmaschine MAFAC KEA in der ETA-Fabrik
- Modellierung der Produktionsanlagen und Entwicklung eines Algorithmus zur Ansteuerung der Reinigungsmaschine MAFAC KEA
- Implementierung eines Demand Response Datenmodells in der Steuerung der MAFAC KEA sowie eines Demand Response Optimierungsmodells in eta_utility
- Validierung der Interaktion der beiden Modelle in mehreren Feldversuchen
- Erarbeiten eines Konzepts zum energieoptimierten Betrieb eines Hermle Bearbeitungszentrums für die Herstellung des Rohlings der Steuerscheibe
- CAM-Fertigung des Steuerscheibenrohlings an einem Bearbeitungszentrum sowie CO₂-Bilanzierung des Rohlings
- Erarbeitung eines Konzepts zur agentenbasierten Koordination von Produktionsmaschinen

Bosch:

- Konzeption eines digitalen Zwillings einer Werkzeugmaschine als reines Software-in-the-loop-System
- Erstellung eines digitalen Zwillings mit animierter Bewegung und Abtrag 3D Simulation
- Einbindung der SPS-Funktion in den digitalen Zwilling
- Validierung des digitalen Zwillings durch geeignet NC-Programme
- Modellabgleich auf den jeweiligen Abstraktionsebenen

IMS:

- Modellierung des hybriden Speichers (sowohl Batteriespeicher als auch kinetischer Speicher) in Matlab und Separierung von Optimierungsalgorithmen für eine Überführung in eine Stand-Alone-FMU
- Abbildung des Offsets zwischen Simulationsmodell und realen Messdaten durch neuronale Netze
- Abbildung der Batteriealterung im Modell

2.5.2. Arbeitspaket 5.2: Energieeffiziente und -flexible Fabriksteuerung

In diesem Arbeitspaket wurde eine Anwendung entwickelt, welche auf Basis der Modelle aus den vorangehenden Teilprojekten eine energetisch möglichst optimale Betriebsstrategie für die Produktion

ausgibt. Zudem war ein wichtiger Bestandteil die Entwicklung von Strategien für die Abbildung des Fertigungssystems in der Optimierungsanwendung. So sollte die energieorientierte Optimierung der Produktionsplanung auch für Anwender mit geringer Expertise im Bereich der Optimierung zugänglich werden.

Die entwickelte Anwendung integriert sich in das Optimierungsframework `eta_utility`, dessen Entwicklung im Rahmen dieses Arbeitspakets hauptsächlich vorangetrieben wurde, das jedoch auch in Arbeitspaketen der Teilprojekte 2 und 4, sowie in den weiteren Arbeitspaketen des Teilprojekts 5 zum Einsatz kommt. Das Framework bietet die Möglichkeit, mit industriellen Anlagen zu kommunizieren und gleichzeitig die KI-basierten Betriebsoptimierungsalgorithmen aus den Arbeitspaketen 5.1, 5.2 und 5.3 einzubinden [123]. Das Framework ist als Python Softwarepaket im Python Package Index (pypi) und auf Github verfügbar:

- <https://pypi.org/project/eta-utility/>
- https://github.com/PTW-TUDa/eta_utility/




Abbildung 2.66: Struktur des `eta_utility` Software Frameworks [123]

Für die Veröffentlichung wurde eine freie OpenSource Lizenz (BSD 2-clause) gewählt, sodass die Software frei verfügbar ist und von allen potenziellen Nutzern problemlos eingesetzt werden kann. Einzelne Teile des Frameworks konnten dabei aus vorherigen Arbeiten weiterverwendet werden, ein Großteil der Inhalte wurde jedoch unter Berücksichtigung der Anforderungen aus dem Projekt KI4ETA neu entwickelt oder grundlegend angepasst. Insbesondere die Interoperabilität der verschiedenen Teile des Frameworks war dabei ein Fokus.

In Abbildung 2.66 ist die Struktur des Frameworks dargestellt. Ein zentraler Teil des Frameworks sind die Module für die rollierende Optimierung (bezeichnet als ETAx) [123]. Diese stammen in ihrer

ursprünglichen Form aus dem Projekt PHI-Factory, wurden jedoch für KI4ETA weiterentwickelt, um mehr Flexibilität bei der Auswahl verschiedener Algorithmen zu gewährleisten und zusätzlich die Abbildung von Systemen als digitale Zwillinge (Interaktion zwischen einer realen und einer virtuellen Umgebung / Environment) zu ermöglichen. Weiterhin wurden Konnektoren (connectors) entwickelt, um Daten von den Anlagen zu erfassen und Daten auf die Anlagen schreiben zu können [123]. Mit Simulatoren (simulators) können Anlagen oder Anlagenteile simuliert werden und mithilfe von Zeitserienverarbeitung (timeseries) können Prognosedaten oder Vergangenheitsdaten, wie Sie beispielsweise im Teilprojekt 4 generiert werden, genutzt werden [123].

Im Rahmen dieses Arbeitspakets wurde in das Framework zudem eine Unterstützung für Julia Code integriert. Julia hat im Vergleich zu Python den Vorteil eines Just-in-Time Compilers, welcher die Geschwindigkeit der Programmabarbeitung deutlich erhöht. In Julia wurden die Fabrik und Anlagenmodelle sowie ein heuristischer Lösungsalgorithmus implementiert. Als Lösungsalgorithmus wurde, auf der Basis einer ausführlichen Literaturrecherche, der NSGA-II Algorithmus [124] ausgewählt.

Im Rahmen dieses Arbeitspakets wurde zudem die Datenanbindung der Maschinen in der ETA-Fabrik und bei Bosch getestet und weiter optimiert, um im Laufe des Projekts Maschinendaten zu erfassen und auszuwerten. Die erfassten Daten wurden im Rahmen des Arbeitspakets 4.3 (siehe Abschnitt 2.4.3) genutzt, um Regressionsmodelle zu parametrieren, welche wiederum in diesem Arbeitspaket für die Optimierung der Fabriksteuerung zum Einsatz kamen.

Da ein Fokus in diesem Arbeitspaket auf der vereinfachten Anwendbarkeit der Optimierungsanwendung lag werden, neben der automatisierten Modellparametrierung aus Arbeitspaket 4.3, ein Implementierungsverfahren und eine Systemarchitektur für Produktionsplanungssysteme vorgeschlagen, welche es ermöglichen, das Produktionsplanungssystem über Konfigurationsdateien an verschiedene Fertigungsprozesse anzupassen. Dabei stellt das Implementierungsverfahren sicher, dass die Bedürfnisse aller Stakeholder im Implementierungsprozess berücksichtigt werden [104].

Das Implementierungsverfahren besteht aus drei Phasen [104]:

- 1) In einer Planungsphase werden die Anforderungen an das energiebewusste Produktionsplanungssystem und die vorliegenden Voraussetzungen in der Fabrik untersucht.
- 2) In der Entwicklungs- und Konfigurationsphase werden Daten für die Konfiguration des Systems erfasst und potenziell fehlende Komponenten im System ergänzt, um die vorliegende Fabrik vollständig abbilden zu können.
- 3) Zuletzt werden in der Umsetzungsphase Nutzer in das System eingeführt und verschiedene Funktionstests durchgeführt, bevor das System in die Nutzung übergeht.

Ähnliche Implementierungsverfahren liegen bereits für konventionelle Produktionsplanungssysteme oder Manufacturing Execution Systeme vor, allerdings berücksichtigen diese typischerweise nicht die besonderen Bedürfnisse einer energiebewussten Produktionsplanung [104]. Diese Bedürfnisse ergeben sich insbesondere aus dem erweiterten Kommunikationsbedarf mit Produktionsmaschinen und externen Entitäten, wie dem Energieanbieter. Weiterhin ist zu berücksichtigen, dass die Energiemodelle der Produktionsmaschinen aus Arbeitspaket 4.3 vorbereitet und mit einer ausreichenden Datengrundlage versorgt werden müssen, damit die Parametrierung erfolgreich umgesetzt werden kann [104].

Neben dem Implementierungsverfahren wird eine Systemarchitektur für das Produktionsplanungssystem vorgeschlagen, welche eine einfache Anpassung auf verschiedene

Produktionssysteme ermöglicht. Die Systemarchitektur basiert, wie bereits erwähnt, auf dem eta_utility Framework [123].

Die Systemarchitektur ist in Abbildung 2.67 abgebildet und besteht aus der Produktionssystemkonfiguration, welche genutzt wird, um das Produktionsplanungssystem auf unterschiedliche Fertigungsstrukturen anzupassen. Die Produktionssystem-Umgebung ist die Umgebung im eta_utility Framework, welche als virtuelles Abbild des realen Produktionssystems interpretiert werden kann. Die Produktionssystemumgebung besteht aus den energetischen Maschinenmodellen, sowie Informationen zu Produktionsaufträgen und Lagerbeständen. Der Optimierungsalgorithmus greift auf die Daten der Produktionssystemumgebung zu und erstellt auf dieser Basis optimierte Produktionspläne, welche in der virtuellen Produktionssystemumgebung simuliert und bewertet werden können. [104]




Abbildung 2.67: Systemarchitektur des energieorientierten Produktionsplanungssystems [104].

Abbildung 2.68 stellt ein Ergebnis der Produktionsplanung für die ETA-Fabrik dar. Im Vergleich zu einer konventionellen Planung, beispielsweise mittels Zuordnungsregeln, konnte im vorliegenden Fall der Fertigung von 10 Aufträgen eine Energiekosteneinsparung von 26 % erreicht werden. Gleichzeitig wurde der produktionsrelevante Parameter der Produktionsdauer um 6 % reduziert, sodass im Vergleich zum konventionellen Planungsansatz nicht nur eine Energieoptimierung stattfand, sondern gleichzeitig ein besserer Wert für die produktionsrelevante Zielfunktion erreicht werden kann. [104]

Im Durchschnitt über mehrere Experimente mit unterschiedlichen Auftragszahlen konnte so eine Verbesserung der Produktionsdauer um 6 % bei gleichzeitiger Verbesserung der Energiekosten um 13 % erreicht werden. Wenn bei der Optimierung stattdessen ein stärkerer Fokus auf die Verbesserung der Energiekosten gelegt wird, ist eine Verbesserung der Energiekosten um 18 % bei einer Verschlechterung der Produktionsdauer um lediglich 6 % möglich. [104]




Abbildung 2.68: Ergebnis der Produktionsplanung für 10 Aufträge in der ETA-Fabrik [104].

Modellierungsansatz mit Petri-Netzen

Da im Arbeitspaket verschiedene Optimierungsansätze untersucht werden sollten, wurde neben der Optimierung mittels des NSGA-II Algorithmus ein Modellierungsansatz mit Petri-Netzen, vergleichbar einem Zustandsautomaten [125] wie in Abbildung 2.69 skizziert, untersucht.




Abbildung 2.69: Petri-Netz Modell einer Werkzeugmaschine mit den Zuständen: Waren auf Werkzeugwechsel, Werkzeugwechsel, Leerlauf, Aus, Warmlauf / Starten, Bearbeitung.

Aufgrund ihrer Systemeigenschaften, wurde in diesem Fall der Mixed Integer Programming und Mixed Integer Nonlinear Programming Optimierer „Solving Constraint Integer Programs (SCIP)“ für die Lösung des Optimierungsproblems ausgewählt [126]. Dieser Optimierer hat über 1600 Hyperparameter die eingestellt und ggf. verbessert werden können, um die Optimierung schneller durchführen zu können.

Das implementierte Verfahren eignet sich prinzipiell zur automatisierten Einstellung von Hyperparametern für die Optimierung mit Petri-Netzen, sodass dieser Ansatz zur energieoptimierten Fertigungssteuerung auch insgesamt vielversprechende Ergebnisse liefert.

Weitere Stellgrößen zur Optimierung der Fertigungssteuerung

Neben der Reihenfolgeplanung, gibt es weitere Möglichkeiten, in die Fertigungssteuerung einzugreifen, um den Energieverbrauch zu optimieren. Wie in Arbeitspaket 5.1 festgestellt, kann es teilweise sinnvoll sein, Maschinenparameter zu verändern, welche keinen signifikanten Einfluss auf die Prozessqualität haben. Weitere Stellgrößen für Werkzeugmaschinen sind somit:

- Nebenaggregate, wenn nicht prozessrelevant (z.B. KSS für Reinigung)
- Bewegungen die nicht während des Eingriffes stattfinden
 - Werkzeugwechsel (Annahme eine Bahnstrecke von 250 mm wird benötigt)
- Werkzeugüberwachungen wie Laserlichtschranke
 - Erhöhung der Span-zu-Span-Zeit
 - Bewegungen am Anfang oder Ende einer Bearbeitung

Traditionelle Ansätze, ohne Berücksichtigung der Energie, haben beispielsweise die Senkung der Wechselzeit Span-Span zum Ziel, hierfür werden die maximalen Beschleunigungen gefahren. Im Folgenden wird von einer 7-Phasen-Bewegung [127] ausgegangen. Bei üblichen Werten ergibt sich das in Abbildung 2.70 dargestellt Profil:

- Ruck = 7000 m/s³
- Beschleunigung = 2 g = 20 m/s²

- Geschwindigkeit = 1,5 m/s = 90 m/min
- Masse = 100 kg




Abbildung 2.70: Begegnungsprofil eines möglichen Werkzeugwechsels.

Für die Bewegung sind 0,2440 s nötig und es werden etwa 66,7 Wh ($W = F \cdot v$) in Form von mechanischer Leistung benötigt. Bei einer Reduktion der Parameter auf:

- Ruck = 1000 m/s³
- Beschleunigung = 0,5 g = 5 m/s²

wird die gewünschte Geschwindigkeit nicht mehr erreicht. Für die Bewegung sind nun 0,4520 s anstatt 0,2440 s nötig und es werden nur noch 33,9 Wh anstatt von 66,7 Wh in Form von mechanischer Leistung benötigt. Bei einer üblichen Bearbeitung kann von ca. 20 Werkzeugwechseln in 5 Minuten ausgegangen werden. Neben der Wirksamkeit ist eine Reduktion von Ruck und Beschleunigung durch eine Anpassung des NC-Codes möglich. Somit kann für jedes Werkstück eine optimierte Beschleunigung eingestellt werden.

Weiter gilt es zu beachten, dass durch den geringeren Energieeintrag es zu Nebeneffekten wie einem veränderten thermischen Betriebspunkt und einer Beeinflussung der geometrischen Genauigkeit kommen kann. Hier können Thermomanagementsysteme Abhilfe schaffen.




Abbildung 2.71: Begegnungsprofil eines reduzierten möglichen Werkzeugwechsels.

Validierung der entwickelten Verfahren bei Bosch

Das im Projekt entwickelte Verfahren wurde zusätzlich in einem Werk von Bosch Rexroth anhand der Planung von zwei Schleifmaschinen für Linearführungen validiert. Dafür wurden zunächst über mehrere Wochen Energie- und Produktionsdaten der Maschinen aufgezeichnet. Diese sind in Abbildung 2.72 dargestellt.




Abbildung 2.72: Messdaten einer Schleifmaschine im Werk bei Bosch Rexroth (normiert auf den Mittelwert).

Anhand der Energiedaten konnte, wie in Abbildung 2.73 dargestellt, eine Optimierung der Produktionsreihenfolge über vier Tage erstellt werden. Diese Optimierung mit dem Optimierungsziel energiebezogene Kosten konnte ein Einsparpotenzial von 9 % bei Einhaltung der gesetzten Schichtzeiten zeigen.




Abbildung 2.73: Optimierter Produktionsplan mit dem Optimierungsziel energiebezogene Kosten.

Zusammenfassung der Arbeiten je Partner

PTW:

- Entwicklung und Veröffentlichung des Software Frameworks eta_utility, auf dessen Basis die verschiedenen Energieoptimierungsansätze in diesem Teilprojekt umgesetzt werden können.
- Entwicklung eines Implementierungsverfahrens für die Abbildung verschiedener Fertigungssysteme unter Einbeziehung unterschiedlicher Anforderungen und Zielfunktionen aus der Industrie.
- Umsetzung einer Systemarchitektur zur Fertigungssteuerung als Cyber-Physisches Produktionssystem unter Gewährleistung der notwendigen Datenerfassung.
- Literaturrecherche zum Vergleich verschiedener Optimierungsansätze und Auswahl des Optimierungsverfahrens.
- Vorbereitung, Durchführung und Auswertung von Produktionstagen in der ETA-Fabrik zur Datenerfassung und Validierung des entwickelten Systems. Zusätzlich Kooperation mit Bosch und Bosch Rexroth zur Bewertung der Übertragbarkeit des entwickelten Systems.
- Parametrierung der Modelle aus AP 4.3 und der Algorithmen für die Produktionsplanung

Bosch:

- Zusammenarbeit mit PTW zur Definition der Anforderungen an das Optimierungssystem und die Zielfunktionen.
- Entwicklung von Betriebsstrategien zur Optimierung der Energieeffizienz von Werkzeugmaschinen unter Berücksichtigung der Anforderungen aus Produktionsplanung und Werkstückqualität
- Durchführung von Versuchen mit dem entwickelten Optimierungssystem im Bosch Rexroth Werk Schweinfurt.

- Untersuchung von Verfahren zur bedienerfreundlichen bzw. automatisierten Einstellung von Hyperparametern für die Optimierung

2.5.3. Arbeitspaket 5.3: Energieeffiziente und -flexible Fabrikversorgung (Betriebsoptimierung Versorgungstechnik)

Die Arbeiten in AP 5.3 fokussieren sich auf die Optimierung der Versorgungstechnik. Es wurden durch die beteiligten Partner drei verschiedene versorgungstechnische Anwendungsfälle betrachtet. In der ETA-Fabrik wurde sowohl die gesamte thermische Versorgungstechnik als auch der Betrieb des hybriden, elektrischen Energiespeichers optimiert. Der Anwendungsfall bei CuroCon fokussierte sich auf die gemeinsame Optimierung von Klimatisierung und Ladepark. Ökotec betrachtete eine Verbundkälteanlage. Im Folgenden sind die Arbeiten nach Anwendungsfall aufgeschlüsselt genauer ausgeführt.

1) Hybrider Energiespeicher:

Für die Erprobung verschiedener Agenten wurde das von Grosch et al. (2022) [123] entwickelte Paket eta-utility verwendet. Für alle Agenten wurde ein Environment definiert, in welchem das FMU-Modell des hybriden Energiespeichers eingebaut wurde. Ansonsten wurde das Environment des Agenten angepasst. So wurde bspw. bei Deep Reinforcement Learning (DRL) eine Reward-Funktion definiert. Bei Mixed-Integer-Linear-Programming (MILP) wurden das Pyomo-Modell und die Zielfunktion sowie die Nebenbedingungen in das Environment eingebaut. Für die Simulation konventioneller Algorithmen waren deren Regler in der Environment-Datei festgelegt. In einer json-Datei werden alle Settings für den jeweiligen Agenten definiert, sowie Ausgangsdaten für Inputs und Speicherpfade. Zuletzt werden in einer Experimente-Datei alle Unterdateien nacheinander aufgerufen und noch einmal der finale Speicherort angegeben, sowie das Experiment gestartet. Im Falle von DRL kann hier sowohl ein Trainingsdurchlauf als auch ein Testdurchlauf mit dem zuvor trainierten Netz durchgeführt werden.

Für die konventionelle Ansteuerung wurde ein sehr einfach gehaltener Regler implementiert, der direkt das bereits vorhandene Wissen über die Vor- und Nachteile der Speicher zu Nutze machte. So wurde der Schwungmassenspeicher für hohe Frequenzen genutzt, und wenn diese nicht mehr abgedeckt werden konnten, kam die Batterie zum Einsatz, sodass deren Zyklenzahl und somit auch die Alterung verringert werden konnte.

Für die mathematische Optimierung und das DRL wurde eine Zielfunktion entwickelt, welche die Strompreise (Leistungs- und Arbeitspreis), Verluste und Alterung der Speicher berücksichtigten. Für das DRL wurden zudem verschiedene Hyperparameter, wie der Lernrate getestet, wobei die Ergebnisse keine signifikanten Unterschiede aufwiesen. Einen größeren Einfluss hatte die Variation der Rewardfunktion, wobei für den Vergleich der drei Agenten alle oben genannten Positionen beinhaltet waren.

Bei MILP wurden die Verluste und Ladezustände der Speicher linearisiert und flossen als Nebenbedingungen ein.




Abbildung 2.74: Simulierter Lastverlauf der Fabrik mit konventioneller Steuerung des hybriden Speichers




Abbildung 2.75: Simulierter Lastverlauf der Fabrik mit Steuerung durch DRL des hybriden Speichers




Abbildung 2.76: Simulierter Lastverlauf der Fabrik mit Steuerung durch MILP des hybriden Speichers

Die Ergebnisse (Abbildung 2.74, Abbildung 2.75, Abbildung 2.76) zeigen deutlich, dass mittels mathematischer Optimierung alle Lastspitzen abgedeckt werden konnten. Der implementierte konventionelle Algorithmus konnte keine Leistung im Speicher vorhalten, bevor die größten Peaks verursacht wurden.

Bei DRL ist anzunehmen, dass der Agent noch kein Optimum für seine Entscheidungsregeln gefunden hat. Dies kann u. a. an der evtl. zu kleinen Datengrundlage, ungeeigneten Hyperparametern, oder zu kurzer Trainingsdauer liegen.




Abbildung 2.77: Ergebnisse der simulierten Agenten zur Steuerung des hybriden Speichers.

Abbildung 2.77 verdeutlicht noch einmal, dass mathematische Optimierung die Lastspitzen am stärksten reduziert, daneben aber zusammen mit dem konventionellen Regler die geringsten Verluste an den Speichern erzeugt. Interessanterweise setzt MILP im Vergleich am häufigsten die Batterie und am wenigsten den Schwungmassenspeicher ein. Dies könnte daran liegen, dass die Verluste der Batterie bei gleicher Belastung im Verhältnis geringer waren.

2) Kühltager

ÖKOTEC hat in Zusammenarbeit mit dem assoziierten Partner Energieering und dem Betreiber des Kühltagers einen Demonstrator aufgebaut, mit dem die Energiekennzahlenmodellierung als Betriebsoptimierung vor Ort getestet werden konnte. In die bestehende Leittechnik am Standort wurde ein Modus programmiert, in der Anlagenzustände als Sollwerte für die Anlagensteuerung aus der Software EnEffCo® übernommen werden können. Das Energiekennzahlenmodell (siehe AP 3.5) inkludiert eine Temperaturmodellierung, bei der effiziente Zustände für die Wahl der Verdichter und einer Kombination von Lüftern in den Kühlzonen gefunden werden, die im Betrieb innerhalb der nächsten Tage die Energiekosten minimiert, aber die Temperaturrestriktionen der Kühlkette einhält. Zudem gibt es die Möglichkeit, über Penalties auch weiter vorausschauend die Temperaturen so zu wählen, dass weiter in der Zukunft liegende Strompreise durch eine flexible Fahrweise berücksichtigt werden. Damit nutzt das Modell das Kühltager vorrausschauend als eine Art Energiespeicher. Das Modell lief einmal und hat den Fahrplan für die nächsten Tage erstellt. Mit den Verdichterkombinationen wird auch die Kombination von Verdampfern und Lüftern in den Kühltagerzonen so bestimmt, dass die

Verdichter immer voll ausgelastet sind und so im effizientesten Zustand laufen. Die vorausgehende Modellierung ergab, dass bei einem Verdichter die Vorzone sowie ein Lüfterpaar im Hochregallager laufen kann. Bei einem zusätzlichen Verdichter müssen dann drei weitere Lüfterpaare eingesetzt werden.

Die Einrichtung der Schnittstellen zwischen EnEffCo® und der Anlagensteuerung der Kälteverbundanlage zur Demonstration der Betriebsoptimierung konnte erfolgreich umgesetzt werden. Es war möglich, nach manueller Anfrage bei der Steuerungsleittechnik der Verbundkälteanlage sowohl für die Begrenzung der Zahl der Verdichter als auch für die aktive Sollwertvorgabe der Lüfter bzw. Verdampferventile der Kühlstellen im Hochregallager als Zustandssollwerte vorzugeben.

Unter Berücksichtigung eines Sicherheitskonzeptes zur Vermeidung der Überschreitung von Grenzwerten können nur Sollwerte direkt in die Steuerung geschrieben werden. Der Optimierungsalgorithmus erstellt täglich einen viertägigen Fahrplan (die nächsten 384 1/4h-Zeitintervalle) für die jeweiligen Sollwerte und exportiert diese an die Steuerung. Da die Betriebsoptimierung täglich wiederholt wird, werden die Fahrpläne der zukünftigen Zeiträume jeweils ab dem zweiten Tag überschrieben.

Als Ergebnis kann bestätigt werden, dass die modellierten Temperaturen des Fahrplans gut mit der realen Entwicklung der Hallentemperaturen übereinstimmen. Es kann sogar sein, dass abweichende Aktivitäten des Anlagenbetreibers, z.B. kurzzeitiger Abschaltung von Lüftern oder Rückkühlern zu Prüfzwecken erkannt werden können, die als Modelleinflüsse vorab gar nicht plan- und modellierbar waren. Des Weiteren wurden für eine Erhöhung der Robustheit der Modelle, gerade in Zeiten solcher nicht planbaren Abweichungen, zusätzliche Restriktionen in die Optimierung eingebunden. Z.B. werden bei erhöhter Abweichung zwischen Modell- und Realwert im nächsten Optimierungsschritt die Differenz als erhöhter Startwert mitberücksichtigt. Sollte zudem eine bestimmte Schwelle der Temperatur kurzfristig überschritten sein, die noch unterhalb der Grenzwerte für den automatischen Entzug der Steuerung liegt, dann wird im nächsten Ausführungsschritt eine Beschränkung des minimalen Zeitraums für eine verstärkte Hallenkühlung hinzugefügt.

3) Versorgungstechnik ETA-Fabrik

Das Arbeitspaket begann mit einer Analyse der relevanten Versorgungstechnik und der Festlegung der zu regelnden Anlagen. Parallel dazu wurden Abstimmungen zur Integration des hybriden elektrischen Speichers durchgeführt. In Zusammenarbeit mit etalytics erfolgten Vereinbarungen zur Einbindung der etaOne-Plattform in die ETA-Fabrik sowie zur Kopplung mit dem Optimierungsframework eta-utility.

Daraufhin wurden durch Vergleichsstudien geeignete DRL-Algorithmen, Hyperparameter und Netzwerktopologien identifiziert. Zur Modellierung des thermischen Versorgungssystems der ETA-Fabrik wurde Modelica (Dymola) eingesetzt, wobei erste Parameter durch Messungen abgeschätzt wurden. Anschließend erfolgte das Training eines DRL-Agents am Simulationsmodell mit dem Ziel, diesen auf das reale System zu übertragen.




Abbildung 2.78: Schematischer Überblick über das thermische Versorgungssystem der ETA-Fabrik [105].

Um die Robustheit gegenüber Abweichungen zwischen Simulation und Realität zu gewährleisten, wurden verschiedene Trainingsmethoden verglichen. Dabei erwies sich eine normalverteilte Domänen-Randomisierung (NDR) ausgewählter Simulationsparameter als vielversprechender Ansatz. Simulative Ergebnisse zeigen eine Reduktion der Gesamtkosten um 27 % im Vergleich zur konventionellen Regelung, die hauptsächlich auf eine über 50%-ige Senkung der Schaltkosten zurückzuführen ist. Eine Reduktion der Energiekosten wurde bislang nicht erreicht, könnte jedoch durch eine Anpassung der Kostenfunktion in Zukunft realisiert werden.




Abbildung 2.79: Auswertung der Betriebskosten über 100 simulierter Versuchstage [105].

4) CuroCon-Anwendungsfall

Im CuroCon-Anwendungsfall wurde die Optimierung der Versorgungstechnik abgestimmt, wobei Wärmepumpe, PV und Ladepark als relevant identifiziert wurden. Teile dieser Technik wurden mit Unterstützung von PTW und etalytics an etaOne angebunden.

Eine studentische Arbeit implementierte eine MPC-Optimierung der Wärmeversorgung unter Einbezug der PV-Eigenerzeugung in eta_utility. Die erforderlichen Daten wurden teils über eine neue etaOne-Schnittstelle, teils durch mobile Messungen erfasst. Aufgrund technischer Probleme konnte der Optimierer nicht live getestet werden, aber die Validierung anhand historischer Daten zeigte eine Reduktion des Netzbezugs um 39 % sowie eine verbesserte Einhaltung der Komforttemperatur.




Abbildung 2.80: Realer und modellierter Verlauf der Raumtemperatur mit zugrundeliegenden Wärmequellen [105].

Für die übergeordnete Steuerung wurde eine Beckhoff-SPS mit EtherCat, KNX, ModBus-TCP und OPC UA eingesetzt. Zur Datenerfassung und Steuerung der Klimatisierung wurden verschiedene Sensoren und Aktoren integriert, darunter KNX-Erweiterungsmodule für die Wärmepumpensteuerung, Temperatur- und Durchflusssensoren in den Wasserkreisläufen sowie KNX-Regler und Ventil-Aktoren für die Raumklimatisierung. Eine KNX-Wetterstation auf dem Dach liefert aktuelle Wetterdaten für Prognosevergleiche. Die elektrische Energieerfassung erfolgt über Strommesswandler und Spannungsmessklemmen, während der PV-Wechselrichter über ModBus-TCP mit der Beckhoff-SPS kommuniziert. Der Ladepark, gesteuert durch eine Siemens-SPS, wurde über OPC UA mit der Beckhoff-SPS verbunden, wodurch Befehle und Messdaten ausgetauscht werden können. Über dieselbe Schnittstelle wurde die KI „etaONE“ angebunden und getestet. Zudem wurde die DC-Ladestation von CuroCon aufgerüstet und ein Ladepunkt für CCS2 und CHAdeMO eingerichtet. Die zugehörige Steuerung, DC-Wandlung und Leistungsverteilung wurden in einen separaten Schaltschrank integriert und erfolgreich getestet.

Zusammenfassung der Arbeiten je Partner

PTW (Leitung):

- Sichtung der Versorgungstechnik und Festlegung der zu regelnden Anlagen
- Abstimmungen zur Einbindung des hybriden elektrischen Speichers und der etaOne-Plattform in die ETA-Fabrik
- Vergleichsstudien zur Auswahl geeigneter DRL-Algorithmen, Hyperparameter und Netzwerktopologien
- Modellierung des thermischen Versorgungssystems mit Modelica (Dymola) und Abschätzung erster Parameter durch Messungen
- Training eines DRL-Agents am Simulationsmodell zur späteren Übertragung auf das reale System
- Vergleich verschiedener Trainingsmethoden; normalverteilte Domänen-Randomisierung (NDR) als zielführende Methode
- 27 % Reduktion der Gesamtkosten gegenüber konventioneller Regelung und über 50 % Reduktion der Schaltkosten
- Keine Reduktion der Energiekosten, aber potenziell durch Anpassung der Kostenfunktion erreichbar

etalytics:

- Im Arbeitspaket hat etalytics ein semantisches Informationsmodell für die einzelnen versorgungstechnischen Anlagen entwickelt und in der etaOne Plattform implementiert. Hierdurch lassen sich schnell neue Anlagen über standardisierte Schnittstellen anbinden und Optimierungsmodelle ableiten.
- Zudem führte etalytics verschiedenen Abstimmungen zur Integration von etaOne und dem im Projekt entwickelten Optimierungsframework eta-utility mit dem PTW durch.
- Darauf aufbauend wurde gemeinsame mit dem PTW die etaOne–eta-utility Verbindung über API-Schnittstelle umgesetzt. Diese erlaubt das Auslesen und Schalten von Datenpunkten.
- Zudem können die Systemzustände des Versorgungssystems über eine grafische Benutzeroberfläche dargestellt werden.

