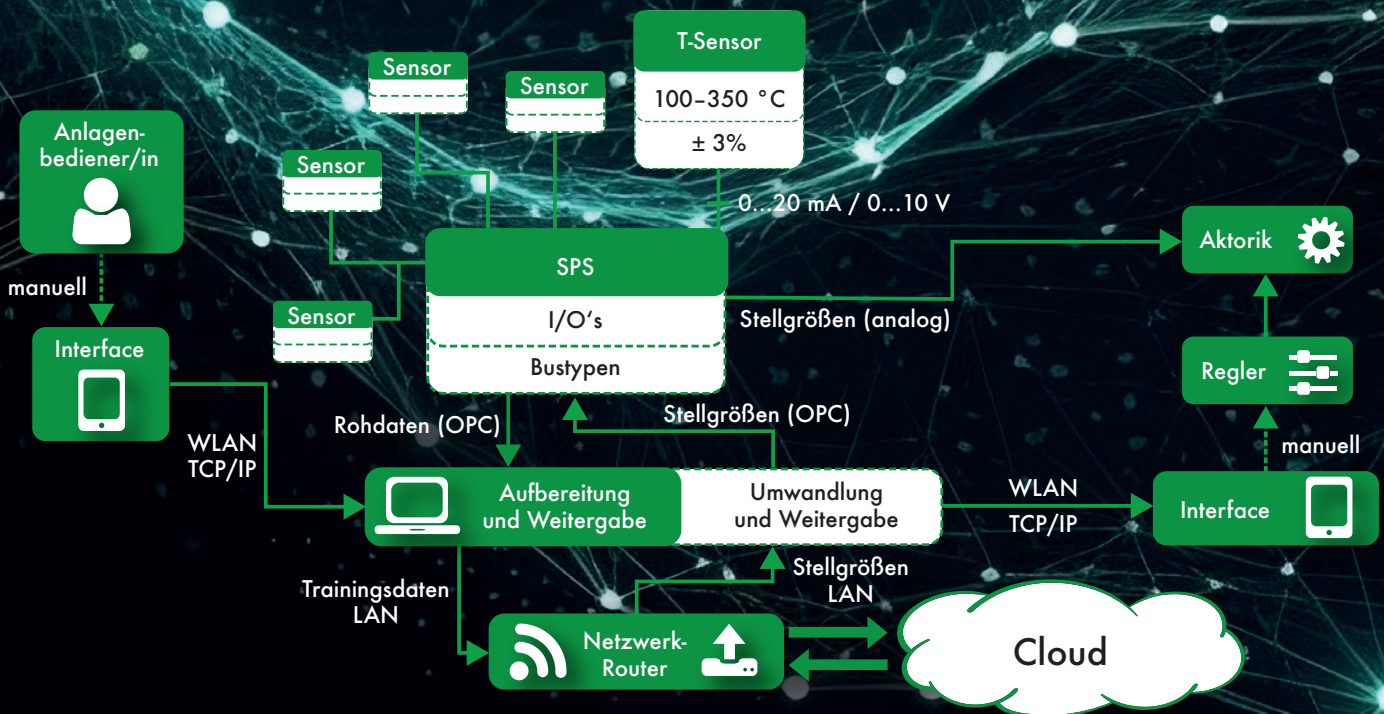




# RESOURCE-EFFICIENT, ECONOMIC AND INTELLIGENT FOODCHAIN



Verbundvorhaben



# RESOURCE-EFFICIENT, ECONOMIC AND INTELLIGENT FOODCHAIN

## **Herausgeber**

Prof. Dr.-Ing. Stefan Braunreuther, Technische Hochschule Augsburg

Dirk Mayer, Software AG

Judith Weber, Spicetech GmbH

Günther Gaßner, Technische Universität München

Philipp Theumer, Fraunhofer-Institut für Gießerei-, Composite- und  
Verarbeitungstechnik IGCV

Daniel Schaten, Westfleisch SCE mbH

Ingo Becker, Inotec GmbH, Handtmann Unternehmensgruppe

Klaus Kaufmann, GS1 Germany

Michael Metzenmacher, Technische Universität München

## © Hinweis der Herausgeber

Wir weisen darauf hin, dass das Urheberrecht sämtlicher Texte und Grafiken in diesem Buch bei den jeweiligen Autoren und das Urheberrecht des Buches als Ganzes bei den Herausgebern liegt. Jede Form der Vervielfältigung auf drucktechnischem oder elektronischem Weg – auch auszugsweise – bedarf der ausdrücklichen, schriftlichen Zustimmung sowohl der Herausgeber als auch der jeweiligen Autoren. Für alle Inhalte und Beiträge sind die Verfasser verantwortlich.

Gefördert durch:



aufgrund eines Beschlusses  
des Deutschen Bundestages

Das Projekt REIF war Teil des Innovationswettbewerbs „Künstliche Intelligenz als Treiber für volkswirtschaftlich relevante Ökosysteme“ und wurde vom Bundesministerium für Wirtschaft und Klimaschutz aufgrund eines Beschlusses des Deutschen Bundestages gefördert. Weitere Informationen zum Projekt finden Sie unter <https://ki-reif.de/> und <https://ki-lebensmittelretter.de/>.

© 2023

ISBN: 978-3-7690-0864-7

Projektleitung: Prof. Dr.-Ing. Stefan Braunreuther, Hans-Martin Braun

Buch: Rainer Schramm, DLG e.V., Frankfurt am Main

Herstellung: Ralph Bennewitz, DLG-Verlag, Frankfurt am Main

Layout: Grafikbüro, DLG-Verlag, Frankfurt am Main

Bildnachweis Titel: AdobeStock

## Vorwort

*„Das Thema Rückverfolgbarkeit von Produkten wird immer wichtiger. Verbraucher interessieren sich immer mehr für Herstellung und Herkunft der Produkte. Mit dem REIF-Projekt leisten wir einen Beitrag für verbesserte, wirksame Wertschöpfung.“*

*„Die interdisziplinäre Zusammenarbeit wird zunehmend wichtiger, ganz besonders müssen die rechtlichen Aspekte in zukünftigen Projekten verstärkt beachtet werden.“*

*„Die Zusammenarbeit mit neuen Partnern hat gezeigt, dass das Wissen über die Produkte im Regal entscheidend ist.“*

*„Gestartet, um einen Mischer zu optimieren, geendet mit einer neuen Möglichkeit, das Mindesthaltbarkeitsdatum vorherzusagen.“*

*„Eine gute Analyse der IST-Situation ist Voraussetzung für den sinnvollen Einsatz von KI.“*

*„Der Einsatz von KI kann die Herstellung von Molkereierzeugnissen optimieren. Ohne Domänenwissen produziert KI in der Molkereiindustrie aber auch nur Käse.“*

*„Bisher bewerten wir Lebensmittel primär nach dem Warenwert. KI wird uns beibringen, den wahren Wert zu erkennen.“*

Oder kurz und knapp auf den Punkt gebracht:

*„KI ist sinnvoll einsetzbar, wenn man ihre Qualitäten kennt.“*

Allein schon diese Stimmen aus der Abschlussveranstaltung des REIF-Projektes im Juni 2023 im DLG-Haus Frankfurt zeigen, wie vielfältig die Erkenntnisse aus diesem Verbundvorhaben sind und welche großen Potenziale im Thema Künstliche Intelligenz (KI) stecken.

Ziel des REIF-Projektes war es, durch den Einsatz von KI die Verschwendung von Lebensmitteln im Produktionsprozess deutlich zu reduzieren; insbesondere in den Branchen Molkerei, Fleisch und Backwaren, die einen relativ großen Klimafußabdruck haben.