IMS:

- Implementierung konventioneller Ansteuerungen in eta-utility als Benchmark
- Implementierung von DRL (PPO) mit Variation der Rewardfunktion und der Hyperparameter (insbes. Lernrate), mit und ohne Predictions: Berücksichtigung der Preisgestaltung durch den Stromanbieter (Leistungspreis für Lastspitzen und Arbeitspreis für generellen Verbrauch), Speicherverluste, zyklische und kalendarische Batteriealterung
- Implementierung einer mathematischen Optimierung (MILP) mit Forecast durch historische Daten, auch hier Berücksichtigung der Preisgestaltung durch den Stromanbieter (Leistungspreis für Lastspitzen und Arbeitspreis für generellen Verbrauch), Speicherverluste, zyklische und kalendarische Batteriealterung
- Versuche zur Beschleunigung der Rechenzeit durch Aufteilung der Zielfunktion

CuroCon:

- Optimierung der Versorgungstechnik (Wärmepumpe, PV, Ladepark) und Anbindung an etaOne mit Unterstützung von PTW und etalytics
- Implementierung einer MPC-Optimierung der Wärmeversorgung in eta_utility unter Einbezug der PV-Eigenerzeugung; Datenerfassung über etaOne-Schnittstelle und mobile Messgeräte
- Validierung des Optimierers anhand historischer Daten mit 39 % Reduktion des Netzbezugs und verbesserter Komforttemperatur
- Beckhoff-SPS als zentrale Steuerung mit EtherCat, KNX, ModBus-TCP und OPC UA; Integration von Sensoren/Aktoren für Wärmepumpen, Raumklimatisierung und Wetterdatenerfassung
- Anbindung des Ladeparks an etaONE über OPC UA sowie erfolgreiche Aufrüstung und Integration einer DC-Ladestation mit CCS2/CHAdemo

ÖKOTEC:

- Aufbau der Übergabe der Sollwertvorgabe der Betriebsoptimierung an die Leittechnik der Verbundkälteanlage
- Testen der Betriebsoptimierung ohne aktives Steuern
- Demonstration der Betriebsoptimierung mit aktiver Sollwertvorgabe für die Verbundkälteanlage
- Prüfung und Plausibilisierung der Ergebnisse und nach Bedarf Anpassungen in der Modellierung

2.5.4. Arbeitspaket 5.4: Kombinierte Anwendung in Simulation und Forschungsfabrik

In AP 5.4 lag der Fokus vermehrt auf der realen Anwendung und Validierung einzelner in AP 5.3 entwickelter Ansätze. So wurde sowohl der hybride elektrische Speicher als auch die thermische Versorgungstechnik der ETA-Fabrik durch DRL-Agenten, mathematische Optimierung oder konventionelle Ansätze geregelt. Bezüglich der Versorgungstechnik wurden dabei auch die Differenzen zwischen Simulation und Realität untersucht.

1) Hybrider Energiespeicher:

Für die Erprobung des Modells und den Agenten wurde eine Schnittstelle an der SPS des Speichers implementiert, die OPC UA Daten, welche durch eta-utility generiert wurden, entgegennehmen konnte. In Abbildung 2.81 ist zu sehen, wie der Lastverlauf aussah, nachdem der Speicher zum Einsatz kam. Leider hat der Agent zu diesem Zeitpunkt noch nicht performant agiert und anstelle eines funktionierenden Peakshavings eher Lastspitzen erzeugt. Dies konnte mit anderen Steuerungsmethoden simulativ gelöst werden. In diesem Abschnitt soll jedoch vorrangig gezeigt werden, dass die Datenübertragung funktioniert und implementierte Agenten den Speicher erfolgreich ansteuern können.

Abbildung 2.82 zeigt dazu die weitergegebenen Sollwerte (gestrichelt) an den Schwungmassenspeicher (blau) und die Batterie (rot), sowie ihre Reaktion auf diese Befehle. Die Batterie reagiert recht exakt, während der Schwungmassenspeicher Abweichungen aufweist. Abbildung 2.83 zeigt den State of Charge (SOC) der Speicher während des Versuchs. Zu sehen ist, dass der kinetische Speicher den gesamten Bereich nutzt, die Batterie weniger. Dies liegt vermutlich daran, dass der Agent gelernt hat, dass eine hohe Zyklenzahl der Batterie auch eine schnellere Alterung dieser mit sich bringt.




Abbildung 2.81: Verlauf der Lastanforderung der Speicher mit (orange) und ohne Speicher (grau)




Abbildung 2.82: Soll- (gestrichelt) und Ist-Leistungen des kinetischen (blau) und elektrochemischen Speichers (rot)




Abbildung 2.83: SOC-Verlauf des kinetischen (blau) und elektrochemischen Speichers (rot)

2) Versorgungstechnik ETA-Fabrik

Der in Abschnitt 5.3 trainierte Agent wurde zur Steuerung des thermischen Versorgungssystems der ETA-Fabrik eingesetzt. In zwei von drei 24-stündigen Versuchen konnte das Realsystem erfolgreich

geregelt werden. Im nicht erfolgreichen Versuch gelang es dem Agenten nicht, die vorgegebenen Temperaturgrenzen einzuhalten, sodass die konventionelle Regelung der ETA-Fabrik als Sicherheitsmaßnahme automatisch die Kontrolle übernahm.




Abbildung 2.84: Anwendung eines trainierten Agenten, Realversuch (25.11.2024). Erfolgreiche Durchführung über 24 h. Dargestellt ist ausschließlich der Temperaturverlauf im Warmwassernetz (HNLT). Die Bedarfe (unten) entstehen durch den Betrieb einer Reinigungsanlage und die Kühlung einer Werkzeugmaschine. Abbildung aus [105].

Zuvor wurde die Diskrepanz zwischen Simulation und Realität untersucht. Dabei zeigte sich eine gute Übereinstimmung in der generellen Dynamik, jedoch traten einzelne Abweichungen auf, die sich über die Zeit akkumulierten.




Abbildung 2.85: Beispielhafte Darstellung des Temperaturverlaufs im Warmwassernetz (HNLT) über 24 h in Realität und der Simulation, s. [105].

Zusätzlich wurde ein Versuch durchgeführt, bei dem die Optimierung der Produktionsplanung (siehe AP 5.2) mit der Steuerung der Versorgungstechnik kombiniert wurde. Hierbei wurde mithilfe der in AP 5.2 entwickelten Methode ein energieoptimierter Produktionsplan erstellt, aus dem die elektrischen Bedarfe

der Produktionsanlagen abgeleitet wurden. Diese Prognosewerte wurden an den DRL-Agenten zur Regelung des Versorgungssystems übermittelt. Während ein stabiler Betrieb der Versorgungstechnik erreicht werden konnte, kam es zu Abweichungen im Produktionsablauf im Vergleich zum berechneten Produktionsplan.

Insgesamt konnte durch die durchgeführten Versuche die generelle Anwendbarkeit der entwickelten Methoden erfolgreich nachgewiesen werden.

Zusammenfassung der Arbeiten je Partner

PTW (Leitung):

- Der in AP 5.3 trainierte Agent wurde zur Steuerung des thermischen Versorgungssystems der ETA-Fabrik eingesetzt
- Drei 24-stündige Versuche wurden durchgeführt, wobei in zwei Fällen die Regelung erfolgreich war und in einem Fall die konventionelle Steuerung übernehmen musste
- Die Übereinstimmung zwischen Simulation und Realität wurde analysiert, wobei eine gute generelle Dynamik, aber akkumulierte Abweichungen festgestellt wurden.
- Ein Versuch zur gleichzeitigen Optimierung von Produktionsplanung und Versorgungstechnik wurde durchgeführt, indem Prognosewerte aus einem energieoptimierten Produktionsplan an den DRL-Agenten übermittelt wurden
- Die Auswirkungen auf die Stabilität der Versorgungstechnik und den Produktionsablauf wurden untersucht
- Die generelle Anwendbarkeit der entwickelten Methoden wurde erfolgreich nachgewiesen.

IMS:

- OPC UA Schnittstelle zwischen SPS des hybriden Speichers und dem Rechner wurde implementiert
- Auf der UI des hybriden Speichers wurde ein Button eingerichtet, mit der sich die Steuerung durch die übermittelten Werte durch eta-utility ansteuern lässt
- Algorithmen (DRL) wurden am realen System erfolgreich getestet

etalytics:

- Für die Verbindung von Simulationsmodellen und der etaOne Plattform war ursprünglich eine direkte Einbindung von FMU-Modellen vorgesehen. Im Projektverlauf hat sich jedoch im Gegensatz zur ursprünglichen Planung eine Alternative Lösung als zielführender erwiesen, welche die FMUs nicht direkt in die etaOne-Plattform einbindet, sondern indirekt durch die bereits entwickelte API-Schnittstelle zwischen eta-utility und etaOne.
- Nach diesem Ansatz wurde bereits die Schnittstelle für das Lesen und Schreiben von Datenpunkten implementiert.
- Zur Prüfung der API-Anbindung wurde ein vereinfachter Test mit einem Blockheizkraftwerk des ETA-Fabrik-Systems durchgeführt. Dieser diente keinem Optimierungsziel, sondern nur der Validierung der Anbindung.

2.5.5. Arbeitspaket 5.5: Vergleich verschiedener Lösungsverfahren nach Anwendungsfall

Die Auswahl der richtigen Modellierungs- und darauf basierender Optimierungsansätze für unterschiedlichste Anwendungsfälle ist ein sehr komplexes Thema und durch die permanente Weiterentwicklung von Algorithmen ständigen Änderungen unterworfen. Das Ziel des Arbeitspaketes 5.5 war es, einen systematischen Vergleich von Optimierungsverfahren durchzuführen, um eine problemspezifische Auswahl zu ermöglichen. Dabei sollten verschiedene Modellierungsoptionen (mathematisch, datengetrieben, etc.) und Hierarchien gegeneinander abgewogen werden. Die Untersuchung sollte mit Hilfe der Anwendungsfälle aus den vorangegangenen Aufgabenpaketen AP 5.1 bis AP 5.4 durchgeführt werden, in denen verschiedene Optimierungsansätze an Teilsystemen der ETA-Fabrik erprobt werden.

Zu Beginn der Arbeiten am Arbeitspaket wurden die verschiedenen Anwendungsfälle in einer Reihe von Workshops mit den Anwendungspartnern von IMS und PTW zusammengetragen und analysiert. Es wurden Profile der einzelnen Anwendungsfälle erstellt, die das Optimierungsziel, eine Beschreibung der Anlagen und Stellvariablen umfassen. Die ausgearbeiteten Profile umfassen den optimierten Anlagenbetrieb des hybriden Energiespeichers, die optimierte Produktionsplanung, den energieflexiblen Betrieb einer Reinigungsmaschine, bei dem auf die Abstimmung von Leistungsspitzen geachtet wurde und den optimierten Betrieb des thermischen Versorgungssystems der ETA-Fabrik.

In der ersten Analyse stellte sich bereits heraus, dass die Betrachtung der Reinigungsmaschine kein geeigneter Anwendungsfall für das AP darstellt. Eine optimierte Lösung wurde bereits dadurch erreicht, dass Überschneidungen von Leistungsspitzen vermieden wurden und es kein großes Potential durch eine Formulierung als Optimierungsproblem gibt. Durch die gemeinsamen Workshops und den Austausch zwischen den Anwendern von ETA-Fabrik und IMS und Experten für Optimierung und KI, konnte jedoch noch einige Vorschläge für weitere Lösungsansätze in den einzelnen Anwendungsfällen erarbeitet werden. Zudem konnten im Rahmen des Austauschs zwischen den Forschungsgruppen auch Ideen für weitere themenähnliche Forschungsprojekte identifiziert werden.

Nach der Auswertung der Workshops, sowie der Ergebnisse der einzelnen Austauschtreffen, wurde ein weiterer gemeinsamer Workshop mit allen Stakeholdern auf Seiten ETA, IMS und DFKI in Kaiserslautern durchgeführt. Dabei wurden auch erste Regeln für die Auswahl geeigneter Optimierungsverfahren basierend auf der Erfahrung der beteiligten Experten formuliert. Im Allgemeinen war das Resultat der Arbeiten jedoch, dass ein direkter Vergleich der verschiedenen Anwendungsfälle nur schwer durchgeführt werden kann und sich die Leistungsfähigkeit der einzelnen Algorithmen kaum von einem auf den nächsten Anwendungsfall übertragen lässt. Dabei spielen sowohl die unterschiedlichen Optimierungsziele als auch die Freiheitsgrade der Optimierungsprobleme eine wichtige Rolle. Entscheidend sind jedoch insbesondere Voraussetzungen die nicht nur problem-, sondern auch unternehmensspezifisch sind.

Zunächst kommt es darauf an, welche Anforderungen vom Unternehmen an eine Optimierungslösung gestellt wird. Sind also Optimalitätsgarantien erforderlich oder reicht bereits eine Approximation der Lösung? Welche Rechenressourcen können in Relation zum gegebenen maximalen Zeithorizont der Problemlösung zur Verfügung gestellt werden? Welche Unsicherheiten bestehen im Produktivbetrieb und können diese modelliert werden? Somit kann eine Optimierungslösung primär reaktiv erzeugt oder mit einem größeren Zeithorizont vorausberechnet werden. Diese Frage spielt zudem in die Anforderungen zu Sicherheitsgarantien ein, da Fehlentscheidungen oder nicht berücksichtigte

Unsicherheiten leicht zu fehlerhaften Lösungen und unsicheren Maschinenzuständen führen können. Des Weiteren kommt es insbesondere auch auf die Erfahrung mit dem Problem und evtl. existierende Vorarbeiten an. Ist das Problem bereits gut genug verstanden, sodass ein hinreichendes Simulationsmodell erstellt werden kann? Und besitzt das Unternehmen genug Know-how eine Lösung zu erarbeiten und auch langfristig zu betreiben? Dies ist insbesondere bei der Wartung komplexer mathematischer Modelle ein wichtiger Faktor. Die Betrachtung dieser Faktoren und eine Erarbeitung von geeigneten Lösungen geschieht üblicherweise über interdisziplinäre Projekte, in denen fallspezifisch die Vorstellungen des Unternehmens sowie die technischen Lösungsmöglichkeiten diskutiert und gegeneinander abgewogen werden.

Im Zuge dieser Betrachtung waren sich die Stakeholder des APs einig, dass ein generischer Vergleich der Optimierungsansätze über die verschiedenen Anwendungsfälle kein aussichtsreiches Vorhaben ist. Über interne Kontakte am PTW und des DFKI wurden Gespräche mit den lokalen Projekten des Netzwerks Mittelstand-Digital (MDZ) aufgenommen. Diese führen regelmäßig Beratungsprojekte mit kleinen und mittleren Unternehmen (KMU) durch. Dadurch kann hier bereits auf einen großen Erfahrungsschatz beim Vergleich und der Bewertung unterschiedlicher Optimierungsverfahren in der Zusammenarbeit mit den anwendenden Unternehmen zurückgegriffen werden. Um das im Antrag formulierte Ziel der problemspezifischen Auswahl geeigneter Algorithmen des Arbeitspaketes zu erfüllen, wurde deshalb eine Anpassung der Vorgehensweise mit allen beteiligten Stakeholdern des Arbeitspaketes beschlossen.

Statt zu versuchen eine individuelle Beratung zur Auswahl einer geeigneten Lösung für Unternehmen durch einen übergeordneten neutralen Vergleich von Lösungsansätzen über die verschiedenen Anwendungsfälle zu ersetzen, wird versucht mit Hilfe von KI-Methodiken die bereits existierenden Beratungsleistungen zu verbessern. Dazu wurde eine Zusammenarbeit mit dem MDZ Kaiserslautern vereinbart, welches neben den Beratungsdienstleistungen in Workshops auch eine umfangreiches Self-Service Angebot online betreibt.

Die Angebote, die hierbei der Öffentlichkeit zur Verfügung gestellt werden, richten sich an Interessierte und Entscheidungsträger aus KMUs und sollen Interesse an den Themen Digitalisierung und KI wecken und auch über Beratungs- und Projektangebote des MDZ informieren. Die Angebote umfassen dabei informative Videos und Texte sowie interaktive Angebote, wie ausfüllbare Fragebögen, die individuell Aufschluss über zu hebende Potentiale im eigenen Unternehmen geben.

Diese Art der Interaktion mit den Mitarbeitern der KMU birgt den Vorteil, dass der Nutzer bereits frühzeitig auf wichtige Fragen zu den interessierenden Themen gestoßen werden kann, die auch im späteren Unterstützungsprozess noch einmal aufgegriffen werden können. Des Weiteren erlaubt es bereits eine gewisse Selbstevaluation der Lage des Unternehmens in Bezug auf die Themen KI und Digitalisierung und kann bereits ein erster Indikator sein, wie weiter verfahren werden soll. Mit der Beantwortung der Fragen können zudem schon erste generische Ratschläge auf Basis der gegebenen Antworten bereitgestellt werden. Bisher nicht genutztes Potential bei dieser Art des Services ist die direkte Kontaktaufnahme und Weiterleitung der Ergebnisse an die Berater des MDZ. Mit Hilfe der Antworten auf die Fragebögen können Beratungsangebote zum einen individueller angepasst werden und zum anderen bereits ein gewisses Vorwissen in ein erstes Gespräch mitgenommen werden.

Um dem Rahmen des Arbeitspaketes gerecht zu werden, wurde vereinbart einen zusätzlichen Service zu entwickeln, der den Einstieg für Beratungsangebote im Bereich des aktiven Energiemanagements bildet. Dabei sollen dem Nutzer insbesondere die Erkenntnisse des Projektes KI4ETA nahegebracht werden.

Dies umfasst die Erkenntnisse zum Vergleich verschiedener Algorithmen im Rahmen des Arbeitspakets. So wurde insbesondere erprobt, ob ein DRL, MILP oder regelbasierter Ansatz zur Steuerung des hybriden Stromspeichersystems der ETA-Fabrik im Anwendungsfall des Peak Shavings die besten Resultate bei der Energieeinsparung erzielt. Ein Teil der Ergebnisse dieses Vergleichs für einen repräsentativen Arbeitstag mit durchschnittlichem Energiebedarf findet sich in Abbildung 2.86.




Abbildung 2.86: Vergleich verschiedener Optimierungsansätze am hybriden Energiespeicher für einen repräsentativen Arbeitstag mit durchschnittlichem Energieverbrauch.

Daneben sollen auch die allgemeinen Ergebnisse des Projektes in den Service einfließen. Im ersten Entwurf würde der Service mit individuell angepassten Vorschlägen zur Auswahl eines passenden Optimierungsverfahren auf die Antworten des Nutzers aufwarten. Dabei würden die Antwortmöglichkeiten des Fragenkatalogs individuell zu bestimmten Verfahren gewichtet und basierend auf den Antworten des Nutzers ein Vorschlag aus der Gesamtpunktzahl errechnet.

Im Laufe der Arbeiten stellte sich, wie bereits erörtert, ein etwas weiter gefasster Fokus des Fragenkatalogs als sinnvoller heraus, der die relevanten Bedingungen in den Unternehmen besser erfasst. Dementsprechend muss allerdings auch der Fokus der Empfehlungen aufgeweitet werden. Diese müssen nun ein wesentlich breiteres Spektrum an Maßnahmen und Vorschlägen abdecken. Gleichzeitig wird potenziell auch eine immer größere Bandbreite an Ergebnissen des Projektes relevant für die Nutzer.

Mit diesen Anforderungen wurde ein Service konzipiert, der im Kern auf einem Empfehlungssystem mit einer Retrieval Augmented Generation (RAG) Pipeline basiert [128]. Diese aufstrebende Technologie kombiniert die Expressivität eines Large Language Models (LLM) mit der Präzision und dem Determinismus einer konventionellen Datenbasis (etwa einer Datenbank oder eines Dateispeichers) [129]. Demnach stellt RAG eine Erweiterung der Textgenerierung mit Hilfe eines LLMs dar. Der klassische Ablauf eines RAGs besteht aus Indexing, Retrieval und Generation [130]. Indexing bezieht sich auf die Umformung des Nutzerprompts in einen Vektor mittels eines speziell trainierten neuronalen Netzes. Die Inhalte der konventionellen Datenquellen, werden ebenfalls in Portionen (sog. Chunks) aufgeteilt und als Vektoren verschlüsselt. Im zweiten Schritt, dem Retrieval, wird die Ähnlichkeit der Vektoren der Datenquellen mit dem transformierten Prompt ermittelt. Im einfachsten Fall kann dies über die Berechnung der L2-Norm geschehen. Es werden die Textstücke, die dem verschlüsselten Prompt am ähnlichsten sind, herausgenommen und wieder entschlüsselt. Diese werden nun im letzten Schritt, der Generation, zusammen mit dem ursprünglichen Prompt als Eingabe in ein LLM gegeben und das Ergebnis dem Nutzer präsentiert. Diese einfache Pipeline kann um ein Vielfaches erweitert werden, um

die Zuverlässigkeit und Qualität der Antworten zu erhöhen, wurde jedoch in ihrer Grundform, bedingt durch die Unterstützung mit verfügbaren Tools, im Projekt umgesetzt [130].

Der Service, der im Rahmen des APs umgesetzt wurde, nutzt diese Pipeline gleich zweimal, um unterschiedliche Empfehlungen zu generieren. Zum einen sollen dem Nutzer unmittelbare Empfehlungen gegeben werden, um basierend auf dem im Fragebogen erfassten Ausgangspunkt in den Unternehmen, nächste Schritte vorzuschlagen. Zum anderen soll passend zu den vorgeschlagenen Maßnahmen auch weiterführende Ergebnisse des Projektes KI4ETA oder anderer Literatur vorgeschlagen werden.

Die Empfehlung nächster Schritte basiert dabei auf einem regelbasierten Algorithmus. Dabei werden Empfehlungen in Text geschrieben, der in natürlicher Sprache verfasst werden kann. Die relevanten Empfehlungen ergeben sich dabei aus der Punktzahl der gewichteten Antworten. Diese Empfehlungen werden dann zusammen mit dem Prompt in die Generation gegeben. Das regelbasierte System nimmt somit die Stelle von Indexing und Retrieval ein. Die Regeln spiegeln die Erfahrung der Berater des MDZ wider und können dabei simpel in Freitext verfasst werden. Der generierte Text für die Empfehlung nächster Schritte dient dann gleichzeitig als Ergänzung für den Prompt zur Generierung der Empfehlungen für weitere Information. Hier wird eine Vektordatenbank genutzt, in die der Text relevanter Dokumente mit ihren Metadaten aufgenommen wird. Es wird also die typische RAG-Pipeline genutzt. Abbildung 2.87 a) illustriert den Ablauf der beiden konsekutiven Durchläufe der RAG-Pipeline.

Implementiert wurde der Service unter der ausschließlichen Nutzung von Open-Source Software. Die Lösung wurde mit einer Micro-Service Architektur entwickelt [131]. Die einzelnen Microservices lassen sich so dezentral auf verteilten Servern deployen. Für den Anschluss an ein LLM wurde eine generische REST-Connector Klasse entworfen, der mit einem Anbieter im Internet (OpenAI, Google, ...) verbunden werden kann und diese zur Textgenerierung verwenden kann. Die im Projekt entwickelte Variante stellt zudem einen Connector für die Open-Source LLM-Hosting Umgebung ollama bereit. Somit können alle Microservices on-premise deployed werden und die Daten verbleiben komplett lokal. Ein Überblick über die Architektur findet sich in Abbildung 2.87 b).




Abbildung 2.87: a) zeigt den konsekutiven Ablauf der RAG-Pipeline zur Generierung der beiden Empfehlungstexte. Die Microservice-Architektur der Software wird in b) gezeigt.

Das Frontend beinhaltet 3 Seiten. Beim Design wurde Wert auf eine Anlehnung an das Design des MDZ gelegt. Allerdings wurde bei der Designsprache zur Verdeutlichung des nachhaltigen Energie-Fokus des Services die Farben Gelb und Grün zentral verwendet. Abbildung 2.88 zeigt Screenshots der Seiten. Der

im AP entstandene Code steht dem MDZ zur Weiterentwicklung und Einbindung in das Online-Angebot zur Verfügung.




Abbildung 2.88: Webseiten des Frontends und die Reihenfolge, in der die Nutzer durch den Service geführt werden.

Zusammenfassung der Arbeiten je Partner

DFKI (Leitung):

- Workshops zur Auswahl und Definition der Anwendungsfälle und der Form des abschließenden Arbeitsergebnisses des APs
- Durchführung einer Serie von Workshops zur Erfassung des Status-quo innerhalb der Anwendungsfälle und zur Vernetzung der Expertengruppen von DFKI, PTW und IMS
- Erstellung eines Multiple-Choice Fragenkatalogs zur Erfragung relevanter Informationen zur automatisierten Erstellung einer Empfehlung
- Gewichtung der Antwortmöglichkeiten zu den ausgewählten Optimierungsansätzen
- Aufbau eines RAG-regelbasierten Recommender-Systems
- Implementation ein modularen RAG-Services als Web-Service zur Einbindung in das Online-Angebot des MDZ

PTW:

- Definition von Anwendungsfällen, welche aus den AP 5.1, 5.2 und 5.3 näher betrachtet werden sollen
- Beschreiben der Anwendungsfälle und Optimierungsprobleme in Experteninterviews
- Bereitstellung von Ergebnissen aus Algorithmenvergleichen

-
- Teilnahme an Workshops und Bereitstellung von Feedback zu Ergebnissen

IMS:

- Teilnahme an Workshops und Bereitstellung von Feedback zu Ergebnissen
- Bereitstellung des Anwendungsfalls zum hybriden Energiespeicher der ETA
- Vergleich der MILP-Strategie mit DRL und einer konventionellen Regelung für den Anwendungsfall Peak Shaving

2.6. Teilprojekt 6: Sektorenkopplung

Fabrikgebäude und Industrieparks bestehen zumeist aus einer Vielzahl organisatorisch oder technisch abgetrennter Einheiten, die eigene Zielstellungen verfolgen, jedoch durch zentrale hybride Energienetze (z.B. Wärme) verknüpft sind. Diese organisatorische Trennung energetisch vernetzter Systeme führt häufig zu Ineffizienzen in der Betriebsweise und Parametrierung dieser Netze. Weiterhin interagiert der Industriepark mit verschiedenen externen Sektoren (Energieversorger, Mobilität). Auch hier führt mangelnde Transparenz zu Ineffizienzen im Betrieb. Während in den vorausgehenden Teilprojekten Ansätze und Optimierungsframeworks für die Steigerung von Energieeffizienz und -flexibilität innerhalb des Gesamtsystems Fabrik betrachtet werden, werden in diesem Teilprojekt Ansätze zur Integration des Fabriksystems mit interagierenden Systemen wie Stromnetz, Wärmenetz und E-Mobilität untersucht.

Tabelle 2.15: Arbeitspakete in Teilprojekt 6.

Sektorenkopplung		Beteiligte Partner
Teilprojektleitung: IMS		
AP 6.1	Parametrierung und Wärmepricing industrieller Wärmenetze	atlan-tec, GreenDelta, PTW
AP 6.2	Schnittstellen für die Umsetzung von Real-Time-Pricing in der Produktion	Entega, etalytics, PTW
AP 6.3	Intelligente bidirektionale Ladeinfrastruktur	IMS, PTW
AP 6.4	Modellierung und Integration der Randbedingungen durch den Fahrer auf die Ladeinfrastruktur	IMS

2.6.1. Arbeitspaket 6.1: Modellierung und Wärmepricing industrieller Wärmenetze

Im Rahmen des AP 6.1 wurden Ansätze zur Integration von Fabrikssystemen mit externen Strom- und Wärmenetzen untersucht, um durch erhöhte Transparenz und Betriebsweise Ineffizienzen und Verluste zu reduzieren. Initial sollte atlan-tec durch KI entsprechende Wärmeverbrauchtrends vorhersagen, was allerdings durch deren Insolvenz nicht stattgefunden hat. Das Müllheizkraftwerk (MHKW) Mannheim-Nord der MVV Energie AG diente als Beispiel und wurde durch Modellierung der Prozessinfrastruktur und durch einen Wärmepricing untersucht. Die komplexe Wärmeinfrastruktur und Stromgeneration des MHKWs ist in einer schematischen Darstellung dargestellt (siehe Abbildung 2.89).




Abbildung 2.89: Wärmeinfrastruktur vom MHKW Mannheim-Nord.

Im Rahmen dieses Arbeitspakets wurde ein System zur Analyse des Bedarfs und der Erzeugung von (Dampf-)Wärmeströmen innerhalb der Sophena-Software der GreenDelta GmbH implementiert, welche ursprünglich für die Modellierung von Wärmenetzen aus erneuerbaren Energien (Holzfeuerung) verwendet wird. Ziel war es, die Prozessinfrastruktur und Berechnung der einzelnen Wärmeströme eines Industriebetriebes sowie die unterschiedlichen Wärmeproduzenten mit den entsprechenden Kapazitäten und Puffern abzubilden. Im Rahmen dessen wurden Programmierarbeiten durchgeführt, die die Implementierung von MHKW in Sophena erlauben. Für die Integration in die Software wurden alle Betriebswerte in entsprechende Wärmemengen umgerechnet und in Sophena gepflegt. Als Resultat konnten geordnete und ungeordnete Jahreslinien erhalten werden, welche die Verwendung der einzelnen Wärmeerzeuger aufschlüsselten und die gesamte Prozessinfrastruktur des MHKW's abbildeten und potenzielle Ineffizienzen aufwiesen.




Abbildung 2.90: Jahreslinien der Prozessinfrastruktur vom MHKW Mannheim-Nord.

Die Veränderung der Sophena-Software wird in der Dokumentation in GitHub (<https://github.com/GreenDelta/Sophena.git>) näher beschrieben. Ein Demonstrator, welcher die Last- und Erzeugergänge des Müllheizkraftwerks beinhaltet, kann intern verwendet und für Untersuchungen herangezogen werden. Eine öffentliche Publikation dieser Sophena-Version wird mit einem anderen Update zusammengelegt.

In Ergänzung zur obigen Betrachtung der Prozesswärmeinfrastruktur des MHKW befasse sich das PTW in Arbeitspaket 6.1 intensiv mit der Analyse und Modellierung aus ökonomischer Sicht. Dabei wurde ein umfangreicher Datensatz mit historischen Betriebsdaten des MHKW und seiner Komponenten untersucht. Mithilfe der von MVV bereitgestellten Dokumentation wurden dann datenbasierte mathematische Modelle für die elektrische Erzeugungsleistung der Generatoren in Abhängigkeit der thermischen Eingangs- und Ausgangsleistung an den zugehörigen Turbinen erstellt. Mit diesen Modellen konnte dann der Einfluss des Dampfexports von MVV an die angeschlossenen Kunden auf den Wirkungsgrad der Turbinen und somit auf die Stromproduktion modelliert werden.




Abbildung 2.91: Lineare Modellierung der elektrischen Leistung von Turbine T60 in Abhängigkeit der thermischen Eingangsleistung und der Dampfbereitstellung.

Damit wurde eine Logik zur dynamischen Anpassung der Wärmepreise in Abhängigkeit von Strompreisen und der Stromerzeugung des Kraftwerks erarbeitet. Abschließend wurde das entwickelte Verfahren anhand historischer Betriebsdaten des MHKW validiert und ausgewertet. Für die historischen Daten wurde ein dynamischer (Mindest-)Dampfpreis ermittelt, zu dem die Stromproduktion des Kraftwerks genauso wirtschaftlich ist wie der Export von Dampf. Stellt man diesen dynamischen Dampfpreis einem konventionellen statischen Preis gegenüber, können Zeitfenster ermittelt werden, in denen der Strompreis so hoch ist, sodass sich der Dampfexport für das Kraftwerk wirtschaftlich weniger lohnt als die Maximierung der Stromproduktion (siehe Abbildung 2.92).




Abbildung 2.92: Dynamische Preisbildung für Dampfbereitstellung in Abhängigkeit dynamischer Marktstrompreise unter Einbezug der Effizienz der Stromerzeugung des Kraftwerks

Zusammenfassung der Arbeiten je Partner

atlan-tec:

- Aus dem Projekt ausgeschieden. Die Beiträge atlan-tecs zu KI4ETA sind in einem eigenen Schlussbericht festgehalten.