Um dieses Ziel zu erreichen, sind entlang der Wertschöpfungskette zwei Punkte entscheidend: die Minimierung von Überproduktion und die Vermeidung von Ausschuss. Wo konventionelle Technologien an ihre Grenzen stoßen, bietet KI innovative Lösungsansätze. Beispielsweise kann mithilfe von KI die Nachfrage der Konsumenten genauer prognostiziert oder die Produktionsinfrastruktur dazu befähigt werden, kurzfristig sowohl auf schwankende Nachfrage als auch auf schwankende Rohstoffqualitäten zu reagieren.

Der Fokus des Projekts lag auf der Entwicklung einer ganzheitlichen Optimierungsstrategie über mehrere Wertschöpfungsstufen und -partner hinweg. Verschiedene Anwendungen der Künstlichen Intelligenz eröffnen hier die bisher einmalige Chance, die Verschwendung von Lebensmitteln drastisch zu reduzieren.

**Hans-Martin Braun, Stefan Braunreuther,**  
Konsortialführung des Projekts REIF,  
Fakultät für Maschinenbau und Verfahrenstechnik,  
Technische Hochschule Augsburg

### **Aktive Projektpartner:**

- ARXUM GmbH
- BayWa IT GmbH
- Collaborating Centre on Sustainable Consumption and Production gGmbH (CSCP)
- Fraunhofer-Institut für Gießerei-, Composite- und Verarbeitungstechnik (IGCV)
- GS1 Germany GmbH
- Hochland Deutschland GmbH
- Hochschule für Angewandte Wissenschaften Hof
- Industrial Analytics IA GmbH
- Inotec GmbH
- Jade Hochschule
- Kuchenmeister GmbH
- Software AG
- Spicetech GmbH
- Technische Hochschule Augsburg
- Technologisches Institut für angewandte Künstliche Intelligenz GmbH (TI.KI) GmbH
- tegut... gute Lebensmittel GmbH & Co. KG
- Technische Universität München (TUM)
- Westfleisch SCE mbH

Vorwort .....	3
Abkürzungen .....	6
Abbildungsverzeichnis .....	8
Tabellenverzeichnis .....	10
<b>1. Projektüberblick REIF .....</b>	<b>11</b>
1.1 Aufgaben und Ziele .....	11
1.2 Voraussetzungen für das Projekt .....	12
1.2.1 Volkswirtschaftlich bedeutsame Wirtschaftsbereiche .....	12
1.2.2 Anwendung Künstlicher Intelligenz .....	13
1.2.3 Schaffung eines innovativen und Erfolg versprechenden Ökosystems .....	13
1.2.4 Wichtige Begleitumstände .....	13
1.3 Struktur, Planung und Ablauf des Projektes .....	14
1.4 Wissenschaftlicher und technischer Hintergrund .....	16
1.4.1 Für REIF genutzte Konstruktionen, Verfahren und Schutzrechte .....	16
1.5 Zusammenarbeit mit Externen .....	20
<b>2 Projektarbeit REIF .....</b>	<b>23</b>
2.1 Inhalte und Ergebnisse der Teilprojekte .....	23
2.1.1 Teilprojekt I – REIF-Ökosystem .....	23
2.1.2 Teilprojekt II – Verlustoptimierte Beschaffungs- und Verkaufsstrategie .....	38
2.1.3 Teilprojekt III – Koordination im Wertschöpfungsnetzwerk .....	53
2.1.4 Teilprojekt IV – Verschwendungsminimierende Produktionssysteme .....	64
2.1.5 Teilprojekt V – Bedarfsgerechte Produktionspläne .....	76
2.1.6 Teilprojekt VI – Zuverlässigkeit der Produktion .....	86
2.1.7 Teilprojekt VII – Rückverfolgbarkeit .....	101
2.1.8 Teilprojekt VIII – Qualitätsgeführte Verarbeitungsprozesse .....	102
2.2 Nutzen und Verwertbarkeit der Ergebnisse .....	113
2.3 Externe Fortschritte während der Projektlaufzeit .....	114
<b>3 Autoren .....</b>	<b>115</b>

## Abkürzungsverzeichnis

AP	Arbeitspaket
API	Application Programming Interface (Schnittstelle zur Programmierung von Anwendungen)
ASUM-DM	Analytics Solutions Unified Method for Data Mining/Predictive Analytics
BMWK	Bundesministerium für Wirtschaft und Klimaschutz
BPM	Business Process Modeling
CAI	Comprehensive Artificial Intelligence
CLSM	Confocal Laser Scanning Microscopy
COVID-19	Coronavirus disease 2019
CRISP-DM	Cross-Industry Standard for Data Mining
CT	Computertomographie
DGA	Data Governance Act
DLR	Deutsches Zentrum für Luft- und Raumfahrt
DLT	Distributed-Ledger Technologie
DMME	Data Mining Methodology for Engineering Applications
DQN	Deep Q Network
DRL	Deep Reinforcement Learning
DSGVO	Datenschutz-Grundverordnung
ESL	Electronic Shelf Label, elektronische Preisauszeichnung
FIFO	First in – First out
HKKL	Herkunftsklasse
HMI	Human Machine Interface
JRC	Joint Research Center
K3-Ware	Aus kommerziellen Gründen nicht für den menschlichen Verzehr bestimmte tierische Schlachterzeugnisse
KBE	Koloniebildende Einheiten
KDD	Knowledge Discovery in Databases
KI	Künstliche Intelligenz
KMU	Kleine und mittelständische Unternehmen
KNN	Künstliches Neuronales Netz
KPI	Key-Performance-Indicator, Leistungskennzahl
LSTM	Long Short-Term Memory
MANU-SL	Methodology for the application of machine learning in manufacturing processes
MAS	Multi-Agenten-System
MHD	Mindesthaltbarkeitsdatum
MPC-Regler	Model Predictive Control Regler
OAS	Open API Specification
OPC	Open Platform Communication
PC-Analyse	Hauptkomponenten-Analyse

PEF	Product Environment Footprint
PLC	Programmable Logic Controller, siehe SPS
PLS/PLSR	Partial Least Squares Regression, Regression der partiellen kleinsten Quadrate (statistisches Verfahren)
PM	Personenmonat
PoS	Point of Sale
PPO	Proximal Policy Optimization
PPO	Proximal Policy Optimization (Algorithmus)
REIF	Resource-efficient, Economic and Intelligent Foodchain
SCM	Strukturelles Kausalmodell
SHAP	SHapley Additive exPlanations
SPS	Speicherprogrammierbare Steuerung
SSTN	Shortest Setup Time Next
SVM	Support Vector Machine
TP	Teilprojekt
UV/VIS	Spektroskopisches Verfahren der optischen Molekülspektroskopie
VDMA	Verband Deutscher Maschinen- und Anlagenbau
WSN	Wertschöpfungsnetzwerk



## Abbildungsverzeichnis

Soweit nicht anders angegeben, stammen die Abbildungen aus der Projektarbeit der jeweiligen REIF-Projektpartner.

Lfd. Nr.	Titel
1	Projektstruktur
2	Projektübersicht
3	Projektzeitplan des REIF-Projektes
4	Technisches Konzept der REIF-Plattform
5	Startseite REIF-Marktplatz
6	REIF-Plattform API-Registrierung
7	REIF-Informationssseite
8	Schulungsunterlagen für PREDECY
9	Vergleich bestehender Anbieter für dynamisches Markdown Pricing
10	Die Werbefigur „Zorrero“
11	Systemelemente des Dynamic-Pricing-Algorithmus
12	Informations- und Schulungsunterlagen zum DYNAMICS-Algorithmus
13	Produktaufkleber für dynamisch preisreduzierte Produkte
14	PoS-Werbematerialien der Zorrero-Kampagne
15	Vergleich bisherige Rabatt-Sticker mit Werbematerialien aus der Kampagne
16	Abbruchgründe für den DYNAMICS-Algorithmus am Beispiel Eichenzell
17	Gründe für nicht identifizierte MHD-Artikel am Standort Eichenzell
18	Konzept für die Integration von Absatzprognose und Dynamic Pricing in die REIF-Plattform
19	Einordnung der untersuchten Modelle und Systeme
20	Betrachtungsräume für die Modell- und Systemauswahl
21	Bewertete Modell- und Systemauswahl
22	Elementarmodell eines Wertschöpfungsnetzwerks
23	Einordnung der Supply-Chain-Optimierung und der globalen Optimierung
24	Illustrative Übersicht der Datenflüsse (Quelle: TI.KI)
25	Elemente der Systemarchitektur aus Sicht der verschiedenen KI-bezogenen Aufgaben (Quelle: TI.KI)
26	Daten-Erzeugung und -Verwendung für die Teilnehmenden entlang der Wertschöpfungskette (Quelle: TI.KI)
27	KI-Modell-Entwicklung und -Bereitstellung (Quelle: TI.KI)
28	KI-Modell-Betrieb (Quelle: TI.KI)
29	Eco-Score-Beispiele aus diversen Branchen (Quelle: Lidl 2022)
30	Übersicht Eco-Score (Quelle: Lidl 2022)
31	Ablauf der Koordination
32	Materialflusssimulationsmodell
33	Visualisierung am Demonstrator
34	Schematische Darstellung des Datenflusses zur Nutzung des KI-Modells zur Prognose der Pumpfähigkeit
35	Systemarchitektur für die intelligente Anlagensteuerung

36	Beispiel einer Empfehlung für Maschinenparameter
37	Vergleich zwischen Vorhersage der Trockenmassedifferenz und dem tatsächlichen Differenzwert im Produkt
38	BPMN-Modell des Produktionsprozesses bei Hochland für das Produktsegment Schmelzkäse
39	Ablauf der Produktionsplanung und -steuerung
40	Identifizierte Ereignisse, welche ein Eingreifen durch den Mitarbeitenden erfordern
41	Kennzahlensystem zur operativen Produktionsperformance (Quelle: Zipfel et al. 2021)
42	Schematischer Aufbau des Multiagentensystems (Quelle: Theumer et al. 2022)
43	Durchschnittliche OPP in Abhängigkeit des untersuchten Simulationsszenarios
44	Umsetzung einer lokalen Erklärung durch die Bestimmung der Merkmalsrelevanz
45	Reinforcement Learning
46	Übersicht der App „Lieferungen“
47	App „Kundenaufträge“
48	Tabellarische Darstellung der App „Balancing Analyse“
49	Grafische Analyse in der App „Balancing Analyse“
50	Grafische Analyse Wasserfalldiagramm
51	Marktplatz der REIF-Plattform
52	Darstellung der Einordnung der Use Cases
53	Fluoreszenzspektren
54	Spektralbilder für Fleisch, Gefrierfleisch und Fett
55	Mischer vom Typ IVM150-V-DD-DM-N2 (Quelle: Inotec/Handtmann)
56	Verpackte Proben und Messaufbau für die at-line Spektroskopie
57	Score-Plot der Hauptkomponentenanalyse für Lauf 1
58	Emissionsspektren der Anregungswellenlängen bei 415 nm
59	Partial-Least-Square-Regression für Lauf 7
60	PCA Lauf 3 gegen Lauf 4
61	Auswertung der Hyperspektraldaten mit Vorhersage und Histogramm-Darstellung
62	Auswertung von Lauf 3 nach der Histogramm-Methode
63	Auswertung von Lauf 4 nach der Histogramm-Methode
64	Manuell bereinigte Daten der Mischmaschine
65	Versuchscockpit 1
66	Schematische Darstellung des Backprozesses und der qualitätsbestimmenden Zusammenhänge
67	Schematische Darstellung des Datennetzwerkes
68	Schematische Darstellung der MANU-ML
69	Darstellung des erweiterten Dashboards von Industrial Analytics mit Anlagenstruktur, Datendarstellung und Events
70	A) Schematische Darstellung der Pitch-Catch-Methode, B) Ultraschall-Sensoranordnung am Messrohr zur Inline-Bestimmung der Strukturparameter in Biskuitmassen
71	A) Zusammenhang zwischen Mischkopfdrehzahl, Mischkopfdruck und Dichte beim Aufschlagen von Biskuitmassen mittels Rotor-Stator-Mischeinheit, B) Gegenüberstellung der vorhergesagten Dichte per Ultraschall und maschinellem Lernen sowie Referenzmessungen
72	Schaumstrukturindex (Online-Messung) der Biskuitmassen über die Prozesszeit im Vergleich zum Qualitätsparameter der resultierenden ausgebackenen Produkte

## Tabellenverzeichnis

Lfd. Nr.	Titel
1	Zusammenarbeit mit anderen Stellen oder außerhalb des Forschungsprojektes
2	Übersicht über die Zusammenhänge von Governance-Mechanismen und deren Auswirkungen
3	Governance-Konzept
4	Beispielhafte Berechnung des Eco-Scores für Hochland-Eckartikel
5	Während der Durchführung des Vorhabens bekannt gewordener Fortschritt auf diesem Gebiet bei anderen Stellen

# 1 Projektüberblick REIF

## 1.1 Aufgaben und Ziele

Das Ziel des REIF-Projekts ist die drastische Reduzierung der Lebensmittelverschwendung durch den Einsatz von Methoden der Künstlichen Intelligenz (KI), wobei die Erarbeitung ganzheitlicher Optimierungsstrategien über mehrere Wertschöpfungsstufen und -partner hinweg besonderer Beachtung zuteilwurde. Diesem großen Ziel sollte durch die Betrachtung zweier Teilaspekte – der Minimierung von Überproduktion und der Vermeidung von Ausschuss – Rechnung getragen werden.

Konkrete Aufgaben, die sich aus der Zielsetzung des Projekts ergaben, sind zum einen eine Verbesserung des Daten- und Informationsaustausches entlang der Wertschöpfungskette sowie eine genauere Prognose der Konsumentennachfrage mit Hilfe Künstlicher Intelligenz. Eine verbesserte Vernetzung der Wertschöpfungsketten und genauere Nachfrageprognosen adressieren die Minimierung von Überproduktion, da diese zur Reduzierung der Auswirkungen des Bullwhip-Effekts auf die Wertschöpfungskette führen. Aus dem Ziel der Vermeidung von Ausschuss in der Lebensmittelindustrie ergaben sich je nach betrachtetem Anwendungsfall verschiedenste Aufgaben. Diese können unter der Befähigung der Produktionsinfrastruktur zur adäquaten Reaktion auf schwankende Nachfrage und Rohstoffqualitäten unter Berücksichtigung wirtschaftlicher Zielgrößen zusammengefasst werden. Darüber hinaus sollten in allen betrachteten Fällen übertragbare Lösungskonzepte entwickelt werden, um eine schnelle Adaption auf weitere Bereiche außerhalb des Projekts zu ermöglichen.

Eine zentrale Rolle im Projekt stellte die Verbesserung des Daten- und Informationsaustausches entlang der Wertschöpfungsketten dar. Um diese Aufgabe zu erfüllen, war zunächst eine Plattform für den Datenaustausch und die Bereitstellung verschiedener KI-basierter Dienste angedacht. Infolge sich während der Projektlaufzeit anbahnender gesetzlicher Verschiebungen musste von dieser Idee Abstand genommen werden, viel mehr erfolgte die Entwicklung eines Marktplatzes für den Handel von KI-basierten Diensten.