GreenDelta:

- Entwicklung eines Konzepts zur Erweiterung und Anpassung der Sophena-Software für den Anwendungsfall MHKW Mannheim (Wärmegeneration durch Müllverbrennung)
- Ausrichtung an Workshops zur Besprechung der Daten und des Anwendungsfalls und Integration der Dampfinfrastruktur in Sophena
- Erfolgreiche Implementierung einer Softwareerweiterung zur Berücksichtigung industrieller Wärmenetze und entsprechende Generation von Dampf/Strom in Sophena mit dem Anwendungsbeispiel für das MHKW Mannheim
- Die Veröffentlichung der Sophena-Erweiterung ist mit anderem Update geplant

PTW:

- Analyse vorhandener historischer Datenreihen zum betrachteten Müllheizkraftwerk von MVV
- Erstellung einer Liste von weiteren benötigten Datenpunkten für die Auswertung
- Analyse und Auswertung des umfangreicheren Datensatzes des MHKW Mannheim
- Erstellung von Modellen zur Beschreibung der Effizienzen der einzelnen Turbinen des MHKW
- Einbezug der exportierten Wärmemenge in die Modellierung der elektrischen Energieeffizienz des Müllheizkraftwerks
- Entwicklung einer Logik zur dynamischen Anpassung von Wärmepreisen in Abhängigkeit von Strompreisen und Stromerzeugung des Müllheizkraftwerks

- Auswertung des Verfahrens für historische Betriebsdaten des Müllheizkraftwerks

2.6.2. Arbeitspaket 6.2: Schnittstellen für die Umsetzung von Real-Time-Pricing in der Produktion

Ziel von Arbeitspaket 6.2 war die Evaluation der Potenziale von Real-Time-Pricing sowie die Implementierung geeigneter Schnittstellen zur Umsetzung entsprechender Preismodelle. Die Anbindung industrieller Abnehmer an Energieversorger durch dynamische Preismodelle hat das Ziel, die Effizienz der Energieverwendung in der Industrie zu steigern. Durch die Implementierung dieser Preismodelle sollen industrielle Verbraucher in die Lage versetzt werden, ihren Energieverbrauch eigenständig und flexibel an die Verfügbarkeit von erneuerbaren Energien im Netz anzupassen.

Ein Schwerpunkt war die Entwicklung und Implementierung von Schnittstellen zwischen Industrie- und Versorgungsunternehmen. Diese Schnittstellen müssen kompatibel und interoperabel mit den Ergebnissen aus den Teilprojekten 4 und 5 sein, um die Übermittlung und Nutzung von Preisprognosen und Echtzeitpreisen in der industriellen Produktion zu ermöglichen. Im Rahmen von Arbeitspaket 6.2 sollte ein Proof-of-Concept anhand eines Assets der ETA-Fabrik erfolgen (Batteriespeicher). Für den Informationsaustausch zwischen Energieversorger und Kunde sollte außerdem ein auf Blockchain-Technologie basierendes Kommunikationsprotokoll entwickelt und getestet werden.

Zusätzlich waren auf Basis von Simulationsmodellen verschiedene Optionen der Flex-Bewirtschaftung zu analysieren. Diese simulationsbasierten Auswertungen dienen der Analyse der Erlöspotentiale von dynamischen Preismodellen und der Verdeutlichung der resultierenden Risikoprofile.

Um die Real-Time-Pricing-Schnittstelle zu realisieren, wurde ein Workshop mit der ENTEGA AG, ihrer Handelstochter citiworks und der etalytics GmbH organisiert. Ziel war es, die fachlichen und technischen Anforderungen zu evaluieren. Dabei einigte man sich auf die Implementierung einer REST JSON (JavaScript Object Notation)-Schnittstelle mit einer openAPI-Dokumentation. Etalytics entwickelte und implementierte anschließend die notwendigen Schnittstellen, um die Preisinformationen regelmäßig bei der ENTEGA-/citiworks-API abzurufen und zuverlässig in die etaONE-Energiemanagementplattform zu integrieren. Auf Seiten der ENTEGA wurden darüber hinaus umfangreiche Analysen auf Basis historischer Daten des Intraday-Handels aus den Jahren 2020 bis 2021 durchgeführt, um die zeitliche Verteilung der Handelsaktivitäten und die Volatilität der Intraday-Preise detailliert zu untersuchen. Auf Grundlage dieser Analysen wurden Risikoaufschläge für das Real-Time-Pricing festgelegt.




Abbildung 2.93: Verteilung der Preisdifferenzen zwischen Intraday-Trades in Abhängigkeit von der Vorlaufzeit.

Zusätzlich wurde die zeitliche Korrelation zwischen den Spotmarktpreisen und den spezifischen CO₂-Emissionen des deutschen Strommixes im Zeitraum von 2012 bis 2020 analysiert. Industrielle Flexibilitäten, deren Stromverbräuche sich an den Strompreisen orientieren, fördern die Integration erneuerbarer Energien besonders dann, wenn der Strompreis auch die aktuelle Zusammensetzung des Strommixes widerspiegelt. Da Strom aus erneuerbaren Energien zu sehr niedrigen (Grenz-)Kosten auf dem Spotmarkt angeboten wird, führt eine hohe Einspeisung aus erneuerbaren Energien in der Regel zu einem Preisrückgang (Merit-Order-Effekt). Daher wäre zu erwarten, dass es einen Zusammenhang zwischen dem Spotpreis und der Emissionsintensität der Stromerzeugung gibt. In den analysierten Zeitreihen war dieser Zusammenhang jedoch nicht direkt erkennbar. Insgesamt lässt sich daher festhalten, dass der Spotpreis zwar Informationen über die aktuelle Zusammensetzung des Erzeugungsmixes liefert, jedoch nur in begrenztem Umfang. Daher könnten zusätzliche Maßnahmen erforderlich sein, um ein zielgerichtetes Verhalten industrieller Flexibilitäten zu fördern, wie beispielsweise die Dynamisierung von Entgelten und Umlagen.




Abbildung 2.94: Zeitliche Korrelation zwischen Spotmarktpreisen und spez. CO₂-Emissionen des deutschen Strommixes (2012-2020).

Ein methodisches Teilziel des Arbeitspakets bestand darin, ein Simulationsmodell für die Bewirtschaftung der industriellen Flexibilität auf Seiten des Versorgers zu entwickeln. Dieses Modell soll es ermöglichen, die verfügbare Flexibilität direkt auf den Strommärkten, wie dem Spot- und Intraday-Markt, zu vermarkten, ohne dass alle Preisfluktuationen an den Kunden weitergegeben werden müssen.

Nach erfolgter Flexibilitätsvermarktung erhält der Kunde lediglich einen Lastfahrplan, den er einhalten muss. Aus Energieversorgersicht stellt sich in diesem Zusammenhang die Frage, welche Methode am besten geeignet ist, um energetische Flexibilitäten abzubilden und zu bewirtschaften. Zu diesem Zweck wurde ein Vergleich zwischen einem klassischen MILP-Modell und einem Machine-Learning-basierten Modell eines Heizkraftwerks durchgeführt. Ziel war es, den Einsatzfahrplan für Blockheizkraftwerke (BHKW) und Gaskessel unter Berücksichtigung der Preise von Strom, Gas und Emissionszertifikaten sowie der Einhaltung relevanter Nebenbedingungen (Nachfragedeckung, Temperaturgrenzen) wirtschaftlich zu optimieren.




Abbildung 2.95: Modellierung eines Heizkraftwerks für den Methodenvergleich (MILP vs. Machine Learning).

Die Ergebnisse zeigen deutliche Vorteile der datenbasierten Parametrierung der Modelle, wie etwa die Nutzung von Messdaten zur Ermittlung von Kennlinien im Vergleich zu Typenschildangaben und das gemessene Verbrauchsverhalten im Vergleich zu Literaturwerten. Hinsichtlich des Aufwands für Implementierung und Parametrierung erscheinen klassische MILP-Modelle für die Ermittlung des Anlagendispatches jedoch besser geeignet als Machine-Learning-Modelle. Ein wesentlicher Vorteil liegt hierbei auch in der Nachvollziehbarkeit der Ergebnisse.

Um die ökonomischen Potenziale der Nutzung industrieller Flexibilitäten und die Wirkung verschiedener Einflussfaktoren besser einschätzen zu können, wurde die Bewirtschaftung eines Batteriespeichers auf dem Intraday-Markt analysiert. Diese Analyse diente insbesondere der Vorbereitung des Teilprojekts 7, Arbeitspaket 7.5 „Anwendungsfall: Sektorenkopplung zwischen Fabrik, Stromnetz und Elektrofahrzeug“. Dabei wurde untersucht, wie sich Faktoren wie Transaktionskosten oder die Konzentration auf Handloptionen mit großem Preis-Spread auf die erzielbaren Erlöse auswirken. Dies wurde vereinfacht durch die Variation des Wirkungsgrads des Speichers dargestellt. Zudem wurden mögliche Verfügbarkeitseinschränkungen, die beispielsweise durch produktionstechnische Anforderungen entstehen, als blockierte Zeiträume modelliert. Eine Blockierung der Flexibilitätsnutzung zwischen 10 Uhr und 16 Uhr kann beispielsweise das Erlöspotenzial um 20 % reduzieren.




Abbildung 2.96: Einnahmen eines Batteriespeichers auf dem Intraday-Markt unter Betrachtung verschiedener Einflussfaktoren.

Um auch den Einfluss untertägiger Planungsprozesse zu berücksichtigen, wurde der zeitliche Vorlauf vor der Erfüllung der einzelnen Viertelstundenprodukte variiert. Da jedoch im kontinuierlichen Intraday-Markt der Großteil der Handelsaktivitäten in der Regel in den 3-4 Stunden vor Erfüllung stattfindet, ist der Einfluss dieser Einschränkungen gering. Selbst wenn der Handel nur in den vier Stunden vor Erfüllung möglich ist, können noch 85 % des Gesamtpotenzials realisiert werden.

Insgesamt ist festzustellen, dass aktuelles Marktniveau und -volatilität durchaus nennenswerte Erlösoptionen bieten. Dem stehen allerdings die politische Situation und die resultierenden, z. T. sehr kurzfristigen regulatorischen Maßnahmen gegenüber. Dies hat eine hohe Verunsicherung der Marktteure zur Folge, so dass die Investitionsbereitschaft mitunter stark eingeschränkt ist.

Um auch die technische Umsetzbarkeit der energiewirtschaftlichen Prozesskette zwischen Versorgungsunternehmen und Industriekunde in Form eines Proof-of-Concepts zu demonstrieren, wurde im Rahmen von AP 6.2 auch der Batteriespeicher der ETA-Fabrik in die Energiemanagementplattform von etalytics eingebunden, so dass eine Steuerung auf Basis marktbasierter Signale ermöglicht wurde. Die notwendigen Schnittstellen wurden zwischen PTW, IMS, etalytics und ENTEGA-IT abgestimmt und implementiert.

⋮	BESS - Batterieleistung (read)	✓	ENTEGA UA	READ	30s	25	a few seconds ago
⋮	BESS - Batterieleistung (write)	✓	ENTEGA UA	WRITE		25	a few seconds ago
⋮	BESS - Batteriestrom (read)	✓	ENTEGA UA	READ	30s	5	a minute ago
⋮	BESS - Batteriestrom (write)	⚠	ENTEGA UA	WRITE		0	10 months ago
⋮	BESS - Leistung_Ist	✓	ENTEGA UA	READ	30s	3500	a few seconds ago



Abbildung 2.97: Einbindung des ETA-Batteriespeichers in die etalytics-Plattform sowie seitens ENTEGA gesteuerter Be- und Entladezyklus.

Die im Rahmen von Arbeitspaket 6.2 vorgesehene Einführung einer Blockchain-Lösung für die Marktkommunikation wurde vor allem aufgrund von Kapazitätsengpässen nicht weiterverfolgt (Hackerangriff, Umsetzung regulatorischer Vorgaben während der Energiekrise). Die Auswirkungen auf die angestrebten Forschungs- und Entwicklungsziele des Projekts wurden als geringfügig betrachtet, da die bestehenden energiewirtschaftlichen Marktkommunikationsprozesse bereits sehr zuverlässig sind.

Insgesamt wurden in Arbeitspaket 6.2 somit sowohl die ökonomischen Potenziale von Real-Time-Pricing unter Berücksichtigung verschiedener Einflussgrößen analysiert als auch die Realisierbarkeit der notwendigen energiewirtschaftlichen Prozesskette anhand einer Proof-of-Concept-Lösung erfolgreich demonstriert. Ergänzend wurden Untersuchungen zum Zusammenhang zwischen Strompreisen und Emissionsintensität des Strommixes sowie ein Methodenvergleich zu MILP und Machine Learning bei der preisorientierten Optimierung von Anlagenfahrplänen durchgeführt.

Zusammenfassung der Arbeiten je Partner

Entega (Leitung):

- Erfassung, Aufbereitung und Analyse umfangreicher Daten des Intraday-Handels von 2012-2024 (zeitliche Verteilung der Handelsmengen, Preisvolatilität)
- Ergänzende Analyse zur Korrelation zwischen Spotmarktpreisen und Emissionsintensität des Strommixes
- Literaturrecherche und Expertengespräche zur Preissensitivität von (Industrie-)Kunden

- Methodenvergleich „MILP vs. Machine Learning“ bei der Modellierung von zu bewirtschaftenden Flexibilitäten
- Analysen zu Handels- bzw. Vermarktungsstrategien auf Basis historischer und/oder aggregierter Daten
- Analysen zur Marktentwicklung auf den Kurzfristmärkten
- Analysen zu zukünftigen Marktdesign-Optionen (u. a. mit Fokus auf resultierende Potentiale für Sektorkopplungstechnologien)
- Abstimmung, Implementierung und Test von Schnittstellen zur Anbindung von Assets (PTW, IMS, etalytics, ENTEGA-IT)
- Umsetzung der Gesamtintegration (Prognosen, Optimierung, Bewirtschaftung)

etalytics:

- Diskussion und Evaluierung verschiedener Schnittstellenoptionen
- Integration von Börsenpreisen und Real-Time Preisen in die smarte Energiemanagementplattform
- Abstimmung, Implementierung und Test von Schnittstellen zur Anbindung von Assets (PTW, IMS, etalytics, ENTEGA-IT)

PTW:

- Absprachen mit der Entega zum Einfluss von Real-Time Preisen auf den energieflexiblen Betrieb von Industriebetrieben
- Abstimmung, Implementierung und Test von Schnittstellen zur Anbindung von Assets (PTW, IMS, etalytics, ENTEGA-IT)

2.6.3. Arbeitspaket 6.3: Intelligente bidirektionale Ladeinfrastruktur

In diesem Arbeitspaket war das Ziel, eine bidirektionale Ladeinfrastruktur in der ETA-Fabrik der TU Darmstadt aufzubauen und zu erproben. Die in der Fahrzeugbatterie verfügbare Speicherkapazität soll dabei in das Energiesystem der Fabrik integriert werden, um die energetischen Freiheitsgrade der Fabrik und damit deren Effizienz und Flexibilität zu erhöhen. Durch die Möglichkeit des bidirektionalen Ladens kann überschüssige Energie aus der Fabrik zwischengespeichert und bei Bedarf wieder ins Netz eingespeist werden. Dies trägt zur Optimierung des Energieflusses bei und ermöglicht eine intelligentere Nutzung erneuerbarer Energien. Neben der Installation einer Ladesäule wird auch ein Elektrofahrzeug eingesetzt, um das Potenzial und die praktischen Anwendungsmöglichkeiten der bidirektionalen Ladefunktion zu demonstrieren.

Für die Umsetzung des bidirektionalen Ladens an der ETA-Fabrik wurde die Energieversorgung der DC-Ladepunkte über das bestehende hybride Energiespeichersystem (HESS) gelöst, welches vom Institut für Mechatronische Systeme (IMS) der TU Darmstadt in der ETA-Fabrik betrieben wird. Dadurch kann die Leistungselektronik für das bidirektionale Laden durch den gemeinsamen Gleichstrom-Zwischenkreis des Hybridspeichers versorgt werden. Eine schematische Abbildung der energetischen Verbindungen zwischen HESS und Ladesäule ist in Abbildung 2.98 zu erkennen. Hier ist außerdem auch die bestehende Ladeinfrastruktur dargestellt, die zwar energetisch nicht mit dem HESS verbunden ist, allerdings kommunikationstechnisch mit dem HESS eng verknüpft ist. An zahlreichen Stellen im System sind Leistungsmessungen möglich (in der Abbildung mit „LM“ gekennzeichnet), um den Systemzustand zu überwachen und die Leistungsflüsse darstellen zu können.

Durch die Kombination von hybridem Speicher und der bidirektionalen Ladesäule ergeben sich beim Aufbau Synergieeffekte. Zum einen entfällt die Notwendigkeit von zusätzlichen AC-DC-Wandlern, mit denen die Ladesäule an das Stromnetz angeknüpft werden müsste. Da im HESS bereits ein Netzwechselrichter vorhanden ist, entfällt die zusätzliche Anschaffung von Leistungselektronik, wodurch sowohl Platz als auch finanzielle Mittel gespart werden können. Gleichzeitig wird das Elektrofahrzeug somit zum Teil des gesamten Speichersystems.

Zur Realisierung von Vehicle-to-Grid (V2G) an der ETA-Fabrik wurde ein Auftrag für die Planung, Umsetzung und Inbetriebnahme der Ladesäule an die CuroCon GmbH vergeben. Das dabei entstandene Konzept umfasst die Erweiterung der bestehenden Ladesäule an der ETA-Fabrik, welche im Vorgängerprojekt PHI-Factory installiert wurde, sowie einen weiteren Schaltschrank im Keller der ETA-Fabrik, welcher alle notwendigen Steuerungs- und Leistungskomponenten enthält. Mit Ausnahme der zusätzlich an der Ladesäule angebrachten DC-Ladepunkte für CHAdeMO und CCS bleibt das äußere Erscheinungsbild der Ladesäule an ETA-Fabrik unverändert, siehe Abbildung 2.99.




Abbildung 2.98: Schematischer Aufbau der bidirektionalen Ladesäule an der ETA-Fabrik.



Abbildung 2.99: Ladesäule an der ETA-Fabrik inkl. DC-Ladepunkten.

Weitere notwendige Umbauarbeiten, wie z. B. die Öffnung von Wanddurchbrüchen, das unterirdische Verlegen von Kabeln und die damit verbundenen Grabungsarbeiten, wurden durch Rahmenvertragspartner der TU Darmstadt erfüllt.

Die Leistungselektronik für die bidirektionale Ladesäule besteht hauptsächlich aus vier parallelen DC-DC-Wandlern, welche über eine Vorladewiderstandsschaltung an den Zwischenkreis des HESS angebunden werden können und ausgangsseitig die Ladepunkte versorgen. Bei den DC-Ladepunkten handelt es sich um einen CHAdeMO-Anschluss sowie einen CCS-Anschluss. Die Ladesäule erreicht eine maximale Lade- bzw. Entladeleistung von 40 kW, bei einer Dauernennleistung von 36 kW. Ein Nutzer der Ladesäule kann für die intelligente Betriebsstrategie (siehe Arbeitspaket 6.4) relevante Daten an dem Touch-Display eingeben, welche über OPC-UA an die Steuerung der Ladesäule übergeben werden. Diese steuert den Ladevorgang und sorgt per Ansteuerung der Leistungselektronik für die Einhaltung der Leistungsvorgabe durch den Algorithmus. Gleichzeitig überträgt die Steuerung auch Messdaten und aktuelle Zustände während des Ladevorgangs, welche wiederum in den Algorithmus einfließen können.

Zur Demonstration des bidirektionalen Ladens sowie der dazugehörigen Betriebsstrategien wurde im Rahmen des Projekts auch ein Elektrofahrzeug angeschafft, welches bidirektionales Laden ermöglicht. Hierbei handelt es sich um einen Nissan Leaf, welcher über den CHAdeMO Ladestandard bereits werksseitig V2G unterstützt. Um ein möglich großes Flexibilitätspotenzial zu erhalten, wurde hier ein Fahrzeug mit einer Gesamt-Akkukapazität von 62 kWh gewählt. Mit einer Gesamtladeleistung von bis zu 100kW stellt es für den Ladebetrieb somit keine Begrenzung dar, jedoch ist die Entladeleistung laut Nissan auf 10 kW begrenzt.

Durch Lieferverzögerungen sowie durch technische Probleme mit den erworbenen Komponenten der Ladesäule kam es zu einigen Verzögerungen beim Aufbau der Hardware. Besonders hervorzuheben sind hier anfängliche Planungsschwierigkeiten aufgrund des Platzmangels an der ETA-Fabrik, sowie Lieferengpässe bei Elektronik-Komponenten durch die Corona-Krise sowie den russischen Angriffskrieg auf die Ukraine. Überdies traten Defekte an den DC-DC-Wandlern auf, wodurch die Inbetriebnahme

mehrmals unterbrochen wurde und zwischenzeitlich eine aufwendige Fehlersuche betrieben werden musste.

Das Gesamtkonzept des Zusammenschlusses aus Ladesäule (uni- als auch bidirektional) und Hybridspeicher wurde im Rahmen eines Papers veröffentlicht [132]. Leider war es im Projektzeitraum jedoch nicht mehr möglich, über einen größeren Zeitraum Ladeversuche durchzuführen. Dies liegt daran, dass erst kurz vor dem Verfassen dieses Berichts eine erfolgreiche Entladung des Fahrzeugs erfolgte. Damit konnte auch die intelligente Betriebsstrategie aus AP 6.4. nicht ausführlich in der realen Umgebung erprobt werden. Dies liegt – neben den genannten Herausforderungen – auch daran, dass die Kommunikationsschnittstellen zwischen Ladecontroller und Fahrzeug bislang nicht vollständig etabliert sind. Da sich der ursprünglich angedachte Ladecontroller von Siemens während der Inbetriebnahme bedauerlicherweise nicht als geeignet herausstellte, wurde ein anderer Ladecontroller von Advantics verbaut. Bei beiden Herstellern war ein intensiver Austausch mit dem jeweiligen Support-Team notwendig, um die Controller in Betrieb zu nehmen. Mit dem Advantics-Controller war es jedoch schlussendlich möglich, das Fahrzeug über CHAdeMO sowohl unidirektional als auch bidirektional zu laden. Abbildung 2.100 zeigt einen exemplarischen Ausschnitt eines Ladeversuchs, bei dem Energie aus dem Fahrzeug entnommen werden konnte. Negative Ströme bedeuten hier einen Leistungsfluss aus dem Fahrzeug in Richtung Netz.




Abbildung 2.100: Exemplarischer Entladeversuch.

Da die Möglichkeit des bidirektionalen Ladens auch außerhalb des Projekts KI4ETA sehr relevant für die Demonstration des Potenzials von intelligenten Betriebsstrategien ist, wird die weitere Inbetriebnahme der Ladeinfrastruktur an der ETA-Fabrik auch außerhalb des Projektrahmens vorangetrieben. Als nächste Schritte gelten Inbetriebnahme der Schnittstellen zwischen Ladecontroller und Steuerung der Leistungselektronik, dem Touch-Display und dem KI-Agenten (AP 6.4). Diese müssen Schritt für Schritt getestet werden, um daraufhin automatisierte Testläufe für intelligente Ladevorgänge durchführen zu können.

Insgesamt zeigen die Arbeiten in diesem Arbeitspaket, dass zwar die technischen Grundlagen für das bidirektionale Laden von Elektrofahrzeugen gegeben sind, und es im Gegensatz zum Beginn des Projekts einige Hersteller von Komponenten der Ladeinfrastruktur gibt, welche das bidirektionale Laden unterstützen oder an der Unterstützung arbeiten. Allerdings zeigen sich hier jedoch auch weitere Angriffspunkte, die es gilt, zeitnah zu beheben. Insbesondere ist aus Sicht dieses Arbeitspakets eine Schaffung stabiler und zuverlässiger Schnittstellen von enormer Wichtigkeit, vorwiegend im Bereich der Ladecontroller. Obwohl es speziell bei CHAdeMO bereits seit Jahren die Unterstützung für bidirektionales Laden in den Kommunikationsstandards für den Ladeprozess gibt, ist diese Technologie weiterhin nicht etabliert, weshalb die beiden verwendeten Ladecontroller vermutlich auch nur in

geringem Umfang für bidirektionales Laden eingesetzt wurden, und somit noch kein stabiles Verhalten zeigen

Zusammenfassung der Arbeiten je Partner

IMS (Leitung):

- Konzipierung, Planung und Beschaffung der Ladesäulen-Komponenten
- Beschaffung eines Fahrzeugs, welches bidirektionales Laden unterstützt
- Umsetzung von Bauarbeiten und Kabelverlegearbeiten
- Betreuung der Firma CuroCon bei der Inbetriebnahme der Ladeinfrastruktur
- Anpassungen am bestehenden Speichersystems sowie an der Ladesäule

PTW:

- Ansprechpartner für Fragestellungen in Zusammenhang mit der Infrastruktur in der ETA-Fabrik

2.6.4. Arbeitspaket 6.4: Modellierung und Integration der Randbedingungen durch den Fahrer auf die Ladeinfrastruktur

Ziel dieses Arbeitspakets war es, eine intelligente Betriebsstrategie für Ladevorgänge von elektrischen Fahrzeugen zu entwickeln, welche die durch den Fahrer und dessen Mobilitätsbedürfnisse gestellten Anforderungen berücksichtigt und die Betriebsstrategie in geeigneter Weise wählt. In der Vorhabenbeschreibung war dafür ein Multiagentensystem angedacht, bei welchem die einzelnen Akteure (Energiemanagement der Fabrik, Fahrer, Fahrzeug) als eigenständige intelligente Agenten eine für das Gesamtsystem optimale Betriebsstrategie aushandeln. Im Verlauf des Projekts wurde jedoch klar, dass für die Ziele dieses APs ein Multiagentensystem nicht geeignet ist. Zum einen liegt das an der zentralen Verfügbarkeit aller notwendigen Daten, die für die Betriebsstrategie relevant sind. Wäre dies nicht der Fall, würde sich ein Multiagentensystem gut dafür eignen, dezentral Entscheidungen auf Basis der Teilmenge der verfügbaren Informationen zu treffen. Da an der Ladesäule der ETA-Fabrik alle relevanten Informationen an einer Stelle gebündelt werden können, ist ein System mit nur einem Agenten ausreichend. Überdies sind Multiagentensysteme sehr komplex und durch die gegenseitige Beeinflussung kann es zu Stabilitäts- bzw. Konvergenzproblemen kommen. Da im Rahmen dieses Arbeitspakets nur an einem Fahrzeug eine intelligente Betriebsstrategie angewendet werden soll, wäre ein Multiagentensystem unnötig komplex.

Zur Generierung der intelligenten Betriebsstrategie wurde ein Reinforcement-Learning (RL) Ansatz gewählt. Bei Reinforcement Learning interagiert ein Akteur (i.d.R. ein neuronales Netz) mit einer Umgebung und erhält neben Informationen über den Zustand der Umgebung (Observation) eine Belohnung (sog. Reward), die dem Akteur Rückmeldung darüber gibt, ob die ausgeführte Aktion im aktuellen Zustand wünschenswert war oder nicht. Die Reward-Funktion setzt sich aus zahlreichen Komponenten zusammen, die das Verhalten in verschiedenen Situationen belohnen oder bestrafen. Während des Lernprozesses führt der Akteur zunächst zufällige Aktionen aus und erlernt dabei das durch die Reward-Funktion charakterisierte gewünschte Verhalten. Die Reward-Funktion und die Gewichtung derer Komponenten spielen dabei eine maßgebliche Rolle, da durch diese das Verhalten des Akteurs beeinflusst werden kann. Um ein angemessenes Verhalten des Akteurs zu erzielen, ist es somit notwendig, bei der Gestaltung der Reward-Funktion so viel Wissen wie möglich über das System einfließen zu lassen. Um den Akteur zu trainieren, wird als Umgebung eine Simulation des realen Systems gewählt, welche

letzteres möglichst gut abbildet, und realistisches Verhalten zeigt. Dadurch kann der Aktor frei agieren und es kommt zu keinem Risiko, z.B. durch die Beschädigung der Ladesäule durch unzulässige Aktionen. Sobald das Training abgeschlossen ist, können die Stellsignale des Aktors mittels geeigneter Schnittstellen (in diesem Fall OPC-UA) an die reale Ladesäule angebunden und die Betriebsstrategie im Realbetrieb angewendet werden.

Als konkreter Anwendungsfall wurde im Rahmen dieses Arbeitspakets die Lastspitzenglättung innerhalb der ETA-Fabrik gewählt. Dabei wird versucht, durch eine geeignete Wahl der Lade- bzw. Entladeleistung des Elektrofahrzeugs Lastspitzen am Netzanschlusspunkt der ETA-Fabrik zu verhindern. Diese Anwendung wurde gewählt, um die Potenziale durch die Anwendung von RL zum intelligenten Laden und Entladen von Elektrofahrzeugen abzuschätzen. Gleichzeitig ist es dadurch auch möglich, einfache Betriebsstrategien (z.B. regelbasierte) als Vergleich heranzuziehen, welche sich für die Lastspitzenglättung einfach formulieren lassen.

Zunächst wurde eine Simulationsumgebung der Ladesäule an der ETA-Fabrik in Python aufgebaut, welche die in AP 6.3 realisierte Hardwareumgebung möglichst realitätsnah abbildet (z.B. Leistungspfade, Wirkungsgrade und Eigenschaften des Elektrofahrzeugs). Für das bessere Verständnis von RL wurde für den Aktor vorläufig ein DQN-Trainingsansatz gewählt, da dieser mit wenig Aufwand komplett eigenständig zu implementieren ist. Die Aktionen dieses Aktors waren begrenzt auf einen diskreten Handlungsspielraum, in dem nur drei Aktionen möglich waren: Laden, Entladen und Stand-By. Zur besseren Stabilität wurde dabei die Ladeleistung auf max. 10 kW begrenzt (analog zur zulässigen Entladeleistung des Fahrzeugs von max. 10 kW), auch wenn an der Ladesäule der ETA-Fabrik bis zu 40 kW möglich wären. Da jedoch die Stabilität des Lernprozesses sowie die schlussendliche Fähigkeit der Lastspitzenglättung problematisch waren, wurde daraufhin ein komplexerer Ansatz gewählt. Hierzu wurde ein sog. „Proximal Policy Optimization“ (PPO) Algorithmus gewählt, welcher im Bereich des RL stark etabliert ist und bessere Leistungsfähigkeit hinsichtlich der Trainingsgeschwindigkeit, Stabilität und des Erlernens des gewünschten Verhaltens zeigt. Für das neuronale Netz des Agenten wurde dabei ein Netz mit zwei versteckten (hidden) Schichten gewählt, bei einer Anzahl an Knoten von 64 pro Schicht. Es wurde eine sog. LeakyReLU Aktivierungsfunktion gewählt, welche die beste Performance unter den verfügbaren Aktivierungsfunktionen zeigte. Der Agent hat einen kontinuierlichen Aktionsbereich, sodass zwischen maximaler Lade- und Entladeleistung alle möglichen Werte ausgegeben werden können. Bei dem Netz handelt es sich um kein LSTM-Netz, sodass das Netz keine Erinnerung aus vorherigen Zuständen hat. Dies ermöglicht eine flexible Nutzung des Netzes für verschiedene Zeitbereiche.

Zum Training wurden zufällig generierte Szenarien innerhalb der Simulationsumgebung gewählt. Dabei wurde immer ein Ladevorgang simuliert, wobei die Anfangs- und Endladezustände sowie Ankunfts- und Abfahrtszeiten variiert wurden. Für das Leistungsprofil der Fabrik wurden synthetische Daten auf Basis realer Messwerte für die Netzanschlussleistung über ca. 2,3 Jahre verwendet. Das neuronale Netz wird dabei jede Minute zur Generierung von Sollwerten verwendet. Zur Validierung der Fähigkeit der Lastspitzenglättung wurde über den kompletten verfügbaren Datensatz für die Netzanschlussleistung angenommen, dass das Elektrofahrzeug an jedem Arbeitstag an der ETA-Fabrik anwesend ist. Außerhalb der Arbeitszeit werden verschiedene Fahrten durchgeführt, u.a. auch am Wochenende. Die komplette Energie für das Fahren wird dabei an der ETA-Fabrik bezogen. Im Rahmen der Validierung wurde ebenso die Batteriealterung betrachtet, welche mithilfe eines semiempirischen Alterungsmodells von Marinelli et al. [133] berechnet wurde. Dieses Alterungsmodell wurde eigens für das Fahrzeug Nissan Leaf e+ 62 kWh entwickelt, welches auch in KI4ETA verfügbar ist.