Aufgrund der Zusammensetzung des Projektkonsortiums verschiedener Partner aus der Lebensmittelindustrie, von KI-Start-ups, Maschinen und Anlagenbauern, Forschungseinrichtungen sowie einem führenden Plattformanbieter ergaben sich drei Stränge, in denen die KI-basierte Befähigung der Produktionsinfrastruktur zur Reaktion auf sich verändernde Eingangsgrößen entwickelt und erprobt wurden:

- Molkereierzeugnisse
- Fleischverarbeitung
- Backwarenherstellung

Die Entwicklung genauerer Nachfrageprognosen erfolgte im Lebensmitteleinzelhandel. Abbildung 1 zeigt den Aufbau des Projektes.

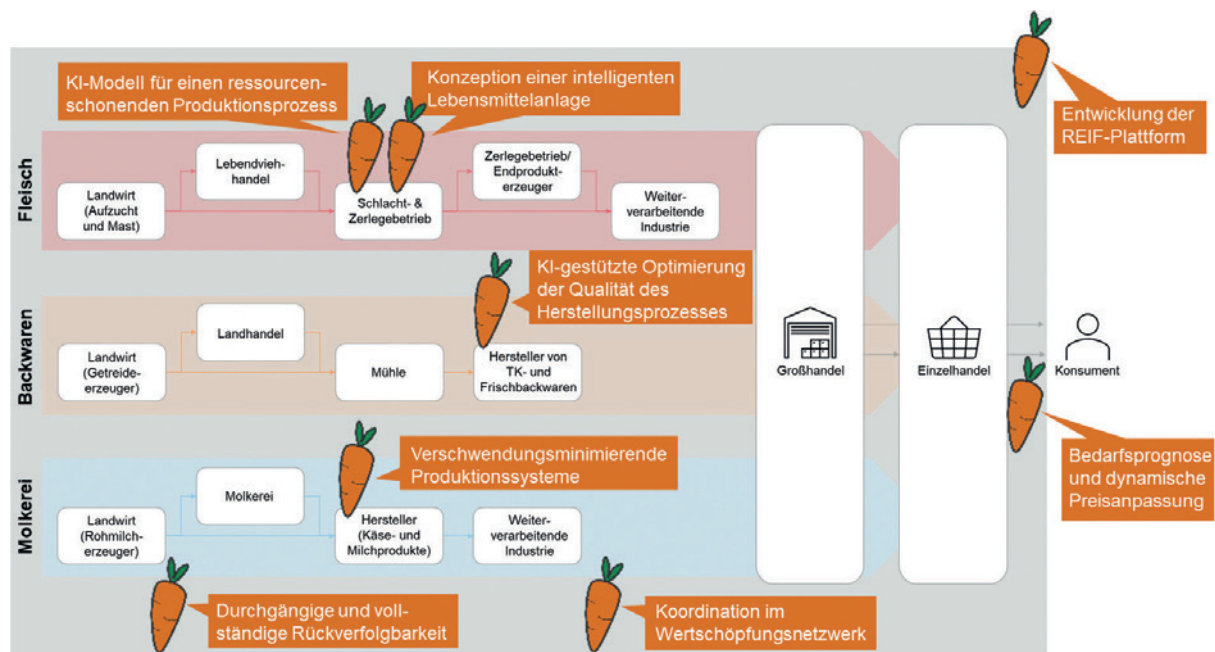


Abbildung 1: Projektstruktur (eigene Darstellung)

## 1.2 Voraussetzungen für das Projekt

Ziel des Innovationswettbewerbs „Künstliche Intelligenz als Treiber für volkswirtschaftlich relevante Ökosysteme“ ist die Entwicklung von Konzepten für die Anwendung Künstlicher Intelligenz und deren Umsetzung durch innovative Ökosysteme in volkswirtschaftlich bedeutsamen Wirtschaftsbereichen. Ferner soll der Mittelstand nachhaltig durch die entwickelten KI-Lösungen profitieren (BMWK 2023).

### 1.2.1 Volkswirtschaftlich bedeutsame Wirtschaftsbereiche

Mit rund 600.000 Beschäftigten stellt die Lebensmittelindustrie den viertgrößten deutschen Industriezweig dar. Darüber hinaus sind ca. 90 Prozent der über 6000 lebensmittelverarbeitenden Betriebe (ca. 1/7 aller deutschen Industriebetriebe) als kleine oder mittelständische Unternehmen (KMU) zu kategorisieren. Die im Rahmen des REIF-Projekts betrachteten Stränge der Lebensmittelindustrien (Molkerei-erzeugnisse, Fleischerzeugnisse und Backwaren) sind für ca. 50 Prozent des Umsatzes der deutschen Lebensmittelindustrie verantwortlich und bilden ca. 55 Prozent der Beschäftigten dieser Branche ab (Bundesverband der deutschen Ernährungsindustrie 2019). Der Lebensmitteleinzelhandel ist mit einem Umsatz und Wertschöpfungsanteil von über 30 Prozent der wichtigste Teilbereich des deutschen Einzelhandels (IFH Institut für Handelsforschung GmbH 2018). Die hohen prozentualen Beteiligungen an den für die deutsche Wirtschaft bedeutsamen Zweigen der Lebensmittelindustrie bzw. des Einzelhandels bedeuten, dass die Verschwendung von Lebensmitteln speziell in diesen Bereichen mit erheblichen finanziellen Einbußen für die gesamte Volkswirtschaft einhergeht. Darüber hinaus führt Verschwendung in diesen Bereichen zu hohen Rohstoff-, Produktions- und ggf. zusätzlichen Entsorgungskosten.

Neben der produzierenden Lebensmittelindustrie zählen mittelständisch geprägte deutsche Maschinen- und Anlagenbauer zu den weltweit führenden Unternehmen. Bisweilen beliefern sie weltweit Kunden und generieren ihre Umsätze durch große Exportanteile. Im Jahr 2017 erzielten ca. 5300 deutsche Unternehmen, die Maschinen für die Nahrungsmittel- und Getränkeindustrie herstellen, mit ca. 470.000 Beschäftigten einen Umsatz von ca. 144 Mrd. Euro (VDMA Volkswirtschaft und Statistik). Des Weiteren ergeben sich durch die Entwicklung und Anwendung von KI Chancen für bestehende und neue Unternehmen aus dem IT-Bereich, neue Märkte zu erschließen.

Die im Rahmen des REIF-Projekts erarbeiteten Lösungen können zum einen zur wirtschaftlichen Stärkung der genannten Bereiche in der Lebensmittelwertschöpfung beitragen und zum anderen der Sicherung von Arbeitsplätzen und zur Entlastung der Verbraucher dienen. Gleichzeitig ermöglicht der Einsatz von KI-Methoden, den ökologischen Wandel zu beschleunigen.

## 1.2.2 Anwendung Künstlicher Intelligenz

Die prozessbedingten Abhängigkeiten in Unternehmen der Lebensmittelindustrie in Kombination mit den vielfältigen Lieferverbindungen zwischen den interagierenden Unternehmen führen zu einer sehr hohen Komplexität in den Wertschöpfungsketten der Lebensmittelbranche. Dadurch ist keine signifikante Reduzierung von Lebensmittelverschwendung durch den Einsatz herkömmlicher Technologien möglich. Der Einsatz von KI-Methoden jedoch bietet die Möglichkeit, durch die Nutzung – z. B. im Rahmen der gesetzlich geforderten lückenlosen Rückverfolgbarkeit generierten – großer Datenmengen, Überproduktion und Ausschuss zu verringern. Aufgrund des vielfältigen Produktportfolios und der damit verbundenen Vielzahl von industriellen Fertigungs- und Vertriebssystemen bietet die Lebensmittelindustrie für KI spezialisierte Unternehmen die Möglichkeit, eine große Anzahl unterschiedlicher – für den Einsatz KI prädestinierter – Prozesse kennenzulernen und Erfahrung im Bereich des gezielten und effektiven Einsatzes von KI-Technologien zu sammeln. Gleichzeitig können die meist mittelständisch geprägten Unternehmen der Lebensmittelbranche an die Zukunftstechnologie KI herangeführt werden.

## 1.2.3 Schaffung eines innovativen und Erfolg versprechenden Ökosystems

Die in REIF entwickelte Plattform soll das technische Fundament für die Datenbündelung und Datenbereitstellung für Algorithmen und Dienste darstellen. Darüber hinaus soll die Plattform als Marktplatz für die in REIF entwickelten Dienste fungieren. Die Bereitstellung und Bündelung von Daten wurde im Rahmen des Projekts aufgrund des zeitnahen Inkrafttretens des Data Governance Acts nicht weiterverfolgt, da dieser die Kombination aus Datenbereitstellung/-bündelung und Marktplatz für Services untersagt. Durch den Marktplatz ermöglicht sie die Nutzung von Netzwerk-, Skalen- und Synergieeffekten.

## 1.2.4 Wichtige Begleitumstände

Neben den grundlegenden Voraussetzungen, welche bisher in diesem Kapitel betrachtet wurden, traten während der Projektlaufzeit verschiedene Begleitumstände auf. Diese führten zu Verzögerungen in der Projektarbeit bzw. zu Anpassungen der Zielsetzung. Die drei wesentlichen hier zu nennenden Begleitumstände sind:

- **COVID-19-Pandemie sowie die pandemiebedingten Effekte**
  - Kein bzw. nur eingeschränkter Zugang zu Ressourcen und Anlagen vieler Projektpartner.
  - Arbeits- und Projekttreffen konnten nur in begrenztem Umfang in Präsenz durchgeführt werden.
  - Temporäre Ausfälle von Personalressourcen und Verzögerungen in der Beschaffung aufgrund von Lieferkettenproblemen.
  - Durch die Verknüpfung und damit einhergehende Abhängigkeit verschiedener Teilprojekte untereinander pflanzten sich coronabedingte Verzögerungen über die Teilprojektgrenzen hinweg fort und führten so an mehreren Stellen zu weiteren Verzögerungen.
- **Data Governance Act und Data Act**
  - Zu Beginn des Projektes gab es weder einen Stand von Gesetzgebung im Datenrecht noch folgerichtig Literatur hierzu. Lediglich im Bereich des Datenschutzrechts (DSGVO) konnte auf Literatur zurückgegriffen werden. Konzepte für eine (Legal) Governance für Plattformen bestanden nicht.
  - Abweichung vom ursprünglichen Konzept der Plattform mit dem Angebot von Services und gleichzeitigem Datenteilen, da dies rechtlich nach dem Data Governance Act nicht mehr auf einer Plattform zulässig ist.
  - Zusätzliche Arbeiten aufgrund der neuen EU-Gesetzesvorhaben (Data Governance Act und Data Act). Diese Gesetzesvorhaben haben sowohl direkte Auswirkungen auf die Governance als auch auf das Geschäfts- und Betreibermodell. So ist eine Abweichung vom ursprünglichen Konzept der Plattform mit dem Angebot von Services und gleichzeitigem Datenteilen, da dies rechtlich nach dem Data Governance Act nicht mehr auf einer Plattform zulässig ist, vonnöten.
  - Da permanente Veränderungen der Gesetzestexte stattgefunden haben, mussten die daraus resul-

tierenden Anforderungen für eine nachhaltige Nutzung der Plattform laufend mit den Ausarbeitungen in Einklang gebracht werden.

- **Cyberattacken bei mehreren Konsortialpartnern**

- Cyberattacken bei verschiedenen Partnern führten während der Projektlaufzeit immer wieder zur eingeschränkten Verfügbarkeit verschiedener Ressourcen, insbesondere personeller Ressourcen.

### 1.3 Struktur, Planung und Ablauf des Projektes

Zur Adressierung der Aufgaben und Ziele des REIF-Projekts erfolgte eine Untergliederung in acht Teilprojekte (Abbildung 2). Die Untergliederung in diese acht Teilprojekte gewährleistete eine effektive Zusammenarbeit sowie die Beherrschbarkeit der hohen Komplexität des Forschungsprojekts.

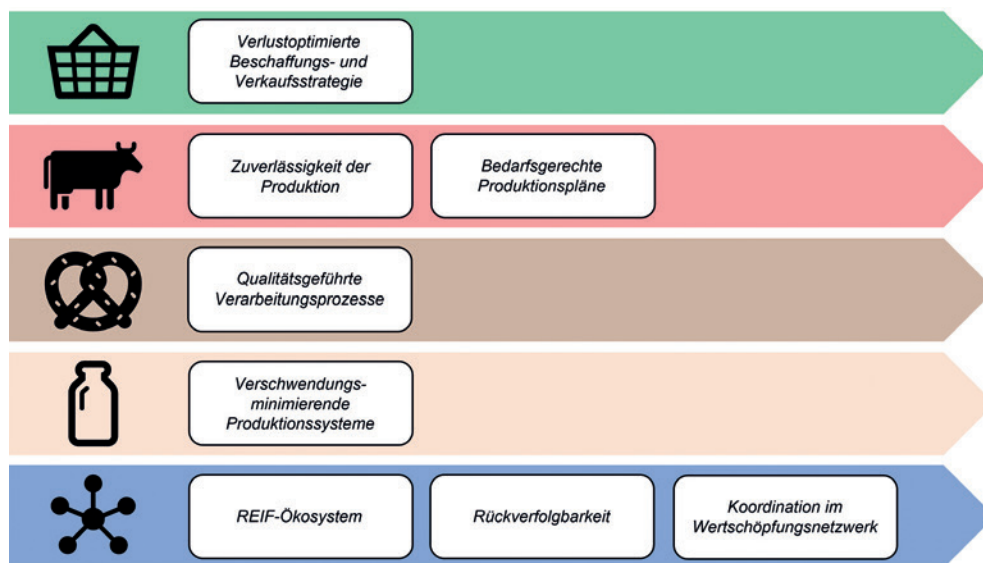


Abbildung 2: Projektübersicht (eigene Darstellung)

Wie Abbildung 2 zeigt, können die acht Teilprojekte jeweils verschiedenen Aufgabenschwerpunkten bzw. Anwendungsbereichen zugeordnet werden. Zu den wertschöpfungskettenübergreifenden Teilprojekten zählen das „REIF-Ökosystem“, die „Rückverfolgbarkeit“ sowie die „Koordination im Wertschöpfungsnetzwerk“. In den Teilprojekten „Verlustoptimierte Beschaffungs- und Verkaufsstrategie“ (Lebensmitteleinzelhandel), „Zuverlässigkeit in der Produktion“, „Bedarfsgerechte Produktionspläne“ (beide Fleischherstellung), „Qualitätsgeführte Verarbeitungsprozesse“ (Backwarenherstellung) und „Verschwendungsminimierende Produktionssysteme“ (Molkereierzeugnisse) wurden anwendungsfallspezifische Lösungen entwickelt.

Die Realisierung der in REIF angestrebten ganzheitlichen Betrachtung der Lebensmittelverschwendung erfolgte durch die Schaffung eines KI-Ökosystems zur Integration aller Stakeholder der verschiedenen Wertschöpfungsstufen im Teilprojekt „REIF-Ökosystem“. Den Kern des REIF-Ökosystems bildet die REIF-Plattform als zentrale Instanz innerhalb des Ökosystems. Bei der Entwicklung der REIF-Plattform wurden neben der Interaktion der Stakeholder (Governance), dem Datenaustausch unter den Wertschöpfungspartnern, der Datenverfügbarkeit, den Standards sowie der Datenübertragung auch der Datenschutz sowie das Datenrecht berücksichtigt.