Als Vergleich zu dem PPO-Ansatz wurden zwei weitere, jedoch einfachere Ansätze verfolgt. Zum einen wurde ein Algorithmus implementiert, welcher sog. ungesteuertes Laden ermöglicht und das Fahrzeug direkt nach Ankunft auf den gewünschten Ladezustand bei Abfahrt lädt. In diesem Fall wird keine Energie aus dem Fahrzeug entzogen. Der zweite Ansatz beruht auf einer Entscheidungslogik, die auf Basis des aktuellen Fahrzeugzustands und der momentanen Netzanschlussleistung die Ladeleistung wählt. Um sicherzustellen, dass das Fahrzeug eine ausreichende Energiemenge erhält, um den Wunschladestand am Ende des Arbeitstages zu erhalten, wurde hier ein Leistungsschwellwert von 30 kW für die Netzanschlussleistung gewählt, unterhalb welcher keine Lastspitzenglättung vorgenommen wird. Damit wird verhindert, dass das Fahrzeug bei Lastspitzen unterhalb dieses Schwellenwerts entladen wird. In diesem Bereich treten sehr viele Lastspitzen auf, diese sind jedoch aus finanzieller Sicht und auch aus Sicht der Netzbelastung nicht relevant.

Zur Sicherstellung des Erreichens des gewünschten Ladezustands am Ende des Arbeitstages wurde eine sog. Fallback-Ebene implementiert, die die Stellsignale der unterschiedlichen Algorithmen überschreibt, sofern der Ladezustand anderweitig nicht mehr erreicht werden kann. Dies kann unter Umständen dazu führen, dass dadurch zusätzliche Lastspitzen entstehen. Die Fallback-Ebene stellt außerdem sicher, dass sich die Leistungsvorgaben sowie der Ladezustand des Fahrzeugs in einem sicheren Bereich bewegen.

Abbildung 2.101 zeigt links die Auftrittshäufigkeiten von Tages-Lastspitzen im Datensatz der gesamten Verbrauchsleistung der ETA-Fabrik. Eine Tages-Lastspitze stellt eine Viertelstunde dar, in der der Leistungsbedarf der Fabrik am höchsten war. Die Leistung P_{Netz} wird dabei über die gesamte Viertelstunde gemittelt. Rechts ist in Abbildung 2.101 der mittlere Fabrikverbrauch über die verschiedenen Tageszeiten aufgetragen. Es ist hier zu erkennen, dass es kurz vor und kurz nach Mittag regelmäßig zu Lastspitzen kommt.




Abbildung 2.101: links: Auftrittshäufigkeit von Tages-Lastspitzen (höchste Lastspitze pro Tag), rechts: mittlerer Fabrikverbrauch über die Tageszeit.

Abbildung 2.102 zeigt das Verhalten der unterschiedlichen Ansätze in der simulativen Validierung. Hier sind alle Tages-Lastspitzen als Punkte dargestellt. Die einzelnen Diagramme geben an, wie die Lastspitzen durch die unterschiedlichen Algorithmen behandelt wurden. Dies ist zu erkennen an der Ladeleistung des Elektrofahrzeugs, welche auf der vertikalen Achse aufgetragen ist. Ist die Ladeleistung positiv, wurde die Lastspitze vergrößert, sodass in diesem Moment zusätzlich zum restlichen Fabrikbedarf weitere Energie aus dem Netz entnommen wurde. Ist die Ladeleistung negativ, wurde das Elektrofahrzeug in diesem Moment entladen, sodass ein Teil des Fabrikverbrauchs durch das Fahrzeug gedeckt werden konnte und somit die Netzanschlussleistung geringer ausfällt. Die farbliche

Kennzeichnung der Datenpunkte gibt an, ob während dieser Tages-Lastspitze das Fahrzeug vorhanden war (blau) oder nicht (rot), bzw. ob in diesem Zeitpunkt die Fallback-Ebene aktiv war (orange).

Beim Betriebsverhalten ist zu erkennen, dass beim ungesteuerten Laden nur positive Ladeleistungen möglich sind. Ein Großteil der Lastspitzen wird erhöht, da diese in der Anwesenheit des Fahrzeugs liegen, und das Fahrzeug ohne Berücksichtigung anderer Faktoren schnellstmöglich vollgeladen wird. Beim regelbasierten Ansatz ist gut zu erkennen, dass unterhalb einer Netzanschlussleistung von 30 kW zahlreiche zusätzliche Lastspitzen erzeugt werden, im Bereich darüber jedoch ein Großteil der Lastspitzen, an denen das Fahrzeug verfügbar ist, erfolgreich geglättet werden. Vier Tages-Lastspitzen werden jedoch verschlechtert, da hier die Fallback-Ebene aktiv wird, um das Fahrzeug auf den gewünschten Abfahrts-Ladezustand aufzuladen. Der RL-Ansatz mit dem neuronalen Netz zeigt ein ähnliches Verhalten wie der regelbasierte Ansatz, allerdings ist hier der Übergang vom Bereich bei kleinen Werten von P_{Netz} , in dem zusätzliche Lastspitzen erzeugt werden, zum Bereich, in dem die Lastspitzen geglättet werden, wesentlich weniger abrupt. Jedoch ist es auch mit dem RL-Agenten möglich, einen großen Anteil der Lastspitzen in höheren Leistungsbereichen zu glätten. Hier wird allerdings nicht immer die maximalen Entladeleistung ausgenutzt.




Abbildung 2.102: Betriebsverhalten der verschiedenen Algorithmen. Jeder Punkt entspricht einer Tages-Lastspitze.

Tabelle 2.16 zeigt die Ergebnisse der simulativen Validierung in tabellarischer Form. Hier wurde die mittlere Lastspitzenverschiebung bei den Tages-Lastspitzen für verschiedene Bereiche des Fabrikverbrauchs berechnet. Der betrachtete Bereich wird dabei Zeile für Zeile verringert, wobei die

erste Zeile ($P_{\text{Verbrauch}} > 0 \text{ kW}$) das gesamte Spektrum abdeckt und in den darauffolgenden Zeilen der betrachtete Bereich zu höheren Leistungen verschoben wird. Beim ungesteuerten Laden lässt sich erkennen, dass in allen Bereichen des momentanen Fabrikverbrauchs im Mittel eine zusätzliche Netzbelastung durch Laden des Elektrofahrzeugs erzeugt wird. Der regelbasierte Ansatz, welcher auch bidirektionales Laden zulässt, ermöglicht in allen Bereichen der Verbrauchsleistung eine Verringerung der Lastspitzen, diese Verringerung ist jedoch besonders im höheren Leistungsbereich $> 40 \text{ kW}$ zu erkennen. Der RL-Ansatz zeigt zwar in den höheren Leistungsbereichen eine etwas geringere Fähigkeit der effektiven Lastspitzenglättung, ist jedoch über den gesamten Bereich der Verbrauchleistung ein Potenzial zur Lastspitzenglättung von mindestens $2,2 \text{ kW}$.

Tabelle 2.16: Lastspitzenverschiebung durch die verschiedenen Algorithmen in verschiedenen Leistungsbereichen.

Mittlere Lastspitzenverschiebung bei Fahrzeuganwesenheit in kW			
Betrachteter Bereich	Ungesteuertes Laden	V2G regelbasiert	V2G Reinforcement Learning
$P_{\text{Verbrauch}} > 0 \text{ kW}$	+3,6	−0,6	−2,4
$P_{\text{Verbrauch}} > 20 \text{ kW}$	+8,0	−0,8	−2,2
$P_{\text{Verbrauch}} > 40 \text{ kW}$	+4,1	−7,8	−6,9
$P_{\text{Verbrauch}} > 60 \text{ kW}$	+5,0	−9,7	−8,3
$P_{\text{Verbrauch}} > 80 \text{ kW}$	+6,2	−8,3	−7,8

Abschließend wurde die Batteriealterung untersucht, welche durch die drei Algorithmen verursacht wird. Dabei wird grundsätzlich zwischen der kalendarischen Alterung und der zyklischen Alterung unterschieden. Während die kalendarische Alterung immer auftritt und hauptsächlich vom Alter der Batterie abhängt, basiert die zyklische Alterung auf der Anzahl von Lade- und Entladezyklen und der Höhe der Ladeleistung. Abbildung 2.103 zeigt die Batteriealterung über den gesamten Zeitraum der verfügbaren Daten für die Netzanschlussleistung.




Abbildung 2.103: Batteriealterung durch die unterschiedlichen Algorithmen.

In Abbildung 2.103 ist zu erkennen, dass die zyklische Alterung für alle drei Algorithmen im Vergleich zur kalendarischen Alterung gering ausfällt. Dies bedeutet, dass die zusätzliche Nutzung für bidirektionales Laden einen geringen Einfluss auf die Lebensdauer der Traktionsbatterie hat. Bei Betrachtung der kalendarischen Alterung fällt auf, dass diese je nach Ladestrategie auch unterschiedlich ausfallen. Obwohl die Ladeleistung keinen Einfluss auf die kalendarische Alterung hat, ist letztere abhängig vom Ladezustand der Batterie, welcher sich durch die verschiedenen Algorithmen in unterschiedlichen Bereichen bewegt. Insgesamt liegen die Werte für den Gesundheitszustand der Batterie am Ende des Zeitraums in einem Bereich von ca. 0,5 %. Dies lässt darauf schließen, dass durch das bidirektionale Laden zwar eine verstärkte Batteriealterung verursacht wird, jedoch nur in geringem Maße. Gleichzeitig deuten die Ergebnisse darauf hin, dass es zukünftig zielführend ist, die Batteriealterung als Teil der Betriebsstrategie zu berücksichtigen. Durch intelligente Betriebsstrategien, die die Mechanismen im Inneren der Traktionsbatterie berücksichtigen, kann sowohl bidirektionales Laden angeboten werden als auch der Ladeprozess an sich so gestaltet werden, dass die Batteriealterung auf ein Minimum begrenzt wird. Eine praktische Erprobung der entwickelten Algorithmen steht noch aus. Dies liegt vor allem an der fehlenden Verfügbarkeit einer geeigneten Ladeinfrastruktur, da in AP 6.3 bis zum Verfassen dieses Berichts nur grundlegende Funktionen implementiert werden konnten. Allerdings wurden die benötigten Schnittstellen zu den realen Systemen an der ETA-Fabrik eingerichtet und die Funktion der Agenten und Algorithmen im realen Einsatz getestet, indem die noch unvollständigen Schnittstellen (insbesondere zum Fahrzeug und der bidirektionalen Ladeinfrastruktur) simulativ nachgebildet wurden. Die Algorithmen werden dabei auf einem Rechner in der ETA-Fabrik ausgeführt, welcher alle notwendigen Daten über OPC-UA erhält und darüber auch Stellsignale ausgeben kann.

In diesem Arbeitspaket wurde mithilfe von Reinforcement Learning eine Betriebsstrategie für intelligentes, bidirektionales Laden entwickelt. Dazu wurde eine Simulationsumgebung aufgebaut, mit der das Betriebsverhalten unterschiedlicher Ansätze untersucht und verbessert werden kann. Der RL-Ansatz zeigt dabei im Vergleich zum ungesteuerten Laden und einem regelbasierten Ansatz zur Lastspitzenglättung durchaus kompetitives Verhalten über weite Bereiche des Betriebsspektrums. Hier ist jedoch zu erwähnen, dass die Implementierung eines auf neuronalen Netzwerken und deren Training basierenden Ansatzes sehr viel Zeitaufwand mit sich bringt, und die Ergebnisse ausschließlich für den vorliegenden Fall benutzt werden können. Eine Anpassung auf andere Ladeinfrastrukturen ist nicht ohne weiteres möglich. Zudem ist es schwierig, das Verhalten des neuronalen Netzes zu erklären, was besonders aus wissenschaftlicher Sicht wichtig ist. Die Entscheidungen, die der Agent fällt, sind somit nicht zweifelsfrei begründbar, was das Erlangen weiterer wissenschaftlicher Erkenntnisse erschwert.

Zusammenfassung der Arbeiten je Partner

IMS (Leitung):

- Recherche nach geeigneten Algorithmen für die intelligente Betriebsstrategie
- Aufbau einer Simulationsumgebung für das Training des neuronalen Netzwerks
- Hyperparameter-Tuning und Training des neuronalen Netzwerks
- Implementierung zweier Vergleichsalgorithmen
- Validierung und Bewertung der Betriebsstrategien anhand historischer Daten
- Betrachtung der Batteriealterung des Elektrofahrzeugs
- Implementierung der Schnittstellen und Test für den Einsatz in der Praxis

2.7. Teilprojekt 7: Anwendung, Bewertung & Übertragbarkeit

Das Ziel von KI4ETA ist die praktische Umsetzbarkeit von Energieeffizienzmaßnahmen in der Industrie mithilfe von KI-basierten Algorithmen zu steigern, indem ein ganzheitliches Konzept für eine smarte Energiemanagementplattform entwickelt wird. Dabei werden viele Faktoren von der Datenaufnahme und Transparenzschaffung über Prognosemodelle bis hin zur Optimierung und tatsächlichen Steuerung eines Fabriksystems betrachtet. Im Projekt wurden einzelne Maßnahmen entwickelt, aus denen sich in Kombination konkrete Anwendungsfälle ergeben. Um die zukünftige Anwendbarkeit in der Industrie zu demonstrieren und weiteren Forschungsbedarf aufzudecken, wurden Anwendungsfälle untersucht, bewertet und auf Ihre Wirtschaftlichkeit hin analysiert.

Das Teilprojekt sieben deckt fünf unterschiedliche Anwendungsfälle ab, die an realen Systemen in der Industrie untersucht wurden. Im AP 7.1 wurden zunächst die geschaffenen Grundlagen in Form der IKT-Infrastruktur mit Möglichkeiten zum Datenaustausch sowie deren Sicherheit untersucht. Dabei wurden vor Allem der Einsatz des Edge Devices und der sichere Datenaustausch betrachtet. Außerdem wurde berücksichtigt, dass die KI-Regelsysteme sicher und zuverlässig funktionieren müssen. In AP 7.2 wurden die Maßnahmen zur energetischen Transparenzschaffung und die daraus generierten Vorschläge für Energieeffizienzmaßnahmen in der Industrie angewendet. Dazu wurden die entwickelten Algorithmen, z.B. zur Detektion von Druckluftleckagen, in Produktionsstätten der Industriepartner getestet. Im AP 7.3 wurde ein prototypisches System zur Betriebsoptimierung mit der zugehörigen Datenerfassung und Modellierung umgesetzt. Dazu wurde die Energiemanagementplattform bei der Firma CuroCon installiert und das dortige Automationssystem zur Ansteuerung der Versorgungstechnik umgerüstet, um Schaltbefehle von der Plattform umzusetzen. In AP 7.4 wurden die entwickelten Lösungen zur Nutzung von Energiedaten für die Produktivitäts- und Qualitätsoptimierung im Produktionsumfeld bei EJOT und Bosch Rexroth umgesetzt. Es wurde untersucht, wie groß die dadurch erreichbaren, indirekten Energieeinsparungen sind. Das AP 7.5 lag den Fokus auf den Anwendungsfall der Sektorenkopplung zwischen Fabrik, Stromnetz und Automobilität. Hier wurde in der ETA-Fabrik und bei CuroCon das intelligente Laden von E-Fahrzeugen unter Berücksichtigung des Energieverbrauchs der Produktion betrachtet. Das AP 7.6 führte die verschiedenen Ansätze zusammen und prüfte die Anwendbarkeit des Gesamtkonzepts am Beispiel der ETA-Fabrik und in AP 7.7 sollte die Übertragbarkeit auf die Holz- und Prozessindustrie analysiert werden, um eine möglichst weite Verbreitung der Projektergebnisse auch in andere Industriezweige als der Metallindustrie zu erreichen.

Tabelle 2.17: Arbeitspakete in Teilprojekt 7.

Anwendung, Bewertung & Übertragbarkeit		Beteiligte Partner
Teilprojektleitung: PTW		
AP 7.1	Anwendungsfall: IKT-Infrastruktur, Sicherheit und verbundene Fabriken	PTW, Bosch, Software AG, TÜV
AP 7.2	Anwendungsfall: Transparenzschaffung und Vorschlagswesen für Energieeffizienz	PTW, DFKI, Evonik, Mader, Software AG
AP 7.3	Anwendungsfall: Datenerfassung, -augmentierung und Betriebsoptimierung	PTW, Bosch, CuroCon, etalytics, ÖKOTEC, TÜV
AP 7.4	Anwendungsfall: Energiedatenbasierte Produktivitäts- und Qualitätsoptimierung	EJOT, Bosch

AP 7.5	Anwendungsfall: Sektorenkopplung zwischen Fabrik, Stromnetz, Wärmenetz und Elektrofahrzeug	IMS, Entega
AP 7.6	Untersuchung des Gesamtkonzepts in der ETA-Fabrik	PTW, DFKI, etalytics, IMS, Software AG
AP 7.7	Übertragung der Projektergebnisse auf die Holz- und Prozessindustrie	atlan-tec, GreenDelta

2.7.1. Arbeitspaket 7.1: Anwendungsfall: IKT-Infrastruktur, Sicherheit und verbundene Fabriken

Ziel des Arbeitspakets ist die Untersuchung der Umsetzbarkeit der entwickelten, ganzheitlichen IKT-Infrastruktur in der Industrie am praktischen Beispiel anhand der Reinigungsmaschine MAFAC KEA in der ETA-Fabrik und einer Linearschleifmaschine bei Bosch Rexroth im Werk Schweinfurt.

Die Bearbeitung des Arbeitspakets begann planmäßig im Oktober 2023. Ein zentraler Erfolg war der Aufbau einer virtuellen Version der Linearschleifmaschine von Bosch Rexroth, die als digitaler Zwilling genutzt wurde. Der OPC UA Server dieser virtuellen Maschine verhält sich exakt wie der der realen Maschine, wodurch Experimente zum Extrahieren und Identifizieren von Datenpunkten möglich wurden, ohne die physische Maschine zu beeinträchtigen.

Das von der Software AG entwickelte Datenpunktidentifikationstool konnte erfolgreich alle relevanten Variablen auslesen und korrekt identifizieren. Hierzu war eine Anpassung des ursprünglichen Tools von Nöten, um sämtliche Datentypen, einschließlich Bool'scher und String-Variablen, zu erfassen. Die Identifikation erfolgte durch den Einsatz eines Large Language Modells (LLM), das die Namen der Variablen einliest und anschließend korrekt interpretiert. Eine wichtige Erkenntnis war, dass die Variablen einzeln in das LLM eingegeben werden mussten, um eine hohe Genauigkeit bei der Identifikation zu erreichen. Besonders hervorzuheben ist, dass das Tool die Variablen, die für die Leistungsaufnahme der Maschine und den damit verbundenen CO₂-Ausstoß von Bedeutung sind, erfolgreich identifizierte und für die Leistungs- bzw. CO₂-Berechnung vorschlug.

Für die Reinigungsmaschine MAFAC KEA wurden insgesamt 152 Variablen via OPC UA ausgelesen und ein Dashboard entwickelt. Alle Variablen konnten erfolgreich identifiziert und in die Visualisierungsplattform integriert werden. Die ermittelten Variablen sind nun in der Lage, die aktuelle Leistungsaufnahme der Maschine genau darzustellen. Darüber hinaus ist es möglich, den Demand Response Service aus Arbeitspaket 5.1 über dieses Dashboard zu steuern (siehe Abbildung 2.104).




Abbildung 2.104: Dashboard zum Steuern und Überwachen des Demand Response Services an der MAFAC KEA Reinigungsmaschine.

Die virtuelle Schleifmaschine wurde ebenfalls visualisiert, wobei die Leistung der Maschine, insbesondere in Abhängigkeit vom Vorschub der Achsen, mithilfe der zuvor identifizierten Datenpunkte in Echtzeit angezeigt wird. Die virtuelle Abbildung der Maschine in der Entwicklungsumgebung IndraWorks ist in Abbildung 2.105 dargestellt.




Abbildung 2.105: Digitale Repräsentation der Linearschleifmaschine bei Bosch.

Zusammenfassung der Arbeiten je Partner

Im AP 7.1 wurden zunächst die geschaffenen Grundlagen in Form der IKT-Infrastruktur mit Möglichkeiten zum Datenaustausch sowie deren Sicherheit untersucht. Dabei wurden vor Allem der Einsatz des Edge Devices und der sichere Datenaustausch betrachtet. Außerdem wurde berücksichtigt, dass die KI-Regelsysteme sicher und zuverlässig funktionieren müssen. In AP 7.2 wurden die Maßnahmen zur energetischen Transparenzschaffung und die daraus generierten Vorschläge für Energieeffizienzmaßnahmen in der Industrie angewendet. Dazu wurden die entwickelten Algorithmen, z.B. zur Detektion von Druckluftleckagen, in Produktionsstätten der Industriepartner getestet. Im AP 7.3 wurde ein prototypisches System zur Betriebsoptimierung mit der zugehörigen Datenerfassung und Modellierung umgesetzt. Dazu wurde die Energiemanagementplattform bei der Firma CuroCon installiert und das dortige Automationssystem zur Ansteuerung der Versorgungstechnik umgerüstet, um Schaltbefehle von der Plattform umzusetzen. In AP 7.4 wurden die entwickelten Lösungen zur Nutzung von Energiedaten für die Produktivitäts- und Qualitätsoptimierung im Produktionsumfeld bei EJOT und Bosch Rexroth umgesetzt. Es wurde untersucht, wie groß die dadurch erreichbaren, indirekten

Energieeinsparungen sind. Das AP 7.5 lag den Fokus auf den Anwendungsfall der Sektorenkopplung zwischen Fabrik, Stromnetz und Automobilität. Hier wurde in der ETA-Fabrik und bei CuroCon das intelligente Laden von E-Fahrzeugen unter Berücksichtigung des Energieverbrauchs der Produktion betrachtet. Das AP 7.6 führte die verschiedenen Ansätze zusammen und prüfte die Anwendbarkeit des Gesamtkonzepts am Beispiel der ETA-Fabrik und in AP 7.7 sollte die Übertragbarkeit auf die Holz- und Prozessindustrie analysiert werden, um eine möglichst weite Verbreitung der Projektergebnisse auch in andere Industriezweige als der Metallindustrie zu erreichen.

2.7.2. Arbeitspaket 7.2: Anwendungsfall: Transparenzschaffung und Vorschlagswesen für Energieeffizienz

Ziel des Arbeitspakets ist die Validierung der in TP 3 entwickelten Lösungen zur Schaffung energetischer Transparenz sowie des in TP 4 erarbeiteten Vorschlagswesens. Die Validierung erfolgt sowohl an Fertigungsmaschinen der Firma EJOT als auch in der Produktion bei Mader.

Die Methodik des ganzheitlichen Energiemonitorings, die sämtliche Produktionssystemebenen einer Fabrik einbezieht, wird ausführlich im Bericht zu AP 3.7 beschrieben (siehe Kapitel 2.3.7). Alle Arbeiten innerhalb von TP 3 fügen sich in dieses Vorgehen ein, das schematisch in Abbildung 2.46 dargestellt ist. Im Folgenden werden die Validierungsergebnisse der Maßnahmen zur energetischen Transparenz am EJOT-Standort Tambach vorgestellt. Im Rahmen der Bestandsaufnahme und Grobanalyse analysiert das KI-gestützte Schaltplantooll (siehe AP 3.1) Elektroschaltpläne und identifiziert eigenständig mithilfe von Bilderkennungsalgorithmen Hauptverbraucher. Da die untersuchte Doppeldruckpresse vom Typ HR-6L für die Massenfertigung von Schrauben eingesetzt wird, erfolgt das Energiemonitoring über eine virtuelle Energiemessstelle. Zur temporären Erfassung der erforderlichen Energie- und LED-Zustandsdaten kommen das ETA-Edge-Lense (siehe AP 3.4) sowie ein mobiler Energiemesskoffer zum Einsatz. Anschließend werden die erfassten Daten vorverarbeitet und ein virtuelles Energiemessstellenmodell trainiert. Die Modellierungsergebnisse sind in Tabelle 2.18 zusammengefasst und in Abbildung 2.106 dargestellt. Die Analyse zeigt, dass die Modellierung der Wirkleistung anhand von Zustands-LED-Signalen mit einem sehr geringen Fehler ($NRMSE_R$) zwischen 3 % und 6,7 % erfolgt.

Tabelle 2.18: Prognosegüte des Wirkleistungsbedarfs auf Maschinen- und Komponentenebene für die HR-6L Doppeldruckpresse.

Komponentenmodelle der HR-6L	Anschlussleitung aus Schaltplan in kW	MAE in W	RMSE in W	$NRMSE_R$	$NRMSE_{95-5\%}$	R^2
Hauptschalter	40	92,4	240,9	3,00 %	3,23 %	0,996
Hauptantrieb	18,5	118,4	272,6	3,91 %	4,05 %	0,993
Rauchabzugsmotor	1,5	6,6	8,8	6,70 %	109,77 %	-3,483
Höhenförderer	0,55	1,4	5,7	3,92 %	4,00 %	0,993
Kühlmittelpumpe	0,37	1,4	6,0	4,24 %	4,30 %	0,992




Abbildung 2.106: Zeitverläufe der gemessenen und modellierten Wirkleistung für einen Fertigungszyklus der EJOT HR-6L Doppeldruckpresse und ihrer Nebenaggregate.

Auf Basis der Investitionskosten für virtuelle und physische Energiemessstellen, die Personal-, Einkaufs- und Materialkosten umfassen, lässt sich das Kostenreduktionspotenzial eines virtuellen Energiemessstellenkonzepts im Vergleich zu einem physischen Konzept quantifizieren. Unter der Annahme, dass am EJOT-Standort Tambach 50 vergleichbare Maschinen im Einsatz sind, belaufen sich die Kosten für 50 virtuelle Energiemessstellen auf 10.865 € auf Maschinenebene und 20.718 € auf Komponentenebene. Ein äquivalentes physisches Energiemessstellenkonzept würde hingegen Kosten von 41.870 € für das Energiemonitoring auf Maschinenebene und 165.967 € auf Komponentenebene verursachen.

Die Implementierungskosten des virtuellen Energiemessstellenkonzepts für die 50 Fertigungsmaschinen, einschließlich der energieintensivsten Komponenten, lassen sich im Vergleich zum physischen Energiemonitoring auf Komponentenebene um 145.249 € bzw. 87,5 % reduzieren. Bei einem reinen Monitoring auf Maschinenebene ergibt sich eine Kostensenkung von 31.005 € bzw. 74,1 %. Die hohen Einsparungen resultieren daraus, dass der variable Kostenanteil, der von der Anzahl der Maschinen abhängt, bei virtuellen Energiemessstellen deutlich geringer ausfällt als bei physischen Systemen. Voraussetzung für diese Einsparungen ist jedoch, dass die Validität der virtuellen Energiemessstellen erhalten bleibt und nicht durch Faktoren wie Änderungen im Fertigungsprogramm beeinträchtigt wird.

Die energetische Transparenz der Maschine und ihre interne Energieverteilung können anschließend vom Vorschlagswesen (AP 4.4) genutzt werden, um Energieeffizienzmaßnahmen zu identifizieren. Mithilfe der in AP 3.6 entwickelten Algorithmen zur KI-gestützten Messdatenauswertung werden die Maschinenzustände „Working“, „Operational“ und „Off“ automatisiert auf Basis der Messdatenverläufe bestimmt (siehe Abbildung 2.107). Darauf aufbauend werden Energieleistungskennzahlen berechnet, grafisch aufbereitet und Energieeffizienzmaßnahmen abgeleitet.




Abbildung 2.107: Ergebnis der automatisierten Einteilung von Maschinenzuständen.

Das eingesetzte Vorschlagswesen zielt darauf ab, den Energiebedarf in nichtproduktiven Zeiträumen zu minimieren und den zeitlichen Auslastungsgrad einzelner Maschinen zu maximieren. Zudem liefert es Erkenntnisse zu Einsparpotenzialen einzelner Komponenten. Auf Basis der berechneten Kennzahlen priorisiert das System die Reduktion des Zustands „Operational“, gefolgt von einer Verkürzung des Zustands „Off“. Zudem wird empfohlen, den Rauchabzugmotor außerhalb des produktiven Zustands „Working“ abzuschalten (vgl. Abbildung 2.108). Darüber hinaus zeigt die Analyse, dass der Hauptantrieb den größten Energiebedarf an der betrachteten Anlage hat. Daher ist eine genauere Prüfung, beispielsweise hinsichtlich effizienterer Antriebe, sinnvoll.




Abbildung 2.108: Visualisierung ausgewählter Kennzahlen. Oben links: Zeitanteil Maschinenzustände, oben rechts: Energieanteil Maschinenzustände, unten links: zustandsabhängiger Energieverbrauch je Komponente, unten rechts: Relativer Energieverbrauch je Komponente.

Zusammenfassung der Arbeiten je Partner

PTW (Leitung):

- Vollständiger Durchlauf des Transparenzschaffungsprozesses anhand der EJOT HR-6L Doppeldruckpresse. Dieser umfasst das Trainieren und Validieren der virtuellen Messstelle, die wirtschaftliche Bewertung des Energiemessstellenkonzepts für diesen Maschinentyp sowie die Anwendung des Vorschlagswesens.

DFKI:

- Erfolgreiche Evaluierungsszenarien der automatischen Leckagesuche in mehreren Umgebungen in der ETA, bei Mader und dem DFKI / SmartfactoryKL
- Bereitstellung der gesammelten und aufbereiteten Daten via OPC-UA

Evonik:

- Erfolgreiche Erprobung des in AP 4.4 entwickelten Vorschlagwesens.
- Verlängerung der Ölwechselintervalle und Energieeinsparungen, beides übersetzt in Return on Investment, wurde als Hauptargument identifiziert, um auf Managementebene die Umstellung auf effizientere Betriebsstoffe voranzutreiben.
- Diese Einsparungen tragen nicht nur zur Verbesserung der Betriebskosten bei, sondern haben auch positive volkswirtschaftliche Auswirkungen durch die Reduktion des Energiebedarfs und der damit verbundenen Kosten.

Mader:

- Erfolgreicher Feldtest des Leckageroboters unter anderem auch bei Mader in der Fertigung.

Software AG:

- Erfolgreiche Erprobung des in AP 3.6 entwickelten Algorithmus zur KI-gestützten Messdatenauswertung anhand der EJOT HR-6L Doppeldruckpresse.

2.7.3. Arbeitspaket 7.3: Anwendungsfall: Datenerfassung, -augmentierung und Betriebsoptimierung

Basierend auf den erfassten Daten, der IKT-Infrastruktur und den Transparenzschaffungsmaßnahmen werden im Projekt Algorithmen zur Optimierung der Datenqualität, Kurzfristprognose und Betriebsoptimierung entwickelt und implementiert. Damit ein System zur Betriebsoptimierung funktionsfähig wird, muss die vollständige Kette von der Datenerfassung über die -weiterverarbeitung bis hin zur Optimierung abgebildet werden.

Die entwickelten Lösungen werden in AP 7.3 durch die Anwendung in der Industrie validiert und ihre Nutzung getestet. Der Vergleich mit der im Normalfall gewählten Betriebsstrategie dient dabei zur Bewertung der erarbeiteten Algorithmen. Zusätzlich wird die Genauigkeit getroffener Modellannahmen bzw. die Anwendbarkeit im realen Umfeld bewertet und Probleme, welche bei der Implementierung von KI-gestützten Assistenzsystemen auftreten ermittelt. Hierfür werden unterschiedliche Anwendungsfälle betrachtet.

1) Energiekennzahlengenerators Kälteverbundanlage

Die Modellierung des Energiekennzahlengenerators von ÖKOTEC am Beispiel der Kälteverbundanlage konnte durch die Übergabe der Sollwerte an die Steuerung der Kälteverbundanlage getestet und verifiziert werden. Das Modell kann den berechneten Benchmark für das Systemmodell umsetzen, da die thermische Modellierung der Zustände für die gewählten Zeiträume der nächsten drei bis vier Tage valide ist. Das zeigt ein Vergleich der modellierten Temperaturverläufe mit den realisierten Temperaturen unter Nutzung der Sollwertvorgabe.