Im Rahmen des Teilprojekts „Verlustoptimierte Beschaffungs- und Verkaufsstrategie“ erfolgte die Entwicklung einer KI-basierten Bedarfsprognose sowie einer dynamischen Preisanpassung zur gezielten Nachfragesteuerung bei sich anbahnenden Lebensmittelverlusten durch das Überschreiten des Mindesthaltbarkeitsdatums (MHD). Die erstellten Bedarfsprognosen stellten die Eingangsgrößen für das Teilprojekt „Koordination im Wertschöpfungsnetzwerk“ dar. Eine KI-gestützte unternehmensübergreifende Koordinationsinstanz ermöglicht die optimale netzwerkweite Synchronisierung von Angebot und Nachfrage.

Das Teilprojekt „Verschwendungsminimierende Produktionssysteme“ adressiert die Vermeidung von

Ausschuss in der Molkereiindustrie, erarbeitete unter anderem eine selbstoptimierende Anlage sowie eine durch KI-Methoden optimierte Produktionssteuerung.

In der fleischverarbeitenden Industrie stand im Fokus des Teilprojekts „Zuverlässigkeit der Produktion“ die Befähigung einer Anlage zur Prognose der Mindesthaltbarkeit von Fleischerzeugnissen und die Entwicklung hierfür benötigter Softsensoren. Das Teilprojekt „Bedarfsgerechte Produktionspläne“ hingegen befasste sich mit einer ressourcenschonenden Produktionsplanung durch den Einsatz von KI-Algorithmen zur Berücksichtigung schwankender Produktnachfrage bei der Anliefersteuerung sowie der Zerlegungsplanung der Tiere. Ebenfalls in der Fleischindustrie angesiedelt war das Teilprojekt „Rückverfolgbarkeit“, das KI-Verfahren zur Verbesserung der Rückverfolgbarkeit von Waren über die gesamte Wertschöpfungskette hinweg entwickelte.

Im Rahmen des Teilprojekts „Qualitätsgeführte Verarbeitungsprozesse“ wurde ein KI-Verfahren zur Realisierung eines qualitätsgeführten Verarbeitungsprozesses in der Backwarenindustrie entwickelt. Insbesondere wurden hierbei die enormen Anfahrverluste bei Sortimentswechseln auf den Produktionslinien adressiert.

Die ursprüngliche Planung sah eine 36-monatige Projektlaufzeit in den Jahren 2020 bis 2023 vor. Durch die parallel zum Projektstart beginnende Covid-19-Pandemie musste eine kostenneutrale Verlängerung des Forschungsprojekts beantragt werden. Speziell zu Beginn der Pandemie konnten grundlegende Arbeiten wie z. B. Vor-Ort-Begehungen und Analysen des Status quo aufgrund der restriktiven Regelungen sowohl von Seiten des Gesetzgebers als auch der Projektpartner nicht durchgeführt werden. Weiter mussten sich die neuen Wege der Zusammenarbeit über Kommunikations- bzw. Kollaborationssoftwares etablieren. Schlussendlich betrug die Projektlaufzeit von REIF 40 Monate. Abbildung 3 stellt den Projektlauf des REIF-Projekts als Zeitstrahlen der Teilprojekte bzw. deren Arbeitspakete über die gesamte Projektlaufzeit dar.

		2020				2021				2022				2023	
		1	2	3	4	1	2	3	4	1	2	3	4	1	2
<b>TP I - REIF-Ökosystem</b>															
AP I.1	Konzeption und entwicklung der REIF-Plattform	03/2020 - 06/2023													
AP I.2	Governance	03/2020 - 06/2023													
AP I.3	Expertenforum Künstliche Intelligenz	03/2020 - 06/2023													
AP I.4	Datenverfügbarkeit & Standards	03/2020 - 12/2021													
AP I.5	Datenübertragung	03/2020 - 06/2023													
AP I.6	Datenschutz & Datenrecht	07/2020 - 06/2023													
<b>TP II - Verlustoptimierte Beschaffungs- und Verkaufsstrategie</b>															
AP II.1	Anforderungsbasierte Erprobung KI-basierter Prognosen	03/2020 - 06/2023													
AP II.2	Aufbau spezifischer Prognosemodule	03/2020 - 05/2023													
AP II.3	Etablierung der Marktreife	03/2021 - 03/2023													
AP II.4	Integration und Business Transformation	06/2022 - 03/2023													
<b>TP III - Koordination im Wertschöpfungsnetzwerk</b>															
AP III.1	Analyse des Status Quo	03/2020 - 12/2020													
AP III.2	Konzeptionierung der Koordination	03/2020 - 12/2022													
AP III.3	Validiertes Gesamtsystem	01/2021 - 03/2023													
AP III.4	Validierung anhand von Use Cases	06/2022 - 06/2023													
<b>TP IV - Verschwendungsminimierende Produktionssysteme</b>															
AP IV.1	Softsensoren	03/2020 - 06/2023													
AP IV.2	Selbstoptimierende Anlage	03/2020 - 06/2023													
AP IV.3	Intelligenter Mixer	10/2020 - 06/2023													
AP IV.4	Optimierte Produktionssteuerung	03/2020 - 06/2023													
<b>TP V - Bedarfsgerechte Produktionspläne</b>															
AP V.1	Analyse des aktuellen Produktionsplanungsprozesses	03/2020 - 09/2020													
AP V.2	Konzeptionierung eines ressourcenschonenden Produktionsplanungsprozesses	06/2020 - 12/2021													
AP V.3	Aufbau eines KI-Prototypen	12/2020 - 06/2023													
AP V.4	Qualitätssicherung des KI-Prototypen	09/2020 - 06/2023													
<b>TP VI - Zuverlässigkeit der Produktion</b>															
AP VI.1	Anforderungsanalyse	04/2020 - 06/2020													
AP VI.2	Analyse bestehender Lebensmittelanlagen	07/2020 - 06/2022													
AP VI.3	Softsensorik konzipieren	07/2021 - 12/2022													
AP VI.4	Konzeption der intelligenten Lebensmittelanlage	01/2023 - 03/2023													
AP VI.5	Evaluation und Übertragbarkeit	04/2023 - 06/2023													
<b>TP VII - Rückverfolgbarkeit</b>															
AP VII.1	Analyse der Ist-Situation der Lieferkettenprozesse	03/2020 - 06/2021													
AP VII.2	Definition spezifischer Soll-Prozesse	01/2021 - 12/2021													
AP VII.3	Konzeptionierung der elektronischen End-to-End-Rückverfolgbarkeit	07/2021 - 03/2022													
AP VII.4	Erprobung und Validierung im Use-Case	01/2022 - 01/2022													
<b>TP VIII - Qualitätsgeführte Verarbeitungsprozesse</b>															
AP VIII.1	Umsetzung in der Backwarenproduktion	03/2020 - 06/2023													
AP VIII.2	Etablierung technischer Essentials	03/2020 - 09/2022													
AP VIII.3	Entwicklung und Implementierung von KI-Ansätzen	04/2020 - 06/2023													

Abbildung 3: Projektzeitplan des REIF-Projekts (eigene Darstellung)



## 1.4 Wissenschaftlicher und technischer Hintergrund

### 1.4.1 Für REIF genutzte Konstruktionen, Verfahren und Schutzrechte

#### **TP I REIF-Ökosystem:**

Zur Entwicklung wurde auf klassische Verfahren des Software Engineerings zurückgegriffen wie strukturierte Arbeitsgruppen (partnerspezifische als auch konsortiumübergreifend wie mehrere Big Picture Workshops mit der Begleitforschung), Prozessaufnahme und Dokumentation mittels Business Process Modeling (BPM) und einer konsolidierten Anforderungsaufnahme als zentrales Dokument, welches über zwei Iterationen aktualisiert und weiterentwickelt wurde.