Die Parametrierungsalgorithmen und der Energiekennzahlengenerator wurden angewendet, um das Optimierungsmodell aufzubauen und in eine kontinuierlich lauffähige Umgebung innerhalb der Software EnEffCo zu bringen. Modelliert wurde die Verbundkälteanlage eines Kühllagers mit dem Ziel, unter der Gewährleistung der Hallentemperaturen einen Fahrplan des Anlageneinsatzes der Verdichter und Kühlstellen für die nächsten vier Tage zu erstellen, die Energiebedarf und Energiekosten minimiert. Das Modell muss in der Lage sein, dynamische Systemzustände in der Warenauslastung, den Umgebungsbedingungen, und nichtplanbarer Lagersituationen kontinuierlich zu parametrieren und

über mehrere Tage den Energiebedarf unter Einhaltung der definierten Kühlraumtemperaturen zu optimieren.

In Bezug auf die kontinuierliche Anwendung des Modells im Regelbetrieb des Kühllagers wurden Auswertungen und Reports zur Überwachung erstellt. Aus der Betriebsoptimierung der Verbundkälteanlage kann ein Fahrplan des Strombedarfs der Anlage berechnet werden. Für den Energieversorger ist jedoch der Gesamtlastgang des Standorts relevant. Dieser umfasst die restlichen Stromverbraucher, die teilweise von der Fahrweise der Kälteanlage abhängig sind und teilweise ein eigenständiges Verbrauchsprofil aufweisen. Auf Basis einer Regressionsanalyse wurde ein Modell der restlichen Stromverbraucher erstellt. Damit kann nun der Gesamtlastgang berechnet werden.

Zudem wurden Benchmarks der Betriebsoptimierung für den Energiebedarf und die Stromkosten hinsichtlich der Einflussfaktoren der Außentemperatur und der Lagertätigkeit erstellt. Dazu wurde ein Regressionsmodell für den historischen Zeitraum für die Übernahme der Steuerung angelern. Das Modell bildet den Energiebedarf der Verbundkälteanlage ohne Einsatzoptimierung ab. Es kann festgestellt werden, dass eine bessere Einhaltung der Grenzwerte und eine effizientere Auslastung der Verdichter durch die Optimierung Energieeinsparungen von bis zu 25 % als Mittelwert über eine Woche bringt, abhängig von den Einflussfaktoren. Die Einsparungen bei den Stromkosten, d.h. die verbesserte Nutzung von Zeiten mit geringen Stromkosten wurde mittels der Abweichung von gewichteten Tagesmittelwert des Strompreises erzielt. Es konnte zuvor gezeigt werden, dass der nichtoptimierte Einsatz der Anlage durch sein regelmäßiges Schaltverhalten gewichtet mit dem Stromverbrauch über den Tag etwa den Tagesmittelwert des Strompreises trifft. Die Flexibilität der Kälteverbundanlage ist nun einerseits von der Einhaltung der Hochlastzeitfenster im Herbst und Winter und andererseits von der Lagertätigkeit in der Außentemperatur abhängig. Gerade am Anfang des Jahres und im Frühjahr werden die Lager wieder für die kommende Sommersaison mit Ware aufgefüllt, was mit einem erhöhten Kühlbedarf und damit einer geringeren Flexibilität einhergeht. Über diesen Zeitraum konnte dennoch ein gewichteter Strompreis für den Bedarf der Kälteanlage um 5 – 10 % unterhalb des mittleren Preises ermittelt werden.

Um die Demonstration des Anwendungsfalls abzuschließen, wurde ein Dashboard zur Überwachung der Modellinputs und der Modellberechnungsschritte angelegt. So konnte jederzeit durch den assoziierten Partner überprüft werden, dass das Modell in der Demonstrationsphase korrekt ausgeführt wurde.

2) etaEdge-Gateway bei CuroCon

Um die Aufnahme von Messdaten von CuroCon in die Energiemanagementplattform zu ermöglichen, wurde durch etalytics ein Edge-Device als Hardware-Gateway aufgesetzt. Abstimmungen bezüglich der Systemgrenzen und der Datenanbindung der Einzelkomponenten ergaben hierbei, dass alle für den Anwendungsfall notwendigen Daten über OPC UA verfügbar sind.




Abbildung 2.109: Beispielhafte über das Hardware-Gateway aufgenommene Zeitseriendaten.

Nach der Einbindung des Edge Devices in das Gebäudenetz konnten initiale Netzwerkprobleme durch die beim Aufsetzen ermöglichte Fernwartung behoben werden. Somit konnten die entsprechenden Datenpunkte erfolgreich angebunden und Daten in die Energiemanagementplattform gestreamt werden. Durch fortlaufende Softwareupdates sowohl von Hardware-Gateway als auch von der verwendeten Instanz der Energiemanagementplattform wurde eine kontinuierliche Datenaufnahme sichergestellt.

Im Rahmen einer Masterthesis wurden zusätzliche temporäre Temperatur- und Leistungsmessungen bei CuroCon seitens TU Darmstadt durchgeführt. CuroCon unterstützte bei den Updates und Zuverlässigkeitstests des etaEdge-Gateways. Die Installation und Parametrierung sowie SPS-Anbindung der KNX-Komponenten (Thermostate, Heizungsaktoren, Wärmepumpensteuereinheit) hat stattgefunden. Um auch den Betrieb der autarken Klimaanlage zu optimieren, wurde diese an die SPS angebunden. Somit kann anhand der Messwerte, des Wochentages und der Uhrzeit die Anforderung bedarfsorientiert gesteuert werden.

3) Linearschleifmaschine bei Bosch

Durch den Einsatz von ML-Methoden sollten wesentliche Fortschritte beim Erstellen eines Digitalen Zwillings für die Validierung der im Rahmen KI4ETA erstellten KI-Methoden und Algorithmen ermöglicht werden. Dafür sind neben der bekannten Emulation der CNC-Steuerungstechnik auch der eigentliche Bearbeitungsprozess maßgeblich. Die ML-basierte und somit so weit wie möglich automatisierte Erstellung des Digitalen Zwillings für die CNC-Emulation ist ein Schwerpunkt. Neben dem schon erstellten Energiemodell wurde eine modellhafte Abbildung der Ursache-Wirkbeziehungen der Qualitätszusammenhänge entwickelt.




Abbildung 2.110: Ausschnitt des für die Animation benötigten CAD-Modells mit Schwerpunkt auf die für den Prozess (rosa hervorgehoben) relevanten Schleifscheiben.




Abbildung 2.111: Sicht auf die Aufstellung des für die Animation benötigten CAD-Modells mit Referenz auf den physikalischen Zwilling.

Zusammenfassung der Arbeiten je Partner

PTW (Leitung):

- Abstimmungen mit etalytics zur Fehlerbehebung der etaOne-Plattform-Anbindung
- Betreuung einer Masterthesis zur Optimierung der Versorgungstechnik bei CuroCon, in Verbindung mit der Photovoltaikanlage
- Koordination mit dem IMS der TU Darmstadt und Festlegung von Schnittstellen für die Optimierungszuständigkeiten
- Erfolgreiche Anbindung an die etaOne Plattform
- Fortschreitende methodische Erfassung des Optimierungsproblems, Erstellung eines mathematischen Modells der Versorgungstechnik und Implementierung mit dem OpenSource Framework eta-utility aus KI4ETA

Bosch:

- Bewertung und Aufbau einer Prozesssimulation für die betrachteten Linearschleifmaschine
- Prüfung der Eignung der aus der Literatur bekannten Ansätze für die Prozesssimulation
- Prüfung von ML-Ansätzen für ein Ersatzmodell zur Vereinfachung der Prozesssimulation

CuroCon:

- Unterstützung bei den Updates und Zuverlässigkeitstests der etaOne Plattform
- Absprachen mit dem PTW bzgl. der Masterthesis
- Temporäre Zusatz-Temperatur und Leistungsmessung wurde durchgeführt
- Installation und Parametrierung der KNX-Komponenten (Thermostate, Heizungsaktoren, Wärmepumpensteuereinheit)

etalytics:

- Bereitstellung und Konfiguration eines Hardware-Gateways als Schnittstelle zur Datenübertragung an eine Instanz der Energiemanagementplattform

- Ermöglichen und Durchführung von Fernwartung und Updates der Gateway-Software und der Netzwerkkonnektivität
- Bereitstellung der Energiemanagementplattform sowie Unterstützung bei der Datenpunktanbindung
- Regelmäßige Updates der Energiemanagementplattform

ÖKOTEC

- Demonstration und Auswertung des optimierten Anlagenbetriebs
- Erweiterung der Auswertung der Betriebsoptimierung aus das Fahrplanmanagement des Gesamtstandorts (Prognose des erwarteten optimierten Strombezugs)
- Einrichtung einer Überwachung der Betriebsoptimierung

2.7.4. Arbeitspaket 7.4: Anwendungsfall: Energiedatenbasierte Produktivitäts- und Qualitätsoptimierung

Im Rahmen des Projekts wurden bei EJOT zwei Demonstratoren mit der erforderlichen Sensorik für Condition Monitoring und Bauteilqualitätsanwendungen ausgestattet. Diese Demonstratoren ermöglichen es, die im Projekt entwickelten Lösungen hinsichtlich ihrer Anwendbarkeit in der Industrie sowie auf wirtschaftliche und energetische Potenziale zu evaluieren. Ein Demonstrator wurde im Werk Tambach (Tambach-Dietharz) installiert, während eine weitere Maschine im Werk Herrenwiese (Bad Berleburg) zum Einsatz kam.

Zur Schaffung einer soliden Datengrundlage wurden mehrere Produktionstage genutzt. Die gesammelten Daten wurden anschließend hinsichtlich ihrer Qualität und Plausibilität analysiert. Der Einsatz von Energiedaten erwies sich als nicht zielführend. Stattdessen lieferten Kraftsensoren näher am Produktionsprozess signifikant aussagekräftigere Daten. Basierend auf diesen Erkenntnissen wurde das Preprocessing konzipiert und umgesetzt, wobei ein Down Sampling beschlossen wurde. Mehrere KI-Modelle wurden trainiert und getestet; die Anomalie-Detektion lieferte hierbei die besten Ergebnisse.

Eine Software wurde entwickelt, die eine Echtzeit-Visualisierung der Kraftverläufe und anderer produktionstechnischer Kenngrößen ermöglicht, was zur Transparenz der Entscheidungen des KI-Modells beiträgt. Diese Software wurde an den Maschinen getestet, wobei paralleles Modelltraining und Transfer Learning zum Einsatz kamen. Die Validierung der Bauteilqualitätsalgorithmen führte zu zufriedenstellenden Ergebnissen, wodurch der Werkzeugverschleiß eine gesamte „Verschleißstufe“ früher erkannt werden konnte als mit bisherigen Überwachungsverfahren.




Abbildung 2.112: Visualisierung der Fehlererkennung in einem früheren Fehlerstadium.

Diese frühere Detektion kann, basierend auf den Beobachtungen der Erprobungsphasen, zu einer Einsparung von 10-20% des aktuellen Schrotts führen. Eine Einsparung von 10% entspricht 395,5 MWh oder 79.100 € pro Jahr, während eine Einsparung von 20% 791,0 MWh oder 158.200 € pro Jahr bedeuten würde (bei Annahme von 20 Cent/kWh). Aufgrund des erzielten Erfolgs hat sich EJOT entschlossen, das System weiter auszuarbeiten, mit dem Ziel eines weltweiten Einsatzes.

Die Grundlage für die bei Bosch getätigten Untersuchungen ist der in Arbeitspaket 5.1 aufgebaut Digitale Zwilling. Neben den eigentlichen Achsbewegungen wurden auch die Nebenzeiten in die Einsparungsbetrachtung einbezogen. Hierfür wurde der für eine Fräsbearbeitung erstellte Digitale Zwilling genutzt und der Werkzeugwechsel sowohl in der graphischen Simulation als auch im Energiemodell modelliert.




Abbildung 2.113: Integration der Nicht-NC-Achsen für den Werkzeugwechsel

Als Referenzprozess wurde hier das Sechskantfräsen aus einem Rundmaterial herangezogen. Die Aussagefähigkeit des Digitalen Zwillings wurde durch eine Messung bestätigt und die Abweichung mit 0,3% ist im Bereich von üblichen Messtoleranzen anzusiedeln.




Abbildung 2.114: Bild links: Ablaufsimulation der Bearbeitung; rechts: Vergleich zwischen Messung und Digitalem Zwillinge

Die in Arbeitspaket 5.1 beschriebenen 9 % Einsparung durch Änderung der Bewegungsprofile konnte auch durch den Digitalen Zwilling bestätigt werden. Des Weiteren sind durch Verbesserungen in der Bearbeitungsbewegung im NC-Code weitere 15 % an Zeitersparnis möglich – es kommt zu einer leichten Erhöhung der Prozessgesamtleistung jedoch nicht der Spitzenlast. Es kann von einer Einsparung von 12 % ausgegangen werden. Diese Aussage wurde für ein Werkzeug für ein Produkt von einer Jahresproduktion von 3 Mio. Stück verifiziert. Daraus kann sich ein Einsparpotential von 104 MWh (20.800 € bei Annahme von 20 Cent/kWh) ergeben – von zentraler Bedeutung ist, dass keine Änderungen an der Werkzeugmaschine durchgeführt werden müssen und keine weiteren Investitionskosten entstehen. Dies NC-Code basierte Optimierung kann auf weitere Bearbeitungsprozess übertragen werden. Da fast in jeder gefertigten Baugruppe Elemente wie Schlüsselflächen oder Sechskantflächen ist von einer großen Wirkung auszugehen.

Zusammenfassung der Arbeiten je Partner

EJOT (Leitung):

- Zwei Demonstratoren mit Sensorik ausgestattet (Werk Tambach und Werk Herrenwiese) zur Evaluierung industrieller Anwendbarkeit
- Analyse der Produktionsdaten ergab, dass Kraftsensoren aussagekräftiger sind als Energiedaten
- Entwicklung eines Preprocessing-Ansatzes mit Down Sampling und Training mehrerer KI-Modelle, beste Ergebnisse bei Anomalie-Detektion
- Software zur Echtzeit-Visualisierung der Kraftverläufe entwickelt und erfolgreich getestet
- Früherkennung von Werkzeugverschleiß ermöglicht Schrottreduktion um bis zu 20 % (Einsparung bis zu 158.200 € pro Jahr)
- EJOT plant aufgrund des Erfolgs die weltweite Einführung des Systems

Bosch:

- Nutzung des Digitalen Zwillings für Fräsbearbeitung aus Arbeitspaket 5.1
- Aufbereitung eines Optimierungsszenario basierend auf einer Sechskant Fräsbearbeitung
- Umsetzung an einer Beispielmachine und Messungen für den Abgleich der Simulation
- Aufbau eines hybriden Modells (Daten- und wissensbasierter Ansatz)
- Bewertung der Ergebnisse

2.7.5. Arbeitspaket 7.5: Anwendungsfall: Sektorenkopplung zwischen Fabrik, Stromnetz, Wärmenetz und Elektrofahrzeug

Dieses Arbeitspaket hat zwei zentrale Ziele: Zum einen soll ein Demonstrator zur Sektorenkopplung in produzierenden Unternehmen entwickelt werden, der eine intelligente Steuerung der bestehenden Ladeinfrastruktur ermöglicht. Zum anderen soll eine wirtschaftliche Betrachtung dabei helfen, die durch Sektorenkopplung entstehenden Potenziale zu bewerten und die durch den Energiemarkt definierten Rahmenbedingungen zu analysieren.

Aufbau eines Demonstrators:

Für die Erarbeitung eines geeigneten Algorithmus, mit welchem die optimierte Betriebsstrategie für die Ladeinfrastruktur bei CuroCon ermittelt wird, wurden zunächst drei verschiedene Ansätze untersucht: die gemischt-ganzzahlige mathematische Optimierung (MILP), eine Heuristik in Form des Grey Wolf Algorithmus sowie ein vereinfachter Ansatz mithilfe von Fuzzy Logic. Diese drei Ansätze wurden parallel entwickelt und gegeneinander verglichen, um den bestmöglichen Lösungsansatz zu finden. Demgegenüber standen zwei einfache Algorithmen. Der erste Vergleichsalgorithmus nennt sich „First-Come-First-Serve“, wobei die Fahrzeuge und deren Ladevorgänge nach der Ankunftszeit priorisiert werden. Beim zweiten Vergleichsansatz werden die Ladeleistungen der Elektrofahrzeuge möglichst gleichmäßig verteilt, indem die benötigte Energiemenge durch die maximal mögliche Ladezeit dividiert wird. Dieser Ansatz wird als „Rectangle Optimization“ Ansatz bezeichnet, da hier der Ladevorgang im übertragenen Sinne als rechteckiges Fenster dargestellt wird, mit der Parkdauer als Länge des Rechtecks und der benötigten Energiemenge als Höhe des Rechtecks. Die Diagonale des Rechtecks von links unten nach rechts oben spiegelt somit den Verlauf der in das Fahrzeug geladenen Energie dar, deren Steigung die Ladeleistung darstellt.

Um ein möglichst praxistaugliches Optimierungssystem aufzubauen, wurden die Randbedingungen sowie die Anforderungen an das System gemeinsam mit CuroCon erarbeitet. Ein zentraler Aspekt war hier neben den technischen Randbedingungen auch die Möglichkeit, Fahrzeuge bzw. Ladesäulen unterschiedlich zu priorisieren, sodass verschiedene Rollen (Pool-Fahrzeuge, Gäste, Privatfahrzeuge) abgebildet werden können und die zugehörigen Fahrzeuge entsprechend behandelt werden. Damit ergibt sich neben dem Hauptziel der Optimierung des Eigenverbrauchs der PV-Energie ein sekundäres Ziel.

Für die Untersuchungen der Algorithmen wurde eine Simulationsumgebung aufgebaut, in der das Fahrzeugverhalten abgebildet werden kann. Zudem wurden historische PV-Erzeugungsdaten implementiert, sowie exemplarische dynamische Energiepreise. Zur Untersuchung der Algorithmen wurden zahlreiche Szenarien definiert, die sich in der Jahreszeit, dem Fahrzeugaufkommen und zufälligen Variationen der An- und Abfahrtszeiten unterscheiden. Zur Beurteilung des Verhaltens wurden insgesamt drei Faktoren identifiziert. Dabei handelt es sich um die PV-Nutzungsrate, einen Ladeerfolgsindikator sowie die durch die Ladevorgänge entstandenen Energiekosten. Die PV-Nutzungsrate gibt an, wie viel der produzierten PV-Energie für das Laden der Fahrzeuge genutzt wurde. Der Ladeerfolgsindikator gibt an, ob alle Fahrzeuge die benötigte Energie zum Erreichen des Wunschladestands erhalten haben. Da auch eine Priorisierung der Fahrzeuge vorgenommen wurde, wird diese hier als zusätzlicher Faktor gewichtet. Dadurch stellt der Ladeerfolgsindikator einen abstrakten Wert dar, der bei Erfüllung aller Ladeziele bei null liegt und bei Nichterfüllung nichtlinear steigt.

Nach anfänglichen Untersuchungen stellte sich heraus, dass der MILP-Ansatz die vielversprechendsten Ergebnisse liefert. Sowohl der Grey-Wolf-Algorithmus als auch der Fuzzy-Logic Ansatz waren nicht in der Lage, besser als Vergleichsalgorithmen (Rectangle Optimization und First-Come-First-Serve) abzuschneiden, wohingegen der MILP-Ansatz in der vorliegenden Form zumindest in zahlreichen Szenarien sowohl bei der PV-Nutzungsrate als auch beim Ladeerfolg besser abschnitt als die Vergleichsmethoden. Daraufhin wurde der MILP-Ansatz als einziger intelligenter Ansatz weiterverfolgt und verbessert. Dies erfolgte vor allem im Hinblick auf die Gewichtung und Anpassung der einzelnen Faktoren in der Zielfunktion, um die teilweise entstehenden Zielkonflikte (zwischen Optimierung der PV-Nutzung und Vollladen der Fahrzeuge) zu lösen. Außerdem wurden die Bedingungen der Optimierungsumgebung so angepasst, dass stark schwankende Leistungsvorgaben für einzelne Fahrzeuge verhindert werden und möglichst gleichmäßige Ladeprofile entstehen. Ein exemplarisches Szenario mit insgesamt acht Fahrzeugen ist in Abbildung 2.115 zu sehen. Hier ist zu erkennen, dass die Ladevorgänge zeitlich so eingeplant werden, dass der Großteil der verfügbaren PV-Energie für das Laden genutzt wird. Allerdings ist auch zu sehen, dass ein Fahrzeug nicht komplett vollgeladen werden kann, was sich negativ auf den Ladeerfolgsindikator auswirkt. Hier handelt es sich jedoch um ein gering priorisiertes Fahrzeug (absteigende Priorisierung von oben nach unten).




Abbildung 2.115: Simulative Ergebnisse des Optimierungssystems an einem beispielhaften Szenario.

Tabelle 2.19 zeigt die Kernergebnisse für alle betrachteten Szenarien im Sommer. Die Winter-Szenarien wurden hier nicht mitberücksichtigt, da hier nur eine sehr geringe PV-Produktion vorherrscht und damit die Ergebnisse eine geringe Aussagekraft haben. Es ist zu erkennen, dass der MILP-Ansatz sowohl bei der PV-Eigennutzungsrate als auch bei den Stromkosten die besten Ergebnisse im Vergleich zu den Vergleichsalgorithmen bietet, während der First-Come-First-Serve bei beiden Bewertungskriterien am schlechtesten abschneidet. Beim Ladeerfolgs-Indikator sticht jedoch die Rectangle Optimization heraus,

während der MILP-Ansatz hier den größten Fehler aufweist. Dies ist zu erklären durch den Zielkonflikt, der sich aus der möglichst kostengünstigen Ladung der Fahrzeuge und der gewünschten Priorisierung der Fahrzeuge ergibt. Da die Vergleichsalgorithmen keine Priorisierung beinhalten, ist es hier wesentlich einfacher, die Fahrzeuge mit der benötigten Energie zu versorgen, allerdings führt das zu einer geringeren Nutzung der PV-Eigenproduktion und somit zu höheren Stromkosten. Zudem kann sich durch neu ankommende Fahrzeuge der Fahrplan für die Erfüllung der Ladevorgänge beim MILP-Ansatz drastisch verändern, während dies bei den Vergleichsalgorithmen nur geringe Auswirkungen hat.

Tabelle 2.19: Gemittelte Ergebnisparameter für alle untersuchten Sommer-Szenarien.

Kernergebnisse für die Sommer-Szenarien			
	Rectangle Opt.	First-Come-First-Serve	MILP
PV-Eigennutzung	76,5 %	58,0 %	80,5 %
Tägl. Stromkosten	17,09 €	20,42 €	14,02 €
Ladeerfolgs-Indikator	0,38	0,50	0,57

Obwohl eine Umsetzung des intelligenten Lademanagements am Realsystem bei CuroCon geplant war, konnte dies im Rahmen der Projektlaufzeit nicht umgesetzt werden. Die Gründe hierfür waren vor allem Kapazitätsengpässe, die durch zusätzliche Arbeitsaufwände in anderen Teilprojekten und Arbeitspaketen (z.B. AP 6.3) anfielen. Dadurch war es nicht möglich, die benötigten Schnittstellen zu implementieren, um die Optimierungsumgebung an die Ladeinfrastruktur bei CuroCon anzubinden.

Untersuchung der wirtschaftlichen Aspekte:

In diesem Teil des Arbeitspakets wird untersucht, wie u. a. durch Sektorenkopplung Anreize für den energieflexiblen Betrieb einer Fabrik geschaffen werden können. Hierzu wurde ein Simulationsmodell entwickelt, das industrielle Lasten mit Photovoltaik-Erzeugung, Batteriespeichern und Ladestationen für den Fuhrpark kombiniert. Auf Basis dieses Modells erfolgt eine vergleichende Bewertung unterschiedlicher Liefer- und Bewirtschaftungsvarianten. Ausgangspunkt ist die Belieferung zu einem Festpreis-Tarif, wobei die Beschaffung der Liefermengen für den jeweiligen Folgetag auf Basis von Prognosen erfolgt, die auf Vortageswerten aufsetzt. Im ersten Schritt wird diese Methode mit einer gesteigerten Prognosequalität verglichen, die durch die Verwendung untertägiger Verbrauchswerte erreicht wird.




Abbildung 2.116: Vergleich der energiewirtschaftlichen Prozesse bei reiner DayAhead- sowie IntraDay-Bewirtschaftung.

Für die Simulation wurden Vergleichswerte von Industrie- und Gewerbekunden sowie PV-Anlagen herangezogen. Die realen Nutzungsdaten eines betrieblichen Ladeparks wurden analysiert, um Prognosen für die eMobilitätsladeinfrastruktur zu erstellen.

Lastbereich		<--Unterschätzung Überschätzung-->																			
5,1	5,8	0%	0%	0%	0%	0%	1%	2%	3%	5%	14%	18%	22%	19%	8%	3%	2%	1%	1%	0%	0%
5,8	6,4	0%	0%	0%	0%	0%	1%	2%	3%	5%	14%	18%	22%	19%	8%	3%	2%	1%	1%	0%	0%
6,4	7,1	0%	0%	0%	0%	0%	1%	2%	3%	5%	14%	18%	22%	19%	8%	3%	2%	1%	1%	0%	0%
7,1	7,8	0%	0%	0%	0%	0%	3%	2%	1%	7%	13%	19%	18%	19%	11%	5%	1%	0%	1%	0%	0%
7,8	8,5	0%	0%	0%	0%	0%	0%	3%	6%	10%	15%	21%	14%	11%	10%	8%	2%	1%	0%	0%	0%
8,5	9,2	0%	0%	0%	0%	0%	0%	5%	11%	10%	15%	16%	13%	9%	13%	4%	4%	1%	0%	0%	0%
9,2	9,9	0%	0%	0%	0%	0%	2%	9%	5%	12%	14%	14%	9%	12%	18%	2%	2%	0%	0%	0%	0%
9,9	10,6	0%	0%	0%	0%	0%	0%	1%	8%	13%	14%	20%	9%	11%	15%	9%	0%	0%	0%	0%	0%
10,6	11,3	0%	0%	0%	0%	0%	0%	2%	19%	3%	9%	0%	3%	29%	34%	1%	0%	0%	0%	0%	0%
11,3	12,0	0%	0%	0%	0%	0%	22%	0%	1%	4%	0%	0%	35%	25%	13%	0%	0%	0%	0%	0%	0%

Lastbereich		<--Unterschätzung Überschätzung-->																			
5,1	5,75	0%	0%	0%	0%	0%	0%	0%	0%	0%	2%	41%	54%	2%	1%	0%	0%	0%	0%	0%	0%
5,75	6,45	0%	0%	0%	0%	0%	0%	0%	0%	0%	2%	52%	41%	2%	1%	1%	0%	0%	0%	0%	0%
6,45	7,15	0%	0%	0%	0%	0%	0%	0%	0%	0%	2%	48%	44%	2%	1%	1%	0%	0%	0%	0%	0%
7,15	7,85	0%	0%	0%	0%	0%	0%	0%	0%	0%	2%	51%	45%	2%	1%	0%	0%	0%	0%	0%	0%
7,85	8,54	0%	0%	0%	0%	0%	0%	0%	1%	1%	4%	56%	37%	1%	0%	0%	0%	0%	0%	0%	0%
8,54	9,24	0%	0%	0%	0%	0%	0%	0%	2%	3%	7%	52%	33%	2%	0%	0%	0%	0%	0%	0%	0%
9,24	9,94	0%	0%	0%	0%	0%	0%	0%	0%	1%	6%	51%	39%	1%	1%	0%	0%	0%	0%	0%	0%
9,94	10,64	0%	0%	0%	0%	0%	0%	0%	0%	1%	7%	65%	26%	1%	0%	0%	0%	0%	0%	0%	0%
10,64	11,33	0%	0%	0%	0%	0%	0%	0%	0%	1%	6%	64%	29%	0%	0%	0%	0%	0%	0%	0%	0%
11,33	12,0	0%	0%	0%	0%	0%	0%	0%	0%	10%	14%	56%	21%	0%	0%	0%	0%	0%	0%	0%	0%

Abbildung 2.117: Beispielhafter Vergleich der Prognosequalität bei reiner DayAhead- sowie bei IntraDay-Bewirtschaftung.

Fahrzeug mit Ladestation verbunden (Stunden)																
Ankunftszeit	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16
1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
2	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
3	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
4	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
5	1	1	2	4	8	1	2	3	2	9	0	0	0	0	0	0
6	9	11	17	18	11	27	10	7	29	29	7	0	0	0	0	0
7	7	15	18	22	61	48	35	41	75	39	18	3	0	0	0	0
8	11	11	9	28	34	29	26	31	36	24	14	0	1	0	0	0
9	0	3	7	9	8	7	6	16	3	0	1	0	0	0	0	0
10	2	1	5	4	3	7	3	3	1	0	0	0	0	0	0	0
11	3	5	4	5	7	9	3	3	0	0	0	0	0	0	0	0
12	8	7	9	21	19	13	3	0	0	1	0	0	0	0	0	0
13	2	11	15	7	12	1	0	0	0	0	0	0	0	0	0	0
14	2	14	10	4	4	0	0	0	0	0	0	0	0	0	0	0
15	1	3	6	0	0	0	0	0	0	0	0	0	0	0	0	0
16	3	2	1	0	0	0	0	0	0	0	0	0	0	0	0	0
17	0	1	2	1	0	0	0	0	0	0	0	0	1	1	1	1
18	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
19	1	0	0	0	0	0	0	0	0	0	0	1	0	0	1	1
20	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0
21	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
22	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0
23	0	0	0	0	0	0	0	0	2	0	0	0	0	0	0	0
24	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0

Energiebezug in kWh																
Ankunftszeit	5	10	15	20	25	30	35	40	45	50	55	60	65	70	75	80
1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
2	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
3	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
4	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
5	10	6	10	4	0	0	1	0	0	0	1	0	0	0	1	0
6	39	37	50	7	12	7	6	3	2	5	4	2	2	1	1	0
7	36	85	124	34	21	17	16	12	15	5	4	4	8	4	1	0
8	30	55	79	18	11	13	15	8	12	9	3	3	1	4	1	0
9	8	12	11	9	5	6	5	3	1	1	0	0	0	0	0	0
10	11	5	3	6	0	1	1	2	1	1	1	1	0	0	0	0
11	12	12	9	5	3	2	2	3	1	0	1	0	0	0	0	0
12	21	19	19	10	6	3	5	2	1	2	1	0	0	1	0	0
13	21	15	4	5	5	5	3	1	3	0	0	0	0	0	0	0
14	16	11	7	6	4	4	1	1	0	2	0	0	0	0	0	0
15	9	3	3	0	1	0	1	0	0	0	0	0	0	0	0	0
16	4	1	5	0	1	1	0	1	1	0	1	0	0	0	0	0
17	1	2	3	2	0	2	0	2	0	0	0	0	0	0	0	0
18	0	0	0	0	0	1	1	0	0	0	0	0	0	0	0	0
19	1	1	2	0	0	0	0	0	0	0	0	0	0	0	0	0
20	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0
21	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
22	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0
23	0	0	2	0	0	0	0	0	0	0	0	0	0	0	0	0
24	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0

Abbildung 2.118: Analyse eines betrieblichen Ladeparks als Input für das Simulationsmodell.




Abbildung 2.119: Entwicklung der Prognosequalität für Ladevorgänge im täglichen Verlauf.

Charakteristisch ist hierbei, dass mit jeder untertägigen Ankunft eines Fahrzeugs die Prognosequalität für den restlichen Tagesverlauf sprunghaft ansteigt. Die simulative Analyse auf Basis von Preisdaten für den Zeitraum Q3/23 bis Q1/24 zeigt, wie sich die Prozessanpassung auf Prognosequalität und Ausgleichsenergiekosten auswirkt.




Abbildung 2.120: Prognosequalität bei DayAhead- und IntraDay-Bewirtschaftung sowie resultierende Preisaufschläge für Ausgleichsenergiekosten.

Im nächsten Schritt wurde die Option der Eigenverbrauchsoptimierung untersucht, bei der die gezielte Nutzung des Batteriespeichers und die Steuerung der Ladevorgänge ergänzt wurden. Zunächst wird der Festpreis-Tarif beibehalten, anschließend erfolgt eine Erweiterung um Real Time Pricing, bei dem Intraday-Preise inklusive Risikoprämie (s. u.) zweimal pro Viertelstunde übermittelt werden.




Abbildung 2.121: Vergleich der energiewirtschaftlichen Prozesse bei Eigenverbrauchsoptimierung sowie bei preis-orientierter Flex-Bewirtschaftung.




Abbildung 2.122: Ergebnis der Eigenverbrauchsoptimierung zu Tages- und zu Produktionsbeginn¹.

¹ Der PV-Strom wird mit ähnlich hoher Priorität für die Ladevorgänge genutzt wie für die Deckung der Produktionslast. Gelb dargestellte PV-Mengen vor dunkelblauem Hintergrund (=Produktion) fließen entsprechend in die Ladeinfrastruktur (hellblau). Verbleibende Überschüsse werden – freie Kapazitäten vorausgesetzt – in der Batterie zwischengespeichert.

Die Ergebnisse zeigen, dass die Ladevorgänge so eingetaktet werden, dass zu erwartende PV-Überschüsse in Randstunden für die Speicher-Beladung und Ladevorgänge genutzt werden können. Auch sonst wird die PV-Erzeugung direkt für die Elektromobilität verwendet. Die Kosteneinsparung gegenüber ungesteuertem Laden ist hierbei mit ca. 5 % relativ gering. Der Batteriespeicher wird zunächst für die Zwischenspeicherung der PV-Überschüsse genutzt und anschließend, sofern der Ladestand es zulässt, zum kurzfristigen Ausgleich von Prognoseabweichungen.




Abbildung 2.123: Ergebnis der preis-orientierten Flex-Bewirtschaftung zu Tages- und zu Produktionsbeginn.

Die Einsparung bei der Spot-Bepreisung beträgt rund 15 % bezogen auf die reinen Beschaffungskosten, wobei der vorherige Flat-Preis dem Durchschnitt der Spot-Preise im betrachteten Zeitraum entspricht. Hierbei ist jedoch zu berücksichtigen, dass die Produktionslast größtenteils bereits in Niedrigpreis-Zeitfenstern liegt. Durch die Verbesserung der Prognosequalität und die Option der IntraDay-Bewirtschaftung können außerdem die Kosten für Prognoseabweichungen um 20 % reduziert werden. Der hier betrachtete Fall umfasst dabei eine Prozessdauer von 5 Minuten mit entsprechender Risikoprämie auf Seiten des Versorgers.

Die Risikoprämie ist dem Umstand geschuldet, dass sowohl der Kommunikationsprozess zwischen Versorger und Kunde als auch die Berechnung des geplanten Strombezugs eine gewisses Zeitintervall in Anspruch nehmen, während dessen sich die Preise an der IntraDay-Börse dynamisch ändern. Um den Kunden während der vereinbarten Haltedauer feste Preise zusagen zu können, ohne selbst systematisch ein hohes Verlustrisiko tragen zu müssen, sind daher seitens des Versorgers Risikoprämien festzulegen, die dann entsprechend auf die aktuellen IntraDay-Preise aufzuschlagen sind. Ausgehend von der Datenanalyse der IntraDay-Preise konnten Risikoprämien festgelegt werden, die sich an der Länge der Haltedauer und am vorherrschenden Preisniveau orientieren.

Da die Bewirtschaftung der kundenseitigen Flexibilitäten demzufolge maßgeblich von der Höhe der Risikoprämien mit beeinflusst wird, wurde im nächsten Schritt analysiert, wie stark sich die Risikoprämien auf die Wirtschaftlichkeit der Flexibilitätsnutzung auswirken. Den Extremfall stellt eine Variante dar, bei dem der Versorger über einen „digitalen Zwilling“ der energetischen Flexibilitäten verfügt und auf dessen Basis direkt am IntraDay-Markt agiert. Der Kunde bekommt dann nach erfolgter Bewirtschaftung den resultierenden Fahrplan verbindlich zugewiesen.





Abbildung 2.124: Energiewirtschaftliche Prozesse bei modell-basierter Flex-Vermarktung sowie Einfluss der Prozessdauer auf die Preisaufschläge für Prognoseabweichungen.

Die durchgeführten Simulationsanalysen zeigen bereits das grundsätzliche Potenzial dynamischer Tarife bzw. von Real Time Pricing auf. Insbesondere kann das im Rahmen des Projekts entwickelt Tool genutzt werden, um Analysen für konkrete Industrie- und Gewerbekunden zu erstellen. Dass die Nutzung energetischer Flexibilitäten zwar mit Implementierungsaufwand verbunden ist, aber dennoch hohes ökonomisches Potenzial bietet, demonstrieren die Spotpreise vom 26.06.2024 sehr deutlich. Entsprechende Lastanpassungen vorausgesetzt konnten allein an diesem Tag fünfstellige Beträge bei einzelnen Verbrauchern eingespart werden.




Abbildung 2.125: Preisspitzen am Spotmarkt infolge technischer Fehler an der EPEX.

Um auch die Übertragbarkeit der verschiedenen Liefer- und Bewirtschaftungsvarianten zu bewerten, wurde ein gemeinsamer Workshop mit dem IMS und CuroCon durchgeführt. Hierbei wurden die Varianten anhand von Kriterien wie Preisnachvollziehbarkeit, Komplexität, Fehleranfälligkeit, Anpassungsmöglichkeiten, technischer Aufwand, Einfluss auf Produktionsabläufe, Prognoseaufwand, organisatorischer Aufwand und Cybersecurity bewertet. Dies führte zu folgenden Einschätzungen:

- **Fixpreis** ist die einfachste und sicherste Variante mit minimalem Aufwand. Sie bietet hohe Preisnachvollziehbarkeit und geringe Fehleranfälligkeit, wenn auch kaum Flexibilität.
- **Fixpreis mit Online-Messung** erhöht den Aufwand leicht durch die Integration von Messsystemen und Kommunikationsprozessen, bietet aber zusätzliche Transparenz. Die Cybersecurity-Anforderungen steigen durch den Datentransfer.

- **Fixpreis mit Online-Messung und Eigenoptimierung** erfordert deutlich mehr Aufwand, bietet jedoch den Vorteil der gesteigerten Autonomie und Flexibilität. Der technische und organisatorische Aufwand ist hoch und muss entsprechend durch ökonomische Vorteile kompensiert werden.
- **Variabler Tarif mit Online-Messung und Eigenoptimierung** ist komplex und risikobehaftet, da er zusätzliche Schnittstellen erfordert. Der technische und organisatorische Aufwand ist sehr hoch, ebenso die Anforderungen an die Cybersecurity.
- **Vorfestlegung und kostenoptimierte Auswahl von Fahrplan-Optionen** ist die aufwendigste und am wenigsten flexible Variante. Dem Lieferanten müsste vorab mitgeteilt werden, welche Grenzkosten/-erlöse mit welcher Flex-Option verbunden wären, da dieser sonst nicht ziel-orientiert optimieren kann. Dies erfordert detaillierte Prognosen und Planungen, was den organisatorischen Aufwand immens erhöht.
- **Modell-basierte Flex-Vermarktung („digitaler Zwilling“)** bietet Flexibilität, erfordert jedoch einen hohen Implementierungsaufwand und birgt Risiken, da kritische Informationen die Unternehmensgrenzen verlassen. Die Komplexität und die Anforderungen an die Cybersecurity sind sehr hoch.

Zusammenfassung der Arbeiten je Partner

IMS (Leitung):

- Aufbau einer Simulationsumgebung zur Erzeugung intelligenter Betriebsstrategien für die Ladeinfrastruktur bei CuroCon
- Austausch mit CuroCon bzgl. der Anforderungen und Rahmenbedingungen des Lademanagements
- Auswahl und Analyse verschiedener Optimierungsansätze
- Implementierung und Verbesserung eines gemischt-ganzzahligen mathematischen Optimierungsmodells
- Bewertung der ausgewählten Optimierungsstrategien

Entega:

- Untersuchung von Verbrauchs- und Erzeugungsdatensätzen von CuroCon (Charakteristika des Lastverlaufs, Analyse von Einflussgrößen)
- Abstimmung mit PTW, etalytics und CuroCon zur Datenerfassung und -weitergabe. Abruf und Analyse von Live-Daten via etalytics-Plattform
- umfassende Sammlung, Aufbereitung und Analyse von Daten des DayAhead-Spot- und des IntraDay-Marktes sowie von Ausgleichsenergie-Preiszeitreihen
- Analyse von DayAhead- und IntraDay-Prognosezeitreihen (industrielle Verbraucher, PV-Anlagen)
- Analyse und Modellierung von Ladevorgängen eines betrieblichen Fuhrparks
- Konzeption und Implementierung von Simulationsmodellen zur Optimierung industrieller Flexibilitäten
- Umfassende Simulationsanalysen zur vergleichenden Bewertung verschiedener Bewirtschaftungskonzepte

- Durchführung eines gemeinsamen Workshops mit IMS und CuroCon zur Analyse und Bewertung verschiedener Bewirtschaftungskonzepte (Anwenderfreundlichkeit und Intuitivität) sowie den resultierenden Umsetzungsmöglichkeiten

2.7.6. Arbeitspaket 7.6: Untersuchung des Gesamtkonzepts in der ETA-Fabrik

Das Ziel dieses Arbeitspakets war es, die bislang separat entwickelten und erprobten Lösungen in einem Gesamtkonzept zu vereinen. Die Demonstration erfolgte in der ETA-Fabrik und soll eine möglichst einfache Übertragung der gezeigten Maßnahmen in die industrielle Praxis ermöglichen. Die Lösungen, die hierbei gemeinsam im Vordergrund standen und erprobt wurden, umfassen Weiterentwicklungen der in AP 4.1 und AP 4.2 präsentierten Prognoseframeworks, die in AP 5.2 erarbeitete Produktionsplanung sowie die Betriebsoptimierung der Versorgungstechnik in AP 5.3. Zusätzlich wurden weitere Projekthinhalte, wie beispielsweise das bidirektionale Laden (AP 6.3) oder der Leckageroboter (AP 3.2) direkt oder indirekt berücksichtigt.

Für die Verknüpfung der verschiedenen Arbeitspakete diente etaONE als zentrale Schnittstelle. Im Rahmen der gemeinsamen Anwendung wurde zunächst ein Produktionsplan erstellt, der auf dem von der ENTEGA AG kommunizierten Day-Ahead-Strompreis sowie den jeweiligen Produktionsaufträgen basierte. Parallel dazu erfolgte die Ausführung elektrischer Lastprognosen mithilfe der Prognoseframeworks aus AP 4.1 und AP 4.2. Als Prognoseziel wurde die elektrische Anschlussleistung für die kommenden 15 Minuten festgelegt, wobei eine zeitliche Auflösung von 10 Sekunden berücksichtigt wurde. Am Beispiel der EMAG VLC 100 GT wurden folgende Merkmale als besonders relevante Einflussfaktoren identifiziert:

- Elektrische Wirkleistung Kühlpumpe Maschinenkreislauf
- Elektrische Wirkleistung Kühlpumpe DC-Schaltschrank
- Elektrische Wirkleistung Hydraulikpumpe
- Elektrische Wirkleistung Absaugung
- Elektrische Wirkleistung Kühlschmierstoff-Aufbereitung
- Elektrische Wirkleistung ohne Antriebsaggregate
- Stellsignal Betrieb Kühlung
- Mechanische Drehzahl Hauptspindel (C1)
- Mechanische Drehzahl Innenspindel (SP3)
- Mechanische Drehzahl Außenspindel (SP3)
- Mechanische Geschwindigkeit Q1 Achse
- Mechanische Geschwindigkeit X1 Achse
- Mechanische Geschwindigkeit Z1 Achse

Das Prognoseframework wurde genutzt, um eine Modellpipeline anzutrainieren und als ONNX-Modell zu exportieren. Für den praktischen Einsatz in realen Produktionsumgebungen war es essenziell, die automatische Ausführung der ONNX-Modellpipeline sicherzustellen und eine nahtlose Anbindung an unterschiedliche Prozessebenen im Unternehmen zu ermöglichen. Zu diesem Zweck wurde im Rahmen des Projekts SynErgie (Förderkennzeichen: 03SFK3A0-3) ein Prognoseservice in der ETA-Fabrik entwickelt. Dieser Service führt die Prognosen automatisiert aus und stellt die Ergebnisse über einen Microservice zur weiteren Nutzung in beliebigen Systemen bereit.

Das auf Python basierende Framework zur Lastprognose gliedert sich in vier Hauptmodule: die Modellierung, die Anwendung und Veröffentlichung, die externe Bereitstellung sowie die Speicherung und Visualisierung auf einer IoT-Plattform (siehe Abbildung 2.126). Letztere speichert die Daten in Zeitserien, sodass basierend auf der prognostizierten und tatsächlich gemessenen elektrischen Leistung der EMAG VLC 100 GT ein Dashboard entwickelt wurde, das die Daten in Echtzeit visualisiert. Die ermittelten Lastprognosen sowie die Energiepreise dienen schließlich als Eingangsgrößen für die energieoptimierte Steuerung der Versorgungstechnik mittels DRL (AP 5.3).




Abbildung 2.126: ETA-Prognoseservice mit Anbindung an die IoT-Plattform etaONE.

Die Anwendung ausgewählter Ergebnisse wurde exemplarisch während der Abschlussitzung demonstriert (siehe Abbildung 2.127). Darüber hinaus wurden weitere Projektergebnisse in einem populärwissenschaftlichen Projektfilm [134] veröffentlicht, um eine breite gesellschaftliche Vermittlung der Erkenntnisse zu ermöglichen.



Abbildung 2.127: Präsentation des Leckageroboters (links) und der AR-Brille zur energetischen Transparenzschaffung (rechts) bei der Abschlussitzung.

Zusammenfassung der Arbeiten je Partner

PTW (Leitung):

- Implementierung und Bereitstellung des Prognoseservices
- Koordination der Teilergebnisse für die gemeinsame Erprobung
- Konzeption, Planung und Produktion des Abschlussfilms
- Planung, Koordination und Durchführung der Abschlusssitzung

DFKI:

- Das Leckage-Robotersystem wurde in das Energiemonitoring-Konzept der ETA-Fabrik eingebunden, sodass Erkenntnisse aus dem Robotereinsatz unmittelbar in die Optimierung der Druckluftversorgung und die Betriebsplanung einfließen können.
- Erste Testläufe belegten, dass häufig unbemerkte Luftverluste zügig erkannt und quantifiziert werden konnten. Dadurch ließen sich rasch Maßnahmen ableiten, mit denen die Leckverluste reduziert und die Energiekosten signifikant gesenkt werden konnten.
- Über eine Schnittstellenanbindung zur Energiemonitoring-Plattform lässt sich zudem ein Live-Monitoring der Energieflüsse (z. B. in Kühlwasserkreisläufen) per AR-Brille realisieren.

IMS:

- Einrichtung von OPC-UA Schnittstellen am hybriden Speichersystem und an der intelligenten Ladeinfrastruktur.
- Anbindung der relevanten Datenpunkte der Speichersysteme (HESS und Ladeinfrastruktur) an die etaONE-Plattform.

etalytics:

- Unterstützung bei der Verwendung der etaONE Plattform und regelmäßige Deployments von Updates und Verbesserungen
- Bereitstellen und Aufarbeiten von Dokumentation zur Nutzung der etaONE Plattform sowie der Python Bibliothek zur Kommunikation mit der etaONE API

Software AG:

- Inhaltliche Beteiligung am Kick-Off-Termin
- Die Software AG unterstützt die Projektpartner bei technischen Fragen, insbesondere im Zusammenhang mit ihrer IoT-Plattform Cumulocity.

2.7.7. Arbeitspaket 7.7: Übertragung der Projektergebnisse auf die Holz- und Prozessindustrie

Ziel des Arbeitspakets war es unter anderem Systeme zur Erfassung und Visualisierung des Ressourcenverbrauchs sowie zur Optimierung von Wärmenetzen zu schaffen. Die GreenDelta GmbH führte intensive Gespräche mit Experten von C.A.R.M.E.N. e.V., um die Ergebnisse aus dem Arbeitspaket 6.1.3 in der Praxis nutzbar zu machen. Obwohl großes Interesse an der Anwendung der Ergebnisse bestand, stellte sich die Rückintegration in die kommunale Wärmeversorgung als schwierig heraus. Der Einsatz von Müllheizkraftwerken mit geringer Kapazität scheiterte an rechtlichen und finanziellen Hürden. Zudem unterliegt die Verbrennung von kommunalem (Holz-)Abfall strengen Richtlinien, die

eine Umsetzung im kleinen Maßstab ausschließen. Daher wurde der Austausch mit der Entega AG forciert, um alternative Ansätze zu identifizieren. Im Fokus stand dabei industrielle Abwärme im kommunalen Kontext, wobei insbesondere das hohe Nutzungspotenzial der Abwärme aus der Holz- und Papierindustrie hervorgehoben wurde. Hierfür wurde das Bundesstelle für Energieeffizienz (BfEE) kontaktiert und die Integration der Daten der Abwärmeplattform in die Sophena-Software angestrebt. Der Zugang zur Abwärmeplattform wurde auf Anfang des nächsten Jahres verschoben. Es konnte nicht abschließend geklärt werden, in welchem Datenformat die Abwärmedaten in die Software integriert werden können. Die positiven Erfahrungen aus dem Arbeitspaket 6.1.3 sowie eine Studie des Bayerischen Landesamts für Umweltschutz, die CO₂- und Wärmeeinsparpotenziale von bis zu 10 % und ein theoretisches Maximum von 6,1 GWh/Monat für Abwärme aus der Papierindustrie aufzeigen, stimmen zuversichtlich.

Zusammenfassung der Arbeiten je Partner

atlan-tec:

- Aus dem Projekt ausgeschieden. Die Beiträge atlan-tecs zu KI4ETA sind in einem eigenen Schlussbericht festgehalten.

GreenDelta:

- Literaturrecherche zum Thema Abwärme im kommunalen Kontext
- Rückintegration der Ergebnisse in die kommunale Wärmeversorgung nach Expertengesprächen (C.A.R.M.E.N. e.V. und Entega AG) kompliziert
- Rechtliche und finanzielle Hindernisse für Müllheizkraftwerke mit geringer Kapazität
- Fokus auf industrielle Abwärme im kommunalen Kontext

3. Voraussichtlicher Nutzen der Arbeitsergebnisse

3.1. Teilprojekt 1: Smarte Energiemanagementplattform

Usability & Automatisierung:

- Plug & Work Funktionalität für Datenpunkte-Sets reduziert den Integrations- und Parametrierungsaufwand deutlich.
- Die ML-basierte Datenpunktidentifikation ermöglicht eine automatisierte Zuordnung von Messgrößen, Einheiten und Kontext – ohne Expertenwissen. Das entwickelte Python-Skript zur ML-basierten Datenpunktidentifikation steht den Cumulocity Consultants zur Verfügung, so dass in Zukunft die Anbindung von OPC-UA und Modbus Geräten an diese IoT-Plattform schneller erfolgen kann.

Technologische Grundlage & Datenintegration:

- Die Plattform stellt die technologische Basis für KI-gestützte Energiemanagement-Anwendungen dar und ermöglicht die Integration von KI-Optimierern, die z. B. durch Betriebsoptimierung signifikante Einsparungen ermöglichen.
- Standardisierte Schnittstellen (z. B. REST/JSON, OpenAPI) und modulare Microservices ermöglichen die flexible Einbindung innovativer KI-Algorithmen.
- Objektorientiertes Daten-Gateway vereinfacht die Anbindung über moderne Protokolle wie OPC UA, Modbus TCP und BACnet.
- Die Integration bestehender Informationsmodelle aus unterschiedlichen Systemen (z. B. Cumulocity, etaONE) ermöglicht plattformübergreifende Interoperabilität.

Effizienzsteigerung & Ressourcenschonung:

- Energiemanager werden bei der Auswertung großer Datenmengen entlastet, sodass mehr Zeit für die eigentliche Optimierung verbleibt.
- Die Plattform ermöglicht automatisierte Vorverarbeitung (z. B. Integration, Ableitung, Plausibilitätsprüfung) von Zeitreihendaten.
- Die Einführung von Retention Policies sorgt für effiziente Langzeitspeicherung und Löschung von Alt-Daten.

Skalierbarkeit & Zukunftssicherheit:

- Containerisierte Architektur (z. B. Kubernetes) erlaubt skalierbare Ausführung von Data Analytics und ML-Skripten.
- Die Plattform ist sowohl für Brownfield- als auch Greenfield-Szenarien geeignet.
- Durch Nutzung von Open-Source Technologien bleibt das System kosteneffizient und flexibel erweiterbar.
- Mit Cross-Plattform-Kommunikation kann die Lösung nahtlos mit bestehenden Energiemanagementsystemen verbunden werden.

Visualisierung & Analysefähigkeit:

- Die grafischen Benutzeroberflächen ermöglichen eine intuitive Modellierung komplexer Energiesysteme mit Echtzeitdatenintegration.
- Dynamische Darstellungen (z. B. Verbindungsgeschwindigkeiten, Farbanpassungen) verbessern das Verständnis von Systemzuständen.
- Die semantische Strukturierung erlaubt eine zielgerichtete Analyse vernetzter Energiesysteme, auch in heterogenen IT-Umgebungen.

3.2. Teilprojekt 2: Vernetzung & Sicherheit

Mess- und Kommunikationsinfrastruktur:

- Es wurde eine kosteneffiziente und flexible Anbindung weiterer Produktionsanlagen erreicht, indem Plug and Play Konzepte umgesetzt und vereinfachte Schnittstellen entwickelt wurden.
- Durch den Einsatz moderner Kommunikationslösungen konnte die Erfassung und Echtzeitübertragung von Messdaten zwischen Maschinen, Edge Devices und zentralen Managementplattformen (z. B. via OPC UA) deutlich verbessert werden.
- Hochauflösende Energiemessungen wurden implementiert, welche die Detektion von Stromspitzen optimieren und zur weiteren Forschung genutzt werden können.
- Die aufgebauten Messstrecken bieten eine solide Basis, um in zukünftigen Untersuchungen weitere Daten zu erfassen und auszuwerten.
- Der rückwirkungsfreie Eingriff in industrielle Bussysteme mittels Ethernet-TAP wird auf weitere Sektoren in der Fertigung übertragen (z. B. HSMS, ein Protokoll für die Kommunikation zwischen Maschine und Fertigungsleitsystem im Bereich Semiconductor). Ein schneller Zugang zu Daten und damit Übertrag der Analysemethoden sind möglich.

IT-Security:

- Es wurden Sicherheitskonzepte entwickelt und implementiert, die eine sichere Einbindung zahlreicher Geräte in die IKT-Infrastruktur gewährleisten.
- Die sicherheitstechnische Beurteilung der Energiemanagement-Plattform bildet die Grundlage für künftige Weiterentwicklungen und Optimierungen dieser Plattform.
- IT-Security-Maßnahmen wurden in realen Produktionsumgebungen der ETA erprobt und validiert, um Schwachstellen dort frühzeitig zu identifizieren und zu beheben.

Sicherheitsbeurteilung von KI-Systemen:

- Es wurden Bewertungsansätze zur Zuverlässigkeit selbstlernender, KI-basierter Systeme im industriellen Einsatz entwickelt.
- Die Validierung von KI-Anwendungen in realen Produktionsszenarien belegt nachvollziehbar deren betrieblichen Nutzen sowie die Sicherheitsaspekte der Systeme.
- Zudem wurde der Weg für zukünftige normative Bewertungen und Zertifizierungsansätze im Bereich KI und Sicherheit vorbereitet.

3.3. Teilprojekt 3: Energetische Transparenzschaffung & Monitoring

Modellierungsmethoden zur Abbildung komplexer Anlagensysteme und dynamischer Zusammenhänge

- Demonstration ML-basierter Ansätze zur Modellierung nicht messbarer sowie zustandsabhängiger Einflüsse
- Entwicklung eines aufeinander aufbauenden Prozesses, der Parametrierungsmodelle und Modellergebnisse in die Konfigurationen eines Datenmodells zur Betriebsoptimierung überführen kann

Abbildung von Datenstrukturen als Grundlage für Kennzahlensysteme und Betriebsoptimierungen

- Abbildung von Restriktionen, Grenzen, Zusammenhängen in Datenstrukturen für Kennzahlensysteme
- Nutzung von Modellen und Datenstrukturen zur Betriebsoptimierung in einem definierten kontinuierlichen Betrieb

Entwicklung von selbstlernenden Algorithmen zur KI-gestützten Messdatenauswertung

- Die entwickelten Algorithmen stehen den Cumulocity-Consultants für zukünftige Projekte zur Verfügung und werden die Implementierung und Anpassung ähnlicher Problemstellungen erheblich vereinfachen. Die UI-Komponenten (Dashboards) können dabei als gute Ausgangsbeispiele für die Implementierung und die Diskussionen mit Kunden dienen
- Das erreichte Ziel der zeitsynchronen Datenerfassung (Beobachtbarkeit) ist eine grundlegende Basis für die Optimierung von industriellen Fertigungsprozessen. Die Erweiterung der Messdaten (Zeitreihen) um Zustände und diskrete Ereignisse ermöglicht eine umfassende Optimierung, die nun wesentlich durch Methoden der KI im Arbeitsaufwand reduziert wird.

3.4. Teilprojekt 4: Datenbasierte Modellerstellung, -parametrierung & Auswertung

Sensitivitätsanalyse und Parameteridentifikation:

- Entwicklung einer Methode zur automatisierten Parametrierung komplexer Simulationsmodelle, basierend auf vorgelagerter Sensitivitätsanalyse.
- Zielgerichtete Reduktion der Parameteranzahl durch Identifikation einflussreicher Modellgrößen.
- Validierung am Beispiel einer PHI-Factory-Simulation mit deutlicher Fehlerreduktion nach Parameteridentifikation.
- Übertragung auf das Modell der thermischen Versorgungstechnik der ETA-Fabrik mit teils widersprüchlichen Ergebnissen hinsichtlich Parameterrelevanz und Modellgüte.
- Erkenntnis: Manuelle Parameterauswahl war teils effektiver als die automatisierte Variante; Hinweise auf zu enge Parametervariationsgrenzen ($\pm 20\%$).
- Empfehlung: Einsatz dynamischer, adaptiver Grenzwerte für künftige Anwendungen zur Verbesserung der Identifikationsgenauigkeit.
- Fazit: Die entwickelte Methodik bildet eine robuste Grundlage für die automatische Parametrierung und bietet Potenzial für eine effiziente Weiterentwicklung.

Vorschlagswesen für Energieeffizienzmaßnahmen

- Entwicklung eines übergreifenden Konzepts zur systematischen Erstellung von Expertensystemen zur Identifikation von Energieeffizienzmaßnahmen.
- Unterstützung von Entscheidungsträgern durch strukturierte, regelbasierte Ableitung geeigneter Maßnahmen.
- Umsetzung in mehreren exemplarischen Anwendungsfällen mit nachgewiesenen Energieeinsparungen.
- Der Nutzen liegt somit in einer Entscheidungsunterstützung bei der Auswahl und Priorisierung von Effizienzmaßnahmen und der systematische Wissensstrukturierung und -speicherung als Grundlage für zukünftige Anwendungen.
- Das Konzept wurde für mehrere Anwendungsfälle exemplarisch implementiert und erfolgreich mit Nachweis von Energieeinsparungen getestet
- Perspektivisch soll eine Verallgemeinerung des Konzepts für breitere industrielle Anwendungen in einer geplanten Dissertation münden.

Condition Monitoring und Predictive Maintenance

- Entwicklung und Umsetzung eines KI-basierten Systems zur Anomalieerkennung in der Produktion hochfrequent hergestellter Produkte.
- Effizientes Datenlabeling im laufenden Produktionsprozess sowie Aufbau einer skalierbaren Datenpipeline zur Echtzeitanalyse.
- Integration eines nutzerfreundlichen Interfaces zur Visualisierung von Prozessdaten und automatisierter Anomalie-Bewertung direkt an der Maschine.
- Erfolgreiche Validierung des Systems mit nachweisbarer Übertragbarkeit auf andere Maschinen mittels Transfer Learning.
- Nachweisbares Einsparpotenzial: Bis zu 791 MWh Energie- und 300,58 t CO₂-Einsparung jährlich bei flächendeckendem Einsatz in der EJOT-Produktion.
- Strategisches Ziel: Skalierung und Roll-out des Systems auf weitere Fertigungsbereiche und Produktlinien (u. a. im Halbleiterbereich).

3.5. Teilprojekt 5: Ganzheitliche Betriebsstrategieoptimierung

Energieoptimierte Produktionsplanung:

- Durch die Entwicklung der EAPS (Energy-Aware Production Scheduling)-Methode im Projekt konnte in der Forschungsgruppe ETA ein neues Forschungsfeld etabliert werden. Die Dissertation von Benedikt Grosch [104] bildet dabei den Grundbaustein. Hiermit konnten im Projekt Effizienzpotenziale demonstriert und bei Anwendungspartnern sowie in der ETA-Fabrik validiert werden.
- Die Arbeiten zur energieoptimierten Produktionsplanung sind eine entscheidende Grundlage für den Projektantrag ENIPRO, der als Folgeprojekt zu KI4ETA das Forschungsfeld energiebewusste Produktionsplanung weiterentwickelt.

Energieoptimierte Versorgungstechnik:

- Energieoptimierte Versorgungstechnik kann einen wesentlichen Beitrag zur Wettbewerbsfähigkeit produzierender Unternehmen leisten und zudem den spezifischen Energieverbrauch senken, ohne, dass größere Umbaumaßnahmen am Versorgungssystem notwendig sind.
- In KI4ETA konnte erstmals die Regelung eines komplexen thermischen Versorgungssystems durch Deep Reinforcement Learning umgesetzt werden. Dabei wurde in zwei von drei Versuchen über 24 Stunden ein stabiler Betrieb erreicht, wobei auch beim nicht erfolgreichen Versuch keine Gefahr für das Versorgungssystem bestand, da dieses beim Überschreiten festgelegter Grenzwerte in den konventionellen Betrieb zurückkehrte.
- Diese praktische Anwendung war auch unter dem Aspekt von Mehrwert, da Realversuche notwendig sind, um die nachvollziehbaren Vorbehalte aus der Industrie abzubauen und verbleibende Schwächen aufzudecken, die in reinen Simulationsstudien nicht ersichtlich wären.
- Es konnte eine geeignete Kombination aus DRL-Algorithmen, Hyperparametern und Topologien neuronaler Netze identifiziert werden.
- Durch die Entwicklung von eta-utility ließ sich der Aufwand bei der Erstellung von Experimenten mit Simulationen und – vor allem – Realsystemen zudem deutlich reduzieren. Das Framework wurde im Rahmen des Projekts veröffentlicht und ist frei verwendbar.
- Hinsichtlich des hybriden kinetisch-elektrochemischen Speichers liegen die größten Mehrwerte im Nachweis deutlich reduzierter Lastspitzen und damit verbundener finanzieller Vorteile. Beim Einsatz von erneuerbarer Energie, wie Photovoltaik, kann zudem ein deutlicher ökologischer Vorteil verzeichnet werden. Besonders die mathematische Optimierung hat gezeigt, wie gezielt, mithilfe eines entsprechenden Forecasts, die Leistungsspitzen abgefangen werden können.