Zwischenergebnisse wie die Anforderungsdokumentation oder der erste Prototyp wurden dem Gesamtkonsortium vorgestellt, diskutiert und aktualisiert.

Die Entwicklung erfolgte dann auf Basis eines abgeleiteten Pflichtenheftes und digitalen Aufgabenboards der beteiligten Entwicklerteams der Partner im Teilprojekt I.

Die Basis zur Entwicklung der Plattform stellten Webmethods API-Gateway der Software AG sowie als Marktplatzbasis das API-Portal der Software AG, welche im Rahmen des Projektes sukzessive um prototypische Erweiterungen auf Basis der erhobenen Anforderungen modifiziert wurden. Beides sind Produkte der Software AG. Für den Marktplatz wurde letztlich ein USP (Universal Service Platform) Marktplatz-Framework von Software AG Research entwickelt, welches die Basis zur Umsetzung des REIF-Marktplatzes und die Schnittstelle zum API-Gateway darstellt. Alle relevanten Software-Komponenten der beiden Plattformen sind durch Patente des Unternehmens geschützt.

Die ARXUM GmbH lieferte die Grundlage für die Zugriffskontrolle und die zugehörige Integritätsprüfung über das aufgesetzte EOSIO-Blockchain-Netzwerk. Jede Änderung wird somit auf der Blockchain als Transaktion dokumentiert und ist unumkehrbar. ARXUM entwickelte verschiedene Performer-API-Endpunkte, die in das Webmethods API-Gateway der Software AG integriert wurden, um mit der Blockchain zu kommunizieren.

Die Integration wurde jeweils partnerspezifisch bilateral getestet und evaluiert.

#### **TP II Verlustoptimierende Beschaffungs- und Verkaufsstrategie:**

Für die Arbeiten wurde das bestehende Prognosesystem PREDECY der Spicetech GmbH genutzt und weiterentwickelt.

Zur Bestimmung ökologischer Fußabdrücke kamen zwei Verfahren zum Einsatz: „Calculator for impacts for food waste prevention actions“, das vom Joint Research Center (JRC) von der Europäischen Kommission entwickelt wurde, und „Product Environment Footprint“ (PEF), das ebenso von der Europäischen Kommission entwickelt wurde.

#### **TP III Koordination im Wertschöpfungsnetzwerk:**

Im TP III mussten sehr viele Inhalte selbst erarbeitet werden.

Zur Nachhaltigkeitsbewertung wurde der Eco-Score verwendet. Dieses in Frankreich entwickelte Konzept bewertet jede Produktkategorie anhand von ADEME- und INRAE-Daten der Agribalyse-Umweltdatenbank entsprechend einer Lebenszyklusanalyse (LCA) der Produkte.

#### **TP IV Verschwendungsminimierende Produktionssysteme:**

Um die in REIF angestrebten Ziele erreichen zu können, ist eine Kombination unterschiedlicher Domänen notwendig. Übergeordnetes Ziel ist die Reduktion der Verschwendung in der Lebensmittelindustrie, wozu bereits diverse Arbeiten durchgeführt worden sind. Für einen größtmöglichen Effekt soll zudem eine über Unternehmensgrenzen hinausgehende Kommunikation innerhalb eines Wertschöpfungsnetzwerks umgesetzt und zur ganzheitlichen Optimierung genutzt werden. Die großen Erfolge der vergangenen Jahre im Rahmen der KI und die hierbei entwickelten Technologien stellen wesentliche Befähiger zu dieser Optimierung dar. So kann der Verschwendung durch Reduktion von Ausschuss entgegen-

gewirkt werden, indem neuste Entwicklungen im Rahmen der KI zur Prozessoptimierung eingesetzt werden. Auch ermöglichen KI-Ansätze zur Verbesserung der Prognosegenauigkeit eine wesentliche Reduktion von Überproduktion, welche durch einen geeigneten Informationsaustausch im Rahmen der angestrebten REIF-Plattform stark skalierbar ist. Im Folgenden werden bisherige Arbeiten im Rahmen dieser vier Domänen näher betrachtet.

- **Ansätze zur Reduktion der Lebensmittelverschwendung:** Um nachhaltige Entwicklungen im Sinne der Agenda 2030 zu adressieren, wurden sowohl europaweite als auch nationale Projekte und Aktionen ins Leben gerufen. Bisher ins Leben gerufene Projekte zielen überwiegend auf die Reduktion der Lebensmittelverschwendung ab, welche bei den Endverbrauchern entstehen. So existieren Customer-Education-Projekte im Rahmen der Strategie zur Reduzierung der Lebensmittelverschwendung des BMWi und die damit verbundene Aufklärung der Konsumenten über bspw. Möglichkeiten der vollständigen Verwertung von Lebensmitteln. Einzelne Projekte adressieren auch die Lebensmittelproduzenten, bspw. das Projekt Food Tracks, welches durch die Analyse von Retouren die Überproduktion bei Filialbäckern reduzieren möchte. Im EU-geförderten Projekt REFRESH wurden zahlreiche Untersuchungen durchgeführt und Faktoren analysiert, die zu Ressourcenverschwendung führen. Die entwickelten Lösungsansätze zielen vor allem auf die Reduktion von Treibhausgasemissionen und Energie ab und beziehen sich stark auf die Endverbraucher und die Formulierung von normativen/regulativen Empfehlungen. Bei SavingFood sollen verzehr-, aber nicht mehr verkaufsfähige Lebensmittel durch den Einsatz von Informations- und Kommunikationstechnik umverteilt werden, damit sie noch durch gemeinnützige Organisationen genutzt werden. Das Projekt AgroCycle untersucht Abfallströme in der Landwirtschaft und möchte Methoden entwickeln, um Abfallprodukte von geringer Wertschöpfung in hochwertige Produkte umzuwandeln. Durch dieses Upcycling soll die Verwertung von Abfallströmen optimiert werden.
- **Entwicklung von Wertschöpfungsnetzwerken (WSN):** Die Internationalisierung der Wertschöpfung durch die schrittweise Expansion von Unternehmen, ggf. über Landesgrenzen hinweg, sowie die Zusammenarbeit in Netzwerken ist ein seit Jahrhunderten erfolgreicher Prozess (Sager 2019). Die rasante Entwicklung des Welthandels in den letzten Jahrzehnten sowie der Direktinvestitionen im Ausland zeugen von einer erheblichen Beschleunigung dieses Prozesses (Rudberg und Martin West 2008). Wertschöpfungsnetzwerke bilden entsprechend das Rückgrat des wirtschaftlichen Erfolgs der im WSN beteiligten Unternehmen, wie beispielsweise den produzierenden Unternehmen (Roland Berger). Ausgehend von ursprünglich lokalen WSN haben sich im Laufe der Zeit WSN entwickelt, die durch vielfältige Liefer- und Leistungsverflechtungen gekennzeichnet sind (Sager 2019; Jacob und Strube 2008; Möller et al. 2011). Ermöglicht wurde diese Veränderung u. a. durch stark sinkende Kommunikationskosten, die Beseitigung von Handelshemmnissen, die Verfügbarkeit von Wissen und Technologien sowie die preiswerte Mobilität von Mitarbeitern und Waren (Friedeli et al. 2014; Jacob und Strube 2008; Möller et al. 2011). Wertschöpfungsnetzwerke ermöglichen unter diesen Voraussetzungen die Realisierung der größtmöglichen Effizienz von Produktion und Märkten (Möller et al. 2011). Diesen Vorteilen steht ein historisches Wachstum heutiger WSN gegenüber, welche nur selten das Ergebnis einer zielgerichteten Planung sind (Jacob 2006). Aufgrund der historisch entstandenen losen Zusammenarbeit von Partnern eines Wertschöpfungsnetzwerkes sowie durch die isolierte Betrachtung von einzelnen Stufen können die Potenziale von Wertschöpfungsnetzwerken derzeit nicht vollständig ausgeschöpft werden (Sager 2019; Thomas 2013). Deshalb gilt es einerseits die Netzwerkkonfiguration, d. h. den strukturellen Aufbau der Aktivitäten entlang der Wertschöpfungskette (Thomas 2013; Friedli und Schuh 2012), an die aktuellen Randbedingungen und Zustände der einzelnen Systemelemente anzupassen. Andererseits müssen die einzelnen Aktivitäten der verteilten Standorte des Wertschöpfungsnetzwerkes aufeinander abgestimmt werden. Dies wird als Netzwerkkoordination bezeichnet (Thomas 2013) und verlangt zur Beherrschung der steigenden Komplexität innovative Ansätze, die über die bestehenden Planungs- und Steuerungsmechanismen hinausgehen. Eine Besonderheit der Wertschöpfung in der Lebensmittelindustrie besteht im Transport und der Verarbeitung von organischem Material mit begrenzter Haltbarkeit sowie Rohstoffen und Produkten von hoher Heterogenität und Variabilität. Des Weiteren spielen Umweltbedingungen wie das Wetter eine wichtige