Übergreifende Optimierung:

- Es wurde ein Versuch für die Kombination von energieoptimierter Produktionsplanung und der DRL-basierten Betriebsoptimierung der Versorgungstechnik durchgeführt.
- Dabei wird in einem kaskadierten Vorgehen zunächst ein optimierter Produktionsplan erstellt und die sich ergebenden Energiebedarfe ermittelt, welche hierdurch perspektivisch von der Versorgungstechnik gedeckt werden müssen.
- In KI4ETA konnte dieses Vorgehen prototypisch an einem realen Produktionstag erprobt werden, was zu einer bedarfsgerechteren Energiebereitstellung führte.
- Hierbei kam es zu Abweichungen vom vorgesehenen Produktionsplan. Zudem wurden die Prognosen nur in diskreten Werten an die Optimierung der Versorgungstechnik übergeben. Beide Aspekte sollten in nachfolgenden Projekten tiefergehender untersucht werden. Der Realversuch in KI4ETA liefert jedoch bereits einen Mehrwert hinsichtlich der Erprobung der notwendigen Anbindungen und verbleibenden Probleme.
- Bei der Erprobung der trainierten Agenten für den hybriden Speicher in der Fabrik zeigte sich, dass beide Speicher präzise auf die Ansteuerung durch eta-utility reagieren, wobei der Batteriespeicher noch etwas exakter als der Schwungmassenspeicher arbeitet. Dadurch erfolgte der Nachweis der Steuerbarkeit hybrider Speicher durch KI-gestützte Agenten als Grundlage für eine flexible, bedarfsorientierte Energiebereitstellung und die netzdienliche Integration dezentraler Speicher.

3.6. Teilprojekt 6: Sektorenkopplung

Parametrierung und Wärmepricing industrieller Wärmenetze:

- Erfolgreiche Erweiterung der kommunalen Wärmeplanungssoftware Sophena für den industriellen Anwendungsfall MHKW Mannheim, inklusive Modellierung von Dampferzeugung und Stromproduktion.
- Durchführung von Workshops zur Datenabstimmung und Anpassung der Software an die spezifische Infrastruktur eines industriellen Wärmenetzes.
- Integration der Erfahrungen aus KI4ETA zur Abbildung komplexer Energieströme in industriellen Prozessen.
- Nutzen: Ermöglicht eine realitätsnahe energetische Bewertung industrieller Wärmenetze, unterstützt sektorübergreifende Planung und erweitert den Anwendungsbereich einer open-source Softwarelösung.
- Veröffentlichung der Softwareerweiterung ist im Rahmen eines kommenden Updates geplant

Bidirektionale Ladeinfrastruktur an der ETA-Fabrik

- Die bidirektionale Ladesäule an der ETA-Fabrik stellt eine hervorragende Grundlage für weiterführende Untersuchungen hinsichtlich der Sektorenkopplung. Sie erlaubt die Integration der Ladevorgänge von Elektrofahrzeugen in das Energiesystem der ETA-Fabrik.
- Die Ladeinfrastruktur erlaubt die Erprobung ganzheitlicher Betriebsstrategien für das gesamte Speichersystem an der ETA (KESS + BESS + EV): Hier kann das Elektrofahrzeug zu einem Teil eines „virtuellen“ Speichers werden, welcher alle Speichertypen umfasst.
- Für die unidirektionale AC-Ladeinfrastruktur wurde eine Sollwertvorgabe der Ladeleistung umgesetzt. Somit kann zukünftig nicht nur der Ladevorgang unterbrochen und später fortgesetzt werden, sondern auch die Ladeleistung variabel eingestellt werden.
- Sowohl die bidirektionale DC-Ladeinfrastruktur als auch die unidirektionale AC-Ladeinfrastruktur kann nun per OPC-UA überwacht und angesteuert werden. Dies erleichtert zukünftig die Einbindung der Systeme in Betriebsstrategien – zentral oder dezentral
- Das User-Interface der Ladesäule wurde überarbeitet, um Messdaten intuitiver darzustellen und die Interaktion mit dem System zu erleichtern. Dadurch kann in weiterführenden Arbeiten die Nutzerinteraktion – insbesondere beim bidirektionalen Laden – verbessert werden.
- Mithilfe des Elektrofahrzeugs ist es möglich, flexibel Versuche an der Ladesäule durchzuführen. Insbesondere das Verhalten der Batterie ist davon von großem Interesse, welches nun genauer untersucht werden kann. Ein wichtiger Aspekt ist dabei die langfristige Batteriealterung. Ebenso können nun hardwarenahe Untersuchungen an der gesamten Ladeinfrastruktur unternommen werden. Dazu gehört die Bestimmung von Wirkungsgraden und der Dynamik des Systems
- Durch den Daten-Logger im Elektrofahrzeug können sowohl Daten des Energiesystems als auch Fahrdaten aufgezeichnet werden. Dies ermöglicht Einblicke in das Verhalten des Fahrzeugs während der Fahrt und stellt eine hervorragende Basis für datenbasierte Methoden dar, die z. B. zur Erstellung von synthetischen Nutzungsprofilen verwendet werden können.
- Mit DRL konnte eine Betriebsstrategie für Lastspitzenglättung entwickelt werden. Das dabei erlangte Systemverständnis – sowohl für die Infrastruktur als auch für DRL – kann nun weiterentwickelt werden zu Anwendungen mit größerer Komplexität.

Schnittstellen für die Umsetzung von Real Time Pricing in der Produktion

- Sowohl auf Seiten von ENTEGA/citiworks als auch von etalytics wurden zuverlässig funktionierende Schnittstellen implementiert, um Preisinformationen von den Strommärkten zu übertragen und in der etaONE-Plattform zur Verfügung zu stellen. Ergänzend werden auch Daten zur CO₂-Intensität des Strommixes übertragen. Diese Schnittstellen können somit als Ansatzpunkt für Folgeprojekte und -anwendungen genutzt werden.
- Die entwickelten Tools zur detaillierten Analyse von Preisvolatilitäten usw. können genutzt werden, um z. B. Risikoprämien für Real Time Pricing-Modelle zu ermitteln.
- Die preis-orientierte Steuerung einer Anlage in der ETA-Fabrik unter Einbindung der etaONE-Plattform ist ein wichtiger Proof-of-concept für potenzielle Folgeaktivitäten bei Industrie-/Gewerbekunden.

3.7. Teilprojekt 7: Anwendung, Bewertung & Übertragbarkeit

- Das erarbeitete Konzept für die synchrone Datenerfassung (Zeitreihen, Prozesskurven, Zustandserfassung) ist wesentlich und ermöglicht den erfolgreichen Übertrag in andere Fertigungsfelder (Semiconductor, etc.)
- Die Nutzung von hybriden Modellen (Daten- und wissensbasierter Ansatz) zur Beschreibung von Ursache-Wirkbeziehungen wird auf Grund des generischen Ansatzes weiter bei Bosch genutzt.

Holz- und Prozessindustrie:

- Zielgerichtete Übertragung der KI4ETA-Ergebnisse auf den kommunalen Kontext, insbesondere zur Nutzung von industrieller Abwärme durch kommunale Wärmenetze.
- Rechtliche und wirtschaftliche Einschränkungen verhinderten eine direkte Umsetzung kleinerer Müllheizkraftwerke, sodass alternative Ansätze im Bereich industrieller Abwärme verfolgt wurden.
- Hervorhebung des hohen Potenzials industrieller Abwärme, insbesondere aus der Papierindustrie, mit möglichen Einsparungen von bis zu 6,1 GWh/Monat.
- Anbahnung einer technischen Anbindung zwischen der Abwärmeplattform der Bundesstelle für Energieeffizienz (BfEE) und der open-source Wärmeplanungssoftware Sophena zur Erschließung neuer Anwendungsfelder.
- Die Arbeiten bilden eine Grundlage für die erweiterte Nutzung industrieller Abwärme in kommunalen Wärmenetzen und fördern sektorübergreifende Synergien in der Wärmeplanung.

Sektorenkopplung:

- Durch die Untersuchung verschiedener Optimierungsansätze für das Lademanagement bei CuroCon konnten wichtige Einblicke in die Vor- und Nachteile der einzelnen Algorithmen gesammelt werden. Obwohl bereits bekannt war, dass sich MILP für die Simulation von Energiesystemen gut eignet, konnte in diesem Arbeitspaket ein Vergleich zu anderen Optimierungsansätzen gezogen werden, der die Eignung von MILP stark unterstreichen konnte.
- Durch die Anwendungsnähe konnten die tatsächlichen Nutzer der Ladeinfrastruktur in die Konzipierung des Managementsystems miteinbezogen werden. Dadurch konnten Methoden entwickelt werden, mit denen eine Individualisierung der Betriebsstrategie möglich wird.
- Durch das gleichzeitige Laden von mehreren Elektrofahrzeugen wird die Komplexität des Systems zwar erhöht, allerdings ergeben sich dadurch auch weitere Freiheitsgrade, da die Energieverteilung auf die einzelnen Fahrzeuge ebenfalls optimiert werden kann. Insbesondere

im Hinblick auf die Batteriealterung ergeben sich hiermit auch langfristige Verbesserungspotenziale.

- Das entwickelte Simulationstool berücksichtigt die Kombination von industriellen Lasten mit Photovoltaik-Erzeugung, Batteriespeichern und Ladestationen. Anhand des Tools können Simulationsanalysen für konkrete Industrie- und Gewerbekunden erstellt werden, um die Chancen und Risiken von dynamischen Tarifen aufzuzeigen.

4. Veröffentlichungen und Teilnahme an Tagungen, Messen o.Ä.

4.1. Wissenschaftliche Veröffentlichungen

- Dietrich, B.; Walther, J.; Chen, Y.; Weigold, M. (2021): A Deep Learning Approach to Electric Load Forecasting of Machine Tools. In: MM SJ 2021 (5), S. 5283–5290. DOI: 10.17973/MMSJ.2021_11_2021146.
- Fuhrländer-Völker, D.; Borst, F.; Theisinger, L.; Ranzau, H.; Weigold, M. (2022): Modular Data Model for Energy-Flexible Cyber-Physical Production Systems. In: Procedia CIRP, 107, S. 215–220, Elsevier B.V., ISSN 2212-8271. DOI: 10.1016/j.procir.2022.04.036.
- Grosch, B.; Fuhrländer-Völker, D.; Stock, J.; Weigold, M. (2022): Cyber-Physical Production System for Energy-Flexible Control of Production Machines. In: Procedia CIRP, 107, S. 221–226, Elsevier B.V., ISSN 2212-8271. DOI: 10.1016/j.procir.2022.04.037.
- Ioshchikhes, B.; Borst, F.; Weigold, M. (2022): Assessing Energy Efficiency Measures for Hydraulic Systems using a Digital Twin. In: Procedia CIRP, 107, S. 1232–1237. DOI: 10.1016/j.procir.2022.05.137.
- Mehmed, I.; Wincierz, C.; Ioshchikhes, B.; Weigold, M. (2022): Entwicklung eines Vorschlagswesens für die Auswahl energieeffizienzsteigernder Betriebsstoffe. In: Reibung, Schmierung und Verschleiß. Forschung und praktische Anwendungen: 63. Tribologie-Fachtagung 2022, 26. bis 28. September 2022 in Göttingen. Gesellschaft für Tribologie. Aachen: GfT Gesellschaft für Tribologie e.V, S. 89–103.
- Walther, J. (2022): Hierarchical Electrical Load Forecasting of Industrial Production Systems in the Manufacturing Industry based on Deep Learning. Dissertation. Technische Universität Darmstadt.
- Walther, J.; Dietrich, B.; Grosch, B.; Lindner, M.; Fuhrländer-Völker, D.; Strobel, N.; Weigold, M. (2022): A Methodology for the Classification and Characterisation of Industrial Demand-Side Integration Measures. In: Energies 15 (3), S. 923. DOI: 10.3390/en15030923.
- Fuhrländer-Völker, D.; Grosch, B.; Weigold, M. (2023): Modelling and Control of Aqueous Parts Cleaning Machines for Demand Response. In: Proceedings of the Conference on Production Systems and Logistics: CPSL 2023, S. 790–800.
- Fuhrländer-Völker, D.; Magin, J.; Weigold, M. (2023): Automation Architecture for Harnessing the Demand Response Potential of Aqueous Parts Cleaning Machines. In: Production Engineering, 17 (6), S. 785–803. DOI: 10.1007/s11740-023-01201-x.
- Ioshchikhes, B.; Elserafi, G.; Weigold, M. (2023): An Expert System-Based Approach for Improving Energy Efficiency of Chamber Cleaning Machines. Hannover: publish-Ing.
- Ioshchikhes, B.; Piendl, D.; Schmitz, H.; Heiland, J.; Weigold, M. (2023): Development of a Holistic Framework for Identifying Energy Efficiency Potentials of Production Machines. In: Manufacturing Driving Circular Economy, Lecture Notes in Mechanical Engineering, Springer International Publishing, S. 431–439.
- Sossenheimer, J. (2023): Hybrides Energiemessstellenkonzept zum ganzheitlichen Energiemonitoring von Fertigungsmaschinen und Komponenten. Dissertation. TU-Darmstadt, Shaker Verlag.
- Stobert, A.; Ioshchikhes, B.; Weigold, M. (2023): Machine Learning-Based Identification and Prioritization of Electrical Consumers for Energy Monitoring. In: MM SJ 2023 (4). DOI: 10.17973/MMSJ.2023_11_2023123.

- Frank, M.; Borst, F.; Theisinger, L.; Lademann, T.; Fuhrländer-Völker, D.; Weigold, M. (2024): Framework for Implementation of Building Automation Control Programs for Industrial Heating and Cooling Systems. In: *Energies* 17 (21), S. 5361. DOI: 10.3390/en17215361.
- Ioshchikhes, B.; Frank, M.; Elserafi, G.; Magin, J.; Weigold, M. (2024): Developing Expert Systems for Improving Energy Efficiency in Manufacturing: A Case Study on Parts Cleaning. In: *Energies* 17 (14), S. 3417. DOI: 10.3390/en17143417.
- Ioshchikhes, B.; Frank, M.; Weigold, M. (2024): A Systematic Review of Expert Systems for Improving Energy Efficiency in the Manufacturing Industry. In: *Energies* 17 (19), S. 4780. DOI: 10.3390/en17194780.
- Ioshchikhes, B.; Weigold, M. (2024): Development of Stationary Expert Systems for Improving Energy Efficiency in Manufacturing. In: *Procedia CIRP*, 126, S. 921-926, Elsevier B.V. DOI: 10.1016/j.procir.2024.08.351.
- Klostermeier, M.; Kunz, L.; Motsch, W.; Ioshchikhes, B.; Plociennik, C.; Ruskowski, M. (2024): Energy Load Profile Analysis and Application for Production Simulation and Scheduling using Energy Load Disaggregation. In: *INFORMATIK 2024*, S. 1079–1097.
- Richard, P.; Dudhagara, S. U.; Kunz, L.; Plociennik, C.; Ruskowski, M. (2024): Autonomous Mobile Robot Search Strategy for Automated Compressed Air Leakage Detection. In: *INFORMATIK 2024*, S. 1099–1111.
- Borst, F.; Frank, Frank, M.; Theisinger, L.; Weigold, M. (2024): Managing complexity in industrial heating and cooling systems: a local energy market framework for transactive control with technical constraints. In: *New insights into Smart Energy Systems : book of abstracts*, S. 123-124, Aalborg, Aalborg Universitet, 10th International Conference on Smart Energy Systems, Aalborg, 10.09.2024 - 11.09.2024.
- Frank, M.; Borst, F.; Theisinger, L.; Weigold, M. (2024): Algorithm-supported operation and investment planning of decentralized energy infrastructure at production sites. In: *New insights into Smart Energy Systems : book of abstracts*, S. 53-54, Aalborg, Aalborg Universitet, 10th International Conference on Smart Energy Systems, Aalborg, 10.09.2024 - 11.09.2024.
- Farhad, A.; Abuibaid, K.; Plociennik, C.; Ruskowski, M. (2025): Generative Grasp Detection and Estimation with Concept Learning-Based Safety Criteria. In: *14. IFAC Symposium of Dynamics and Control of Process Systems*.
- Franzelin, T.; Schwarz, S.; Rinderknecht, S. (2025): Smart Charging and V2G: Enhancing a Hybrid Energy Storage System with Intelligent and Bidirectional EV Charging. In: *World Electric Vehicle Journal* 16 (3). DOI: 10.3390/wevj16030121.
- Ioshchikhes, B.; Heller, P.; Weigold, M. (2025): Machining Cycle Detection-Based Expert System for Improving Energy Efficiency in Manufacturing. In: *Lecture Notes in Mechanical Engineering*.
- Ioshchikhes, B.; Zink, R.; Ozen, O.; Weigold, M. (2025): A Holistic Framework for Developing Expert Systems to Improve Energy Efficiency in Manufacturing. In: *Energies* 18, 1406. DOI: 10.3390/en18061406.
- Walunj, S.; Plociennik, C.; Ruskowski, M. (2025): Context-Sensitive Worker Assistance System using Semantic Zoom in AR. In: *Conference on Cognitive and Computational Aspects of Situation Management (CogSIMA)*.

4.2. Teilnahme an Tagungen, Messen o.Ä.

- High Speed Machining Conference 2021, Darmstadt (Konferenzbeitrag, TU Darmstadt)
- The smarter E Europe Restart 2021, München (Messebesuch durch IMS, TU Darmstadt)
- Besuch der Hannovermesse, Hannover (Besuch des OPC-Foundation Standes zur Information bzgl. OPC UA FX, um den TSN-Usecase in TP 2 voranzutreiben)
- Besuch der hub.berlin, Berlin (Teilnahme an Vorträgen über aktuelle Trends bzgl. Datenspeicherung, Diskussion und Vernetzung mit Kollegen, Herstellen neuer Kontakte)
- CIRP CMS 2022, Lugano, Schweiz (Präsentation von drei wissenschaftlichen Veröffentlichungen mit je einem Vortrag)
- Tribologie-Fachtagung 2022, Aachen (Vortrag: "Entwicklung eines Vorschlagswesens für die Auswahl energieeffizienzsteigernder Betriebsstoffe")
- 11th DACH+ Conference on Energy Informatics 2022, Freiburg im Breisgau (Vorstellung des rollierenden Optimierungsframeworks eta_utility)
- Inria-DFKI European Summer School on Artificial Intelligence 2022, Saarbrücken (Postervorstellung zum Arbeitsinhalt von AP 3.2)
- Conference on Production Systems and Logistics (CPSL) 2023, Querétaro, Mexiko (Präsentation von zwei wissenschaftlichen Veröffentlichungen aus KI4ETA)
- 17th International Conference on High Speed Machining, Nanjing, China (Papervorstellung: "Machine Learning-based Identification and Prioritization of Electrical Consumers for Energy Monitoring")
- Hessenmetall Energieeffizienzkongress 2023, Darmstadt (Vortrag: "Transformation zu Klimaneutralität – Von der Strategie zur Umsetzung")
- Jahreskongress der Wissenschaftlichen Gesellschaft für Produktionstechnik 2023, Freudenstadt (Teilnahme)
- 19th Global Conference on Sustainable Manufacturing, Buenos Aires, Argentinien (Papervorstellung: "Optimizing GHG-Emissions in Milling by Integrating Electricity Mix Data into Manufacturing Parameter Decisions" und "Machining Cycle Detection-Based Expert System for Improving Energy Efficiency in Manufacturing")
- ABB Energy Efficiency Symposium for Academia 2023 (Poster-Vorstellung des Leakage-Use-Cases)
- 5. Workshop zur Künstlichen Intelligenz in der Umweltinformatik 2024, Wiesbaden (Präsentation von zwei Veröffentlichungen aus KI4ETA)
- Hannover Messe 2024 (Vorstellung des Projektes auf dem Stand der Smartfactory am 22.04.2024)
- Fokus Technik der Smartfactory KL (Vorstellung des Arbeitsinhaltes von AP2.4 auf YouTube, Veröffentlicht am 19.09.2024)
- Innovationstag der Smartfactory 2024, Kaiserslautern (Vorstellung des Arbeitsinhaltes von AP2.4 am 10.09.2024)
- Workshop Standardization Community Map der All Electric Society (Vortrag zum Thema "Flexibilitäten" am 06.06.2024)
- Die CO₂-Neutrale Fabrik, Würzburg (Teilnahme: Tobias Lademann, PTW Darmstadt, 15. & 16.05.2024)
- Bitkom-Konferenz Transform 2024, Berlin (Teilnahme: Dr. Gerald Ristow, SAG, 6. & 7. März 2024)

- UNITI Mineralöl-Technologie-Forum 2024, Stuttgart (Vortrag: "Effiziente und nachhaltige Industrieschmierstoffe" von Dr. Christoph Wincierz, Evonik, 17.04.2024)
- Conference on Smart Energy Systems 2024, Aalborg (Teilnahme)
- GCSM 2024, Ho Chi Minh City / Binh Duong, Vietnam (09.10. – 11.10.2024)
- Internationale Conference on Tribology and Sustainable Lubrication (NEXTLUB) 2025, Düsseldorf (Präsentation: "Development of a Holistic Framework for Identifying Energy Efficiency Potentials of Production Machines")

4.3. Dissertationen

- Walter, Jessica (2022): Hierarchical Electrical Load Forecasting of Industrial Production System in the Manufacturing Industry based on Deep Learning. Dissertation. Darmstadt, Technische Universität Darmstadt. DOI: 10.26083/tuprints-00021767.
- Sossenheimer, Johannes (2023): Hybrides Energiemessstellenkonzept zum ganzheitlichen Energiemonitoring von Fertigungsmaschinen und Komponenten. Shaker-Verlag, Dissertation. TU-Darmstadt, Darmstadt.
- Fuhrländer-Völker, Daniel (2023): Automation Architecture for Demand Response on Aqueous Parts Cleaning Machines. Dissertation. Darmstadt, Technische Universität Darmstadt.
- Grosch, Benedikt (2024): Simplified implementation of energy-aware production scheduling in job shops. Shaker Verlag, Dissertation. TU-Darmstadt, Darmstadt.

5. Abkürzungsverzeichnis

Abkürzung	Beschreibung
AC	Alternating Current
ALF	Automated Leakage Finder
AMR	Autonomer mobiler Roboter
API	Application Programming Interfaces
AP	Arbeitspaket
AR	Augmented Reality
BESS	Battery Energy Storage System
BfEE	Bundesstelle für Energieeffizienz
BMWK	Bundesministerium für Wirtschaft und Klimaschutz
CAM	Computer Aided Machining
CCS	Combined Charging System
CNN	Convolutional Neuronal Networks
DC	Direct Current
DIRMO	Direct Multi-Input Multi-Output
DRL	Deep Reinforcement Learning
EAPS	Energy-Aware Production Scheduling
FEM	Finite-Elemente-Methode
FMU	Functional Mock-up Unit
GRU	Gated Recurrent Units
HESS	Hybride Energiespeichersystem
IKT	Informations- und Kommunikationstechnik
IM	Informationsmodell
IoT	Internet of Things
KESS	Kinetic Energy Storage System
KI	Künstliche Intelligenz
KMU	Kleine und mittelständische Unternehmen
LiDAR	Light Detection and Ranging
LLM	Large Language Model
LSTM	Long-Shortterm-Memory
MAD	Median Absolute Deviation
MAE	Mean Absolute Error
MDZ	Mittelstand Digital Zentrum
MHKW	Müllheizkraftwerk
MILP	Mixed Integer Linear Programming
MSE	Mean Squared Error
NAS	Neural Architecture Search
NN	Neuronales Netz
PoC	Proof of Concept
PPO	Proximal Policy Optimization
RAG	Retrieval Augmented Generation
RL	Reinforcement Learning
ROS	Robot Operating System

SoC	State of Charge
TAP	Test Access Point
TP	Teilprojekt
UI	User Interface
UX	User Experience
V2G	Vehicle-To-Grid
YOLOv4	You Only Look Once Version 4

6. Literaturverzeichnis

- [1] Bundesministerium für Umwelt, Naturschutz und nukleare Sicherheit, „Klimaschutzplan 2050,“ Druck- und Verlagshaus Zarbock GmbH & Co. KG , Berlin, 2016.
- [2] C. Schmid, Energieeffizienz in Unternehmen: Eine wissensbasierte Analyse von Einflussfaktoren und Instrumenten, Zürich: vdf Hochschulverlag AG, 2004, p. 232.
- [3] Bundesministerium für Wirtschaft und Energie, „Kosten senken durch Energieberatung im Mittelstand,“ [Online]. Available: <https://www.deutschland-machtseffizient.de/KAENEFF/Redaktion/DE/Foerderprogramme/C-energieberatung-im-mittelstand.html>. [Zugriff am 5 Februar 2020].
- [4] S. Russel und P. Norvig, Künstliche Intelligenz: Ein moderner Ansatz, München: Person Deutschland, 2012.
- [5] VDI Verein Deutscher Ingenieure e.V., „Künstliche Intelligenz: VDI-Statusreport,“ 2018.
- [6] I. Seifert, M. Bürger, L. Wangler, S. Christmann-Budian, M. Rohde, P. Gabriel und G. Zinke, „Potenziale der künstlichen Intelligenz im produzierenden Gewerbe in Deutschland: Studie im Auftrag des Bundesministeriums für Wirtschaft und Energie im Rahmen der Begleitforschung zum Technologieprogramm PAiCE,“ iit-Institut für Innovation und Technik in der VDI / VDE Innovation + Technik GmbH, Berlin, 2018.
- [7] J. Mauerer, „Studie Internet of things,“ IDG Business Media GmbH, München, 2019.
- [8] H. Bauer, G. Richter, J. Wüllenweber, M. Breunig, D. Wee und H. Klein, „Smartening up with Artificial Intelligence (AI) - What's in it for Germany and its Industrial Sector?,“ McKinsey & Company, 2017.
- [9] R. Evans und J. Gao, „DeepMind AI Reduces Google Data Centre Cooling Bill by 40%,“ 20 Juli 2016. [Online]. Available: <https://deepmind.com/blog/article/deepmind-ai-reduces-google-data-centre-cooling-bill-40>. [Zugriff am 5 Februar 2020].
- [10] N. Jones, „nature,“ 2018 September 2018. [Online]. Available: <https://www.nature.com/articles/d41586-018-06610-y>. [Zugriff am 14 April 2020].
- [11] G. Beier, S. Niehoff, T. Ziems und B. Xue, „Sustainability Aspects of a Digitalized Industry – A Comparative Study from China and Germany,“ *International Journal of Precision Engineering and Manufacturing-Green Technology* Vol. 4, No. 2, pp. 227-234, April 2017.
- [12] Umwelt Bundesamt, „Branchenabhängiger Energieverbrauch des verarbeitenden Gewerbes,“ 03 Mai 2018. [Online]. Available: <https://www.umweltbundesamt.de/daten/umweltwirtschaft/industrie/branchenabhaengiger-energieverbrauch-des#der-energiebedarf-deutschlands>. [Zugriff am 29 April 2020].
- [13] F. Bühler, A. Guminsik, A. Gruber, T.-V. Nguyen, S. von Roon und B. Elmegaard, „Evaluation of energy saving potentials, costs and uncertainties in the chemical industry in Germany,“ *Applied Energy*, pp. 2037-2049, 15 Oktober 2018.
- [14] Y. Han, Q. Zeng, Z. Geng und Q. Zhu, „Energy management and optimization modeling based on a novel fuzzy extreme learning machine: Case study of complex petrochemical industries,“ *Energy Conversion and Management*, pp. 163-171, 1 Juni 2018.

-
- [15] T. Fleiter, D. Fehrenbach, E. Worrell und W. Eichhammer, „Energy efficiency in the German pulp and paper industry – A model-based assessment of saving potentials,“ *Energy*, pp. 84-99, April 2012.
- [16] Z. Zeng, M. Hong, J. Li, Y. Man, H. Liu, Z. Li und H. Zhang, „Integrating process optimization with energy-efficiency scheduling to save energy for paper mills,“ *Applied Energy*, pp. 542-558, 1 September 2018.
- [17] S. Wang, M. Liu, F. Chu und C. Chu, „Bi-objective optimization of a single machine batch scheduling problem with energy cost consideration,“ *Journal of Cleaner Production*, pp. 1205-1215, 20 November 2016.
- [18] N. Bhadbhade, M. J. S. Zuberi und M. K. Patel, „A bottom-up analysis of energy efficiency improvement and CO2 emission reduction potentials for the swiss metals sector,“ *Energy*, pp. 173-186, 15 August 2019.
- [19] X. Shen, L. Chen, S. Xia, Z. Xie und X. Qin, „Burdening proportion and new energy-saving technologies analysis and optimization for iron and steel production system,“ *Journal of Cleaner Production*, pp. 2153-2166, 20 Januar 2018.
- [20] R.-H. Hechelmann, F. Schlosser, H. Meschede und H. Dunkelberg, „Optimization of Cooling Utility System with Continuous Self-Learning Performance Models,“ *Energies*, Mai 2019.
- [21] N. Kumbartzky, M. Schacht, K. Schulz und B. Werners, „Optimal operation of a CHP plant participating in the German electricity balancing and day-ahead spot market,“ *European Journal of Operational Research*, pp. 390-404, 16 August 2017.
- [22] G. Liu, Y. Xu und K. Tomovic, „Bidding Strategy for Microgrid in Day-Ahead Market Based on Hybrid Stochastic/Robust Optimization,“ *IEEE Transactions on Smart Grid*, pp. 227-237, 22 September 2015.
- [23] A. Barckhausen, S. Joest, M. Koselleck, J. Paulus und A. Quezada, „Evaluation des Förderprogramms „Investitionszuschüsse zum Einsatz hocheffizienter Querschnittstechnologien im Mittelstand“,“ Berlin, 2016.
- [24] A. T. de Almeida, P. Fonseca und P. Bertoldi, „Energy-efficient motor systems in the industrial and in the services sectors in the European Union: characterisation, potentials, barriers and policies,“ *Energy*, pp. 673-690, Juni 2003.
- [25] P. Sirtalski, „Intelligent pumps: do they exist?,“ *World Pumps*, pp. 34-36, März 2014.
- [26] S. Leonow, Nutzung des Energiesparpotentials von Kreiselpumpen durch szenarienbasierte Regelung, Bochum: Ruhr-Universität Bochum, Universitätsbibliothek, 2016.
- [27] I. Oauchani, A. Rabhi, I. Yahyaoui, B. Tidhaf und T. Fernando Tadeo, „Renewable Energy Management Algorithm for a Water Pumping System,“ *Energy Procedia*, pp. 1030-1039, März 2017.
- [28] S. M. Abelin, „Intelligent future for wastewater pumping,“ *World Pumps*, pp. 34-37, März 2017.
- [29] D. Fischer und H. Madani, „On heat pumps in smart grids: A review,“ *Renewable & sustainable energy reviews*, pp. 342-357, 2017.
- [30] H. Wang, H. Wang, Z. Haijian und T. Zhu, „Optimization modeling for smart operation of multi-source district heating with distributed variable-speed pumps,“ *Energy*, pp. 1247-1262, 1 November 2017.

-
- [31] L. Ferrari, F. Esposito, M. Becciani, G. Ferrara, S. Magnani, M. Andreini, A. Bellissima, M. Cantu, G. Petretto und M. Pentolini, „Development of an optimization algorithm for the energy management of an industrial Smart User,“ *Applied Energy*, pp. 1468-1486, 15 Dezember 2017.
- [32] E. Ugleva, K. Zmineva und E. Kuznetsova, „Intelligent Power Consumption Management Systems,“ *IERI Procedia*, pp. 117-122, 2014.
- [33] S. K. Jha, J. Bilalovic, A. Jha, N. Patel und H. Zhang, „Renewable energy: Present research and future scope of Artificial Intelligence,“ *Renewable and Sustainable Energy Reviews*, pp. 297-317, September 2017.
- [34] S. D. Sessa, A. Tortella, M. Andriollo und R. Benato, „Li-Ion Battery-Flywheel Hybrid Storage System: Countering Battery Aging During a Grid Frequency Regulation Service,“ *Applied Sciences*, Bd. 11, Nr. 8, November 2018.
- [35] L. W. Chong, W. Y. W., R. K. Rajkumar, R. K. Rajkumar und I. D., „Hybrid energy storage systems and control strategies for stand-alone renewable energy power systems,“ *Renewable and Sustainable Energy Reviews*, Nr. 66, pp. 174-189, 2016.
- [36] T. Weitzel, M. Schneider, G. Franke, C. Glock und S. Rinderknecht, „Sizing and operating a hybrid electric energy storage system using meta heuristics,“ in *REMOO*, Venedig, Italien, 2018.
- [37] M. Rossi, D. Brunelli, A. Adami, L. Lorenzelli, F. Menna und F. Remondino, „Gas-Drone: Portable gas sensing system on UAVs for gas leakage localization,“ in *SENSORS*, Valencia, 2014.
- [38] A. Entrop und A. Vasenev, „Infrared drones in the construction industry: designing a protocol for building thermography procedures,“ *Energy Procedia*, pp. 63-68, Oktober 2017.
- [39] K. Juschkat, „Siemens entwickelt Drohne als Inspektionssystem,“ Vogel Communications Group, 16 Januar 2017. [Online]. Available: <https://www.elektrotechnik.vogel.de/siemens-entwickelt-drohne-als-inspektionssystem-a-572547/>. [Zugriff am 5 Februar 2020].
- [40] Bosch Rexroth AG, „IoT Gateway software – Get ready for Industry 4.0!,“ [Online]. Available: <https://www.boschrexroth.com/en/xc/products/product-groups/electric-drives-and-controls/news/software-iot-gateway/index>. [Zugriff am 5 Februar 2020].
- [41] VDMA, „Industrie 4.0 Kommunikation mit OPC UA: Leitfaden zur Einführung in den Mittelstand,“ VDMA Verlag, Frankfurt, 2017.
- [42] Hilscher Gesellschaft für Systemautomation mbH, „netIOT Edge,“ [Online]. Available: <https://www.hilscher.com/products/product-groups/industrial-internet-industry-40/netiot-edge/>. [Zugriff am 5 Februar 2020].
- [43] Siemens AG, „Industrial IoT Gateways SIMATIC CloudConnect 7,“ [Online]. Available: <https://new.siemens.com/global/de/produkte/automatisierung/industrielle-kommunikation/industrial-ethernet/industrial-iot-gateway-simatic-cloudconnect-7.html>. [Zugriff am 5 Februar 2020].
- [44] Intel Corporation, „Intel® IoT-Gateways,“ [Online]. Available: <https://www.intel.de/content/www/de/de/internet-of-things/gateway-solutions.html>. [Zugriff am 5 Februar 2020].
- [45] OPC Foundation, „OPC Unified Architecture: Wegbereiter der 4. industriellen (R)Evolution,“ Verl.

-
- [46] OPC Foundation, „OPC Foundation extends OPC UA including TSN down to field level,“ 11 Mai 2018. [Online]. Available: <https://opcfoundation.org/news/press-releases/opc-foundation-extends-opc-ua-including-tsn-down-to-field-level/>. [Zugriff am 20 April 2019].
- [47] ITWissen, „edge device,“ 30 Juli 2019. [Online]. Available: <https://www.itwissen.info/edge-device-Edge-Device.html>. [Zugriff am 5 Februar 2020].
- [48] R. Waslo, T. Lewis, R. Hajj und R. Carton, „Industry 4.0 and cybersecurity: Managing risk in an age of connected production,“ Deloitte, 2017 März 2017. [Online]. Available: <https://www2.deloitte.com/us/en/insights/focus/industry-4-0/cybersecurity-managing-risk-in-age-of-connected-production.html>. [Zugriff am 5 Februar 2020].
- [49] European Union Agency For Network and Information Security, „Good Practices for Security of Internet of Things in the context of Smart Manufacturing,“ Maroussi, 2018.
- [50] S. Amini, H. Mohsenian-Rad und F. Pasqualetti, „Dynamic load altering attacks in smart grid,“ in *IEEE Power & Energy Society Innovative Smart Grid Technologies Conference (ISGT)*, Washington, 2015.
- [51] H. Susanto und M. N. Almunawar, *Information Security Management Systems: A Novel Framework and Software as a Tool for Compliance with Information Security Standard*, New York: Apple Academic Press, 2018.
- [52] Bundesamt für Sicherheit in der Informationstechnik, „IT-Grundschutz: BSI-Standards,“ [Online]. Available: https://www.bsi.bund.de/DE/Themen/ITGrundschutz/ITGrundschutzStandards/it_grundschutzstandards.html. [Zugriff am 5 Februar 2020].
- [53] Bundesamt für Sicherheit in der Informationstechnik, „ICS-Security-Kompendium,“ Bonn, 2013.
- [54] VDMA, „Leitfaden Industrie 4.0 Security: Handlungsempfehlungen für den Mittelstand,“ VDMA Verlag, Frankfurt, 2016.
- [55] DKE, „Funktionale Sicherheit: Der Schutz des Menschen vor der Maschine,“ DKE, 20 November 2019. [Online]. Available: <https://www.dke.de/de/arbeitsfelder/core-safety/funktionale-sicherheit>. [Zugriff am 14 April 2020].
- [56] *ISO 50001: Energiemanagementsysteme - Anforderungen mit Anleitung zur Anwendung*, 2018-08.
- [57] J. Bischoff, „Erschließen der Potenziale der Anwendung von Industrie 4.0 im Mittelstand,“ agiplan GmbH, Mülheim an der Ruhr, 2015.
- [58] G. Schuh, R. Anderl, J. Gausemeier, M. ten Hompel und W. Wahlster, „Industrie 4.0 Maturity Index: Die digitale Transformation von Unternehmen gestalten,“ Herbert Utz Verlag, München, 2017.
- [59] S. Schenk und T. Heinen, „Ganzheitliche Einführung von Industrie 4.0 zur Steigerung der Energietransparenz,“ GITO mbH Verlag für Industrielle Informationstechnik und Organisation, [Online]. Available: <https://www.industrie-management.de/node/60>. [Zugriff am 5 Februar 2020].
- [60] M. Blesl und A. Kessler, *Energieeffizienz in der Industrie*, Berlin: Springer Vieweg, 2013.
- [61] GUT Zertifizierungsgesellschaft für Managementsysteme mbH, „zum effizienten Energiemanagement nach ISO 50001: Ein Leitfaden für Einsteiger,“ Berlin, 2018.

- [62] G. Posselt, Towards Energy Transparent Factories, Basel: Springer International Publishing, 2016.
- [63] E. O'Driscoll, D. Og Cussack und G. O'Donnell, „Implementation of Energy Metering Systems in Complex Manufacturing Facilities–A Case Study in a Biomedical Facility,“ *Procedia CIRP*, pp. 524-529, 2012.
- [64] J. Sossenheimer, J. Walther, J. Fleddermann und E. Abele, „A Sensor Reduced Machine Learning Approach for Condition-based Energy Monitoring for Machine Tools,“ *Procedia CIRP*, pp. 570-575, 2019.
- [65] Ökotec Energiemanagement GmbH, „Die Zeit drängt bei der Einführung von Energiemanagement,“ [Online]. Available: <http://www.oekotec.de/de/die-zeit-draengt-bei-der-einfuehrung-von-energiemanagement/>. [Zugriff am 5 Februar 2020].
- [66] J. S. Armstrong und D. J. Reibstein, „Evidence on the value of strategic planning in marketing: how much planning should a marketing planner plan?,“ in *Strategic Marketing and Management*, Philadelphia, John Wiley & Sons, Ltd, 1985, pp. 73-87.
- [67] M. P. Clements und D. Hendry, „On winning forecasting competitions,“ *Spanish Economic Review*, pp. 123-160, September 1999.
- [68] H. Hahn, S. Meyer-Nieberg und S. Pickl, „Electric load forecasting methods: Tools for decision making,“ *European Journal of Operational Research*, pp. 902-907, 16 Dezember 2009.
- [69] T. Hong und S. Fan, „Probabilistic electric load forecasting: A tutorial review,“ *International Journal of Forecasting*, pp. 914-938, September 2016.
- [70] T. Hong, Short Term Electric Load Forecasting, Raleigh: North Carolina State University, 2010.
- [71] L. Alejandro, C. Blair, L. Bloodgood, M. Khan, M. Lawless, D. Meehan, P. Schneider und K. Tsuji, „Global Market for Smart Electricity Meters: Government Policies Driving Strong Growth,“ U.S. International Trade Commission, Washington, 2014.
- [72] P. Su, X. Tian, Y. Wang, D. Shuai, J. Zhao, Q. An und Y. Wang, „Recent Trends in Load Forecasting Technology for the Operation Optimization of Distributed Energy System,“ *Energies*, pp. 1-13, 2017.
- [73] C. Fan, F. Xiao und Y. Zhao, „A short-term building cooling load prediction method using deep learning algorithms,“ *Applied Energy*, pp. 222-233, 1 Juni 2017.
- [74] A. E. Ben-Nakhi und M. A. Mahmoud, „Cooling load prediction for buildings using general regression neural networks,“ *Energy Conversion and Management*, pp. 2127-2141, August 2004.
- [75] P. Lorenzen, P. Janßen, M. Winkel, D. Klose, P. Kernstock, J. Schrage und F. Schubert, „Design of a Smart Thermal Grid in the Wilhelmsburg district of Hamburg: Challenges and approaches,“ *Energy Procedia*, pp. 499-508, September 2018.
- [76] M. Saeedi, M. Moradi, M. Hosseini, A. Emamifar und N. Ghadimi, „Robust optimization based optimal chiller loading under cooling demand uncertainty,“ *Applied Thermal Engineering*, pp. 1081-1091, 5 Februar 2019.
- [77] M. Coatalem, V. Mazauric, C. Le Pape-Gardeaux und N. Maizi, „Optimizing industries' power generation assets on the electricity markets,“ *Applied Energy*, pp. 1744-1756, 1 Januar 2017.
- [78] FGH e.V., „Metastudie Smart Grid: Forschungsüberblick intelligente Stromnetze,“ BDEW Bundesverband der Energie- und Wasserwirtschaft e.V., Berlin, 2016.

- [79] Golem Media GmbH, „Reinforcement Learning: genetischer Algorithmus,“ [Online]. Available: <https://www.golem.de/news/random-forest-k-means-genetik-machine-learning-anhand-von-drei-algorithmen-erklart-1810-136755-3.html>. [Zugriff am 20 April 2019].
- [80] R. Becker, „Genetische Algorithmen und Deep Learning - Die Evolution von Neuronalen Netzen mit Evolutionären Algorithmen,“ JUST ADD AI GmbH, 30 November 2018. [Online]. Available: <https://jaai.de/genetische-algorithmen-1496/>. [Zugriff am 20 April 2019].
- [81] K. Fang, N. Uhan, F. Zhao und J. W. Sutherland, „A new approach to scheduling in manufacturing for power consumption and carbon footprint reduction,“ *Journal of Manufacturing Systems*, pp. 234-240, Oktober 2011.
- [82] M. Kube, M. Schimmel, J.-M. Rhiemeier, A. Barckhausen, J. Fehr, S. Büttner, M. Unger, F. Bottner und A. Piegsa, „Marktverfügbare Innovationen mit hoher Relevanz für die Energieeffizienz in der Industrie,“ Berlin, 2017.
- [83] R. Glass, A. Meissner, C. Gebauer, S. Stürmer und J. Metternich, „Identifying the barriers to Industrie 4.0,“ *Procedia CIRP*, pp. 985-988, 2018.
- [84] R. Walter, „Ein Vergleich verschiedener auf Machine-Learning basierender Modelle zur Klassifikation von Energiedaten,“ Bachelorarbeit, h_da, Darmstadt, 2021.
- [85] ISO, *ISO 6983-1:2009-12: Automationssysteme und Integration - Steuerung von Maschinen - Programmformat und Definition von Adresswörtern - Teil 1: Datenformat für Positionierung, Linearbewegungen und Bahnsteuerungen*, Beuth, (2009).
- [86] *Deutschen Normungsroadmap Künstliche Intelligenz, Ausgabe 2, Kapitel 4.2.1.1*, Offenbach am Main, Dec 2022.
- [87] *Deutschen Normungsroadmap Künstliche Intelligenz Ausgabe 2, Kapitel 4.2.1.2*, Offenbach am Main, Dec 2022.
- [88] *Deutschen Normungsroadmap Künstliche Intelligenz Ausgabe 2, Kapitel 2*, Offenbach am Main, Dec 2022.
- [89] *Deutschen Normungsroadmap Künstliche Intelligenz Ausgabe 2, Kapitel 4.2.1.3*, Offenbach am Main, Dec 2022.
- [90] K. O'Rielly und J. Jeswiet, „The Need for Better Energy Monitoring within Industry,“ *Procedia CIRP*, pp. 74-79, 2015.
- [91] A. Trianni, E. Cagno und S. Farne, „Barriers, drivers and decision-making process for industrial energy efficiency: A broad study among manufacturing small and medium-sized enterprises,“ *Applied Energy*, pp. 1537-1551, 15 Januar 2016.
- [92] M. Blesl und A. Kessler, *Energieeffizienz in der Industrie*, Berlin, Heidelberg: Springer, 2018.
- [93] D. Kaya, F. Çanka Kılıç und H. H. Öztürk, „Energy Efficiency in Compressed Air Systems,“ in *Energy Management and Energy Efficiency in Industry*, Cham, Springer International Publishing, 2021, p. 395–418.
- [94] P. Richard, S. U. Dudhagara, L. Kunz, C. Plociennik und M. Ruskowski, *Autonomous mobile robot search strategy for automated compressed air leakage detection*.
- [95] J. Sossenheimer, O. Vetter und E. W. M. Abele, „Hybrid Virtual Energy Metering Points — A Low-Cost Energy Monitoring Approach for Production Systems Based on Offline Trained Prediction Models,“ *Procedia CIRP*, 2020.

-
- [96] J. Sossenheimer, Hybrides Energiemessstellenkonzept zum ganzheitlichen Energiemonitoring von Fertigungsmaschinen und Komponenten, Darmstadt: Dissertation, TU Darmstadt, 2023.
- [97] P. Bescond, „Cyclic l fe ures encoding, i ’s bou ime! - Towards Data Science.,“ 2020. [Online]. Available: <https://towardsdatascience.com/cyclicalfeatures-encoding-its-about-time-ce23581845ca>. [Zugriff am 2022].
- [98] J. Walther, Hierarchical Electrical Load Forecasting of Industrial Production Systems in the Manufacturing Industry based on Deep Learning (angenommen)., Darmstadt: Technische Universität Darmstadt, 2022.
- [99] S. Taieb, G. Bontempi, A. F. Atiya und A. Sorjamaa, „A review and comparison of strategies for multi-step ahead time series forecasting based on the NN5 forecasting competition,“ *Expert systems with applications*, Bd. 39.8, pp. 7067-7083, 2012.
- [100] H. Jin, Q. Song und X. Hu, „Auto-Keras: An Efficient Neural Architecture Search System,“ in *KDD '19: The 25th ACM SIGKDD Conference on Knowledge Discovery and Data Mining*, New York, USA, Association for Computing Machinery, 2019, pp. 1946-1956.
- [101] H. Pham, M. Y. Guan, B. Zoph, Q. V. Le und J. Dean, Efficient Neural Architecture Search via Parameter Sharing, 2018.
- [102] M. Wistuba, „Deep Learning Architecture Search by Neuro-Cell-Based Evolution with Function-Preserving Mutations,“ in *Machine Learning and Knowledge Discovery in Databases*, Basel, Schweiz, Springer International Publishing, 2019, pp. 243-258.
- [103] O. Grein, Hyperparameter optimization of deep neural network architecture for forecasting energy demands in industry, Darmstadt: Technische Universität Darmstadt, 2022.
- [104] B. Grosch, Simplified Implementation of Energy-Aware Production Scheduling in Job Shops, Technische Universität Darmstadt: Unveröffentlichte Dissertation, 2023.
- [105] H. Ranzau, Anwendung von Deep Reinforcement Learning zur Betriebsoptimierung industrieller Energieversorgungssysteme, Darmstadt: (Veröffentlichung erfolgt im Mai 2025), 2025.
- [106] M. Klostermeier, L. Kunz, W. Motsch, B. Ioshchikhes, C. Plociennik und M. Ruskowski, „Energy Load Profile Analysis and Application for Production Simulation and Scheduling using Energy Load Disaggregation,“ *INFORMATIK 2024, Lecture Notes in Informatics (LNI), Gesellschaft für Informatik*, pp. 1079-1097, 2024.
- [107] B. Ioshchikhes, G. Elserafi und M. Weigold, „An Expert System-Based Approach For Improving Energy Efficiency Of Chamber Cleaning Machines,“ *Proceedings of the Conference on Production Systems and Logistics (CPSL)*, p. 1–11, 2023.
- [108] B. Ioshchikhes, M. Frank, G. Elserafi, J. Magin und M. Weigold, „Developing Expert Systems for Improving Energy Efficiency in Manufacturing: A Case Study on Parts Cleaning,“ *Energies*, Nr. 14, 2024.
- [109] I. Mehmed, C. Wincierz, B. Ioshchikhes und M. Weigold, „Entwicklung eines Vorschlagswesens für die Auswahl energieeffizienzsteigernder Betriebsstoffe,“ *Gesellschaft für Tribologie e.V. (Hg.) 2022 – 63. Tribologie-Fachtagung*, p. 89–103, 2022.
- [110] J. Stock, Entwicklung eines Simulationsmodells für die energetische Abbildung und Betriebsoptimierung von Reinigungsmaschinen, Darmstadt, 2021.

-
- [111] D. Fuhrländer-Völker, F. Borst, L. Theisinger, H. Ranzau und M. Weigold, „Modular Data Model for Energy-Flexible Cyber-physical Production Systems,“ *Procedia CIRP*, Bd. 107, pp. 215-220, 2022.
- [112] B. Grosch, D. Fuhrländer-Völker, J. Stock und M. Weigold, „Cyber-physical production system for energy-flexible control of production machines,“ *Procedia CIRP*, Bd. 107, pp. 221-226, 2022.
- [113] D. Fuhrländer-Völker, B. Grosch und M. Weigold, „Modelling and control of aqueous parts cleaning machines for demand response,“ *Proceedings of the Conference on Production Systems and Logistics: CPSL 2023*, pp. 790-800, 2023.
- [114] D. Fuhrländer-Völker, J. Magin und M. Weigold, „Automation architecture for harnessing the demand response potential of aqueous parts cleaning machines,“ *Production Engineering*, 2023.
- [115] D. Fuhrländer-Völker, Automation Architecture for Demand Response on Aqueous Parts Cleaning Machines. Dissertation., Darmstadt: Technische Universität Darmstadt, 2023.
- [116] S. Schmitt, Energetische Synchronisierung von Beschleunigungs- und Abbremsvorgängen im DC-Verbundnetz spanender Werkzeugmaschinen, Darmstadt, 2021.
- [117] G. Plett, „Battery Management Systems,“ in *Battery Modeling*, Artech House, 2015.
- [118] A. E. Rahmoun und H. Biechl, „Modelling of Li-ion batteries using equivalent circuit diagrams,“ *Przegląd Elektrotechniczny, Engineering*, pp. 152-156, 2012.
- [119] M. Schneider, „Ganzheitlicher modellbasierter Entwurf von kinetischen Energiespeichern in Außenläuferbauform,“ *Shaker Verlag*, 29.05.2019.
- [120] M. R. S. Schneider, „System Loss Measurement of a Novel Outer Rotor Flywheel Energy Storage System,“ *2019 IEEE International Electric Machines & Drives Conference (IEMDC)*, pp. 1379-1385, 2019.
- [121] J. Schmalstieg, S. Käbitz, M. Ecker und D. U. Sauer, „A holistic aging model for Li(NiMnCo)O₂ based 18650 lithium-ion batteries,“ *Journal of Power Sources*, pp. 325-344, 1. Juli 2014.
- [122] K. Smith, P. Gasper, A. M. Colclasure, Y. Shimonishi und S. Yoshida, „Lithium-Ion Battery Life Model with Electrode Cracking and Early-Life Break-in Processes,“ *Journal of the Electrochemical Society*, 22. Oktober 2021.
- [123] B. Grosch, H. Ranzau, B. Dietrich, T. Kohne, D. Fuhrländer-Völker, J. Sossenheimer, M. Lindner und M. Weigold, „A framework for researching energy optimization of factory operations,“ *Energy Informatics*, Bd. 5, Nr. 1, p. 29, 2022.
- [124] K. Deb, A. Pratap, S. Agarwal und T. Meyarivan, „A fast and elitist multiobjective genetic algorithm: NSGA-II,“ *IEEE Transactions on Evolutionary Computation*, Bd. 6, Nr. 2, pp. 182-197, 2002.
- [125] A. Erl, E. Westkämper, E. Abele, A. Dietmair, J. Schlechtendahl, J. Friedrich, H. Haag und S. Schrems, „Architecture for Multilevel Monitoring and,“ *Glocalized Solutions for Sustainability in Manufacturing – Proceedings of the 18th CIRP International Conference on Life Cycle Engineering in Braunschweig*, p. 347–352, 2011.
- [126] SCIP, „SCIP,“ [Online]. Available: <https://scipopt.org/>. [Zugriff am 09.01.2023].
- [127] M. Böhm, „Verfahren zur Ruckbegrenzung von numerischen Antriebssystemen.“. Patent 0 419 705 A1, 29.09.1989.

- [128] D. Di Palma, „Retrieval-augmented recommender system: Enhancing recommender systems with large language models,“ in *Proceedings of the 17th ACM Conference on Recommender Systems*, 2023.
- [129] P. Lewis, E. Perez, A. Piktus, F. Petroni, V. Karpukhin, N. Goyal, H. Küttler, M. Lewis, W.-t. Yih und T. Rocktäschel, „Retrieval-augmented generation for knowledge-intensive nlp tasks,“ *Advances in Neural Information Processing Systems*, Bd. 33, pp. 9459-9474, 2020.
- [130] Y. Gao, Y. Xiong, M. Wang und H. Wang, „Modular rag: Transforming rag systems into lego-like reconfigurable frameworks,“ arXiv preprint arXiv:2407.21059, 2024.
- [131] N. Alshuqayran, N. Ali und R. Evans, „A systematic mapping study in microservice architecture,“ in *2016 IEEE 9th international conference on service-oriented computing and applications (SOCA)*, 2016.
- [132] T. Franzelin, S. Schwarz und S. Rinderknecht, „Smart Charging and V2G: Enhancing a Hybrid Energy Storage System with Intelligent and Bidirectional EV Charging,“ *World Electr. Veh. J.*, Bd. 3, Nr. 121, p. 16, 2025.
- [133] M. Marinelli, L. Calearo and J. Engelhardt, "A Simplified Electric Vehicle Battery Degradation Model Validated with the Nissan LEAF e-plus 62-kWh," *Proceedings of 6th International Electric Vehicle Technology Conference - Yokohama, Japan*, p. 8, 2023.
- [134] „KI4ETA | Künstliche Intelligenz für Energietechnologien und Anwendungen in der Produktion,“ PTW TU Darmstadt, 22 November 2024. [Online]. Available: <https://www.youtube.com/watch?v=XqUhCVUpXRY>. [Zugriff am 2 April 2025].
- [135] United Nations, „Transforming our world: the 2030 Agenda for Sustainable Development,“ in *General Assembly: 70th session*, New York, 2015.
- [136] Bundesministerium für Umwelt, Naturschutz und nukleare Sicherheit, „Die Klimakonferenz in Paris,“ 05 September 2017. [Online]. Available: <https://www.bmu.de/themen/klima-energie/klimaschutz/internationale-klimapolitik/pariser-abkommen/>. [Zugriff am 23 April 2019].
- [137] Bundesministerium für Wirtschaft und Energie, „7. Energieforschungsprogramm: Innovationen für die Energiewende,“ Druck- und Verlagshaus Zarbock GmbH & Co. KG, Frankfurt, 2018.
- [138] Universität Duisburg Essen, „Informatik,“ [Online]. Available: https://www.uni-due.de/isa/fg_naturwiss/informatik/informatik_hs_frm.htm. [Zugriff am 20 April 2019].
- [139] B. Menz, Methode zur digitalen Vernetzung von Produktionsmaschinen zur Lastgangglättung im Betrieb, Aachen: Shaker Verlag, 2017.
- [140] P. Schraml, Methode zur Reduktion maximaler elektrischer Lasten spanender Werkzeugmaschinen, Aachen: Shaker Verlag, 2018.
- [141] E. Abele, M. Beck, D. Flum, P. Schraml, N. Panten, F. Junge, C. Bauerdick, M. Helfert, T. Sielaff, C. Daume, M. Weber, N. Strobel, A. Redelberger, L. Pototzky, S. Rothenbücher, G. Landgraf, W. Rummel, K. Heimbach, P. Haase, S. Stock, J. Schwarz, S. Schaal, R. Kunde und A. Krönauer, Gemeinsamer Schlussbericht zum Projekt ETA-Fabrik : Energieeffiziente Fabrik für interdisziplinäre Technologie- und Anwendungsforschung, Darmstadt, 2019.
- [142] A. Verl, Abschlussbericht FOR 1088 Ecomation, Düsseldorf: VDI Verlag, 2017.
- [143] A. Eytan, Project Final Report: Eco Manufactured transportation means from Clean and Competitive Factory, Braunschweig, 2014.

-
- [144] E. Abele, Maximierung der Energieeffizienz spanender Werkzeugmaschinen : Schlussbericht zum Projekt MaxiEM, Darmstadt, 2013.
- [145] M. Armendia, M. Gassempouri, E. Ozturk und F. Peysson, Twin-Control: A Digital Twin Approach to Improve Machine Tools Lifecycle, Cham: Springer, 2019.
- [146] E. Abele, M. Dittrich, C. Eisele, O. Kessing, W. Klöblen, M. Rudolph und W. Rummel, Energieeffiziente Produktionsmaschinen durch Simulation in der Produktentwicklung: Ergebnisbericht des BMBF Verbundprojektes eSimPro, Darmstadt, 2013.
- [147] L. Quilumba, L. K. Lee, W.-J. Lee und A. Harding, „Improving Hydraulic System Energy Efficiency With High-Performance Hydraulic Fluids,“ *IEEE Transactions on Industry Applications*, August 2013.
- [148] E. Keogh und A. Mueen, „Curse of Dimensionality,“ in *Encyclopedia of Machine Learning and Data Mining*, Boston, Springer, 2017.
- [149] B. Mittelstadt, C. Russel und S. Wachter, „Explaining Explanations in AI,“ in *Proceedings of FAT* '19: Conference on Fairness, Accountability, and Transparency*, Atlanta, 2019.
- [150] S. Koenig und M. Likhachev, „D*Lite,“ in *Proceedings of the Eighteenth National Conference on Artificial Intelligence*, Edmonton, 2002.
- [151] G. Grisetti, C. Stachniss und W. Burgard, „Improved Techniques for Grid Mapping With Rao-Blackwellized Particle Filters,“ *IEEE Transactions on Robotics*, pp. 34-46, 5 Februar 2007.
- [152] R. Raso, A. Emrich, B. Torsten, M. Schlenker, T. Gudehus, O. Sträter, P. Fettke und P. Loos, „Activity Monitoring Using Wearable Sensors in Manual Production Processes - An Application of CPS for Automated Ergonomic Assessments,“ in *Tagungsband Multikonferenz Wirtschaftsinformatik (MKWI) 2018 - Data driven X - Turning Data into Value*, Lüneburg, 2018.
- [153] C. J. H. Bauerdick, M. Helfert, B. Menz und E. Abele, „A Common Software Framework for Energy Data Based Monitoring and Controlling for Machine Power Peak Reduction and Workpiece Quality Improvements,“ *Procedia CIRP*, pp. 359-364, 2017.
- [154] H. Teiwes, S. Blume, C. Herrmann, M. Rössinger und S. Thiede, „Energy load profile analysis on machine level,“ *Procedia CIRP*, pp. 271-276, 2018.
- [155] W. B. a. S. T. D. Fox, „The dynamic window approach to collision avoidance,“ *IEEE Robotics & Automation Magazine*, vol. 4, no. 1, pp. 23-33, March 1997.
- [156] M. Appel, U. Konigorski und M. Walther, „A Graph Metric for Model Predictive Control of Petri Nets,“ *IFAC-PapersOnLine 51.2: 9th Vienna International Conference on Mathematical Modelling*, pp. 254-259, 2018.
- [157] M. Appel, M. Walther und U. Konigorski, „Distributed trajectory planning for multi-agent discrete event systems,“ *at - Automatisierungstechnik*, p. 751–761, 2019.
- [158] M. Appel, M. Walther und U. Konigorski, „Modeling and Control of Production Networks,“ *25th International Conference on Mechatronics and Machine Vision in Practice (M2VIP)*, 2018.
- [159] A. Neifer, M. Appel, M. Walther und U. Konigorski, „Flow network control via substituted flows determining the ratio of parallel flows,“ *IFAC-PapersOnLine: 9th IFAC Conference on Manufacturing Modelling, Management and Control*, p. 1455–1460, 2019.
- [160] M. Appel, *Regelung ereignisdiskreter Multi-Agenten-Systeme am Beispiel flexibler Produktionsnetzwerke*, Darmstadt: Technische Universität Darmstadt, 2020.

- [161] M. J. Alibert, H. Görlitzer, S. N. Herzog und C. D. Neveu, „Efficiency advantages in vane, piston and gear pumps – what high VI hydraulic fluids can do for you!“, in *5th International Fluid Power Conference*, Dresden, 2006.
- [162] S. N. Herzog und C. D. Neveu, „Relative Impact of Hydromechanical and Volumetric Losses on Hydraulic Pump Efficiency at High and Low Temperatures“, in *Proceedings of the 52nd National Conference on Fluid Power*, Las Vegas, 2011.
- [163] P. Radgen, „Compressed Air Systems in the European Union“, p. 127, 2001.
- [164] dena, „Energieeffizienz in kleinen und mittleren Unternehmen.“, Dezember 2015.
- [165] dena, „Marktverfügbaren Innovationen mit hoher Relevanz für die Energieeffizienz in der Industrie“, 2017.
- [166] M. Alibert und T. Schimmel, „The importance of viscosity for hydraulic fluid efficiency - What can we learn from a decade of fluid development?“, in *TAE Colloquium Tribology 2012*, Ostfildern, 2012.
- [167] European Commission, „White Paper on Artificial Intelligence - A European approach to excellence and trust“, European Commission, Brüssel, 2020.
- [168] L. Vogel, P. Richard, M. Brey, S. Mamel und K. Schätz, „Künstliche Intelligenz für die integrierte Energiewende“, Deutsche Energie-Agentur GmbH (dena), Berlin, 2019.
- [169] Bundesministerium für Wirtschaft und Energie, „Das Projekt GAIA-X: Eine vernetzte Dateninfrastruktur als Wiege eines vitalen, europäischen Ökosystems“, Bundesministerium für Wirtschaft und Energie, Berlin, 2019.
- [170] ETA-Fabrik, „eta-utility auf GitLab“, 4 2022. [Online]. Available: <https://git.rwth-aachen.de/eta-fabrik/public/eta-utility>. [Zugriff am 15 4 2022].
- [171] ETA-Fabrik, „eta-utility auf PyPi“, 04 2022. [Online]. Available: <https://pypi.org/project/eta-utility/>. [Zugriff am 15 04 2022].
- [172] S. Hansen, Automated Neural Architecture Search of Machine Learning Load Forecasting Models, Darmstadt : Tu Darmstadt, 2021.
- [173] M. Blesl und A. Kessler, Energieeffizienz in der Industrie, Berlin, Heidelberg: Springer, 2018.
- [174] J. Metternich, L. Schebek, R. Anderl, P. Bausch, C. Czwick, C. Geyer, L. Hartmann, S. Kugler, M. Schreiber, J. Sossenheimer, C. Urnauer, A. Weyand und J. Zeulner, Fit für die Zukunft, Ressourceneffizienz in der Produktion, Wiesbaden, 2021.
- [175] J. Metternich, L. Schebek, R. Anderl, P. Bausch, C. Czwick, C. Geyer, L. Hartmann, S. Kugler, M. Schreiber, J. Sossenheimer, C. Urnauer, A. Weyand und J. Zeulner, Fit für die Zukunft, Ressourceneffizienz in der Produktion, Wiesbaden, 2021.
- [176] A. Ruffini, Entwicklung von Betriebsstrategien für hybride Energiespeicher auf Basis von künstlicher Intelligenz, Darmstadt, 2019.
- [177] M. Schneider, S. Rinderknecht und D. Schaab, „Loss models of a PMSM in an outer rotor flywheel concept“, *IEEE*, 21. - 24. Mai 2017.
- [178] P. T. Darmstadt, „KI4ETA | Künstliche Intelligenz für Energietechnologien und Anwendungen in der Produktion“, PTW TU Darmstadt, 22 November 2024. [Online]. Available: <https://www.youtube.com/watch?v=XqUhCVUpXRY>. [Zugriff am 2 April 2025].