Rolle. Diese Informationen müssen in einer effizienten Wertschöpfungskette für alle Partner in einer vor Manipulation sicheren Umgebung digital zur Verfügung stehen. Einen ersten kostenpflichtigen Ansatz stellt der IBM Food Trust dar. Der Food Trust basiert auf einer sehr rechen- und energieintensiven Blockchain (IBM 2019). Aufgrund des monatlichen Beitrags ist es kleinen und mittelständischen Unternehmen nicht möglich, an dem Konstrukt teilzunehmen, und die hohen Energiekosten (Gatteschi et al. 2018) stehen dem Ziel der Ressourceneffizienz konträr gegenüber. Trotz der Nachteile werden ähnliche Ansätze auch in China verfolgt (Tian 2016). Ziel des Projekts EVAREST ist die Entwicklung und Verwertung von Datenprodukten im Ökosystem der Lebensmittelproduktion durch Smart Services. Basis sollen dabei eine über Unternehmensgrenzen hinweg angelegte offene, technische Datenplattform sowie ökonomische und rechtliche Nutzungskonzepte sein. Der Ansatz zielt darauf ab, die Daten der einzelnen Plattformteilnehmenden als eigenständige Wirtschaftsgüter zu vermarkten.

- **KI-Ansätze zur Optimierung von Prozessabläufen:** Bei bestärkendem Lernen besteht das lernende System aus einem sogenannten Agenten, welcher mit der Umgebung interagiert und dabei selbstständig eine Strategie lernt, um eine vorgegebene Aufgabe durchzuführen. Die Definition der Aufgabe erfolgt durch eine Belohnungsfunktion, welche eine numerische Bewertung der Zielerreichung vornimmt und vom Agenten zu maximieren versucht wird (Sutton und Barto 2018). Dieses Lernverhalten ist dem menschlichen Erlernen intuitiver Entscheidungsfindung nachempfunden und unterscheidet sich von Optimierern in einem höheren Bedarf an Daten und einer schnellen Entscheidungsfindung hinsichtlich auszuführender Aktionen in der Betriebsphase (Geffner 2018). (Breyer et al. 2018) wenden Reinforcement Learning in der Robotik an, um eine Vielzahl unterschiedlicher Geometrien handhaben zu können. Die Online-Planung erfolgt auf Basis einer Tiefenbild-Kamera, welche eine dreidimensionale Ansicht der Objekte ermöglicht und dem Agenten zur Wahrnehmung der Umgebung dient. Ein weiterer Einsatz in der Robotik erfolgt durch (Zeng et al. 2018), wobei durch Kombination von Verschieben und Greifen die Handhabung eng anliegender Objekte ohne manuelles Eingreifen ermöglicht wird. Neben Ansätzen in der Robotik und in Computerspielen (Mnih et al. 2015) wird bestärkendes Lernen auch in der Produktionsplanung eingesetzt. So wendet (Waschneck et al. 2018) Deep Q Network (DQN) auf die Produktionsplanung an. Die kooperativen DQN-Agenten, die neuronale Netze nutzen, werden anhand benutzerdefinierter Ziele trainiert. Das System wird anhand einer Fabriksimulation einer Produktionslinie in der Halbleiterindustrie validiert. Während im bestärkenden Lernen eine direkte Ausführung von Aktionen gelernt wird, können auch andere Ansätze der KI zur Optimierung von Prozessabläufen genutzt werden. (Schmid 2018) wendet künstliche neuronale Netze zur Modellierung der Druckqualität von Rollenoffset-Druckmaschinen an, wodurch eine Regelung der Volltondichte in der Hochlaufphase der Maschine ermöglicht wird und die hierbei entstehende Makulatur um bis zu 85 Prozent reduziert werden kann. (Gaafar und Choueiki 2000) berechnen die optimale Losgröße in der Produktion, mit der die Bestell- und Transportkosten minimiert werden können. Dafür nutzen sie ein künstliches neuronales Netz. Das Modell muss für die normalverteilte Nachfrage und zufällig schwankende Bestell- und Transportkosten die kostenoptimale Losgröße ermitteln.
- **KI-Ansätze zur Verbesserung der Prognosegenauigkeit:** Maschinelle Lernverfahren können auch zur Lösung von Regressionsproblemen beitragen, um auf diese Weise das Verhalten eines Systems vorherzusagen. Unter Einsatz eines SVM (Support Vector Machine) untersuchen (Susto et al. 2013) die Veränderungen im Stromsignal bei dem Dotierungsprozess in der Halbleiterfertigung. Das entwickelte Modell ermöglicht die Identifikation von Ausreißern. Es wird hier gezeigt, dass so der Bruch des Dotierungswerkzeugs vorhergesagt werden kann. Damit ist eine vorausschauende Instandhaltung möglich. Neben der Vorhersage konkreter Ereignisse ist auch eine Prognose zukünftiger Zeitreihen möglich (sog. time series forecasting). Arbeiten bei Uber (Laptev et al. 2017) beschäftigen sich mit der präzisen Vorhersage der Nachfrage nach Mitfahrgelegenheiten auch während hochvarianten Zeitabschnitten wie bspw. Feiertagen durch den Einsatz von LSTM (Long short-term memory). Diese Art der rekurrenten neuronalen Netze besitzt die Fähigkeit, relevante Informationen zu speichern und in späteren Vorhersagen abzurufen. Weitere Arbeiten wie die von (Teng und Dasgupta 2018) beschäftigen sich zudem mit der Quantifizierung der Unsicherheit von Vorhersagen, wie sie durch die Anwendung bayesischer Ansätze ermöglicht werden. Besonders im industriellen Kontext gewinnen diese Ansätze

an Bedeutung, um trotz der Intransparenz der meisten erlernten Modelle einen sicheren Einsatz der KI-Ansätze zu ermöglichen. Zusammenfassend zeigt eine Betrachtung bisheriger Arbeiten eine hohe Signifikanz der einzelnen Domänen sowohl im akademischen als auch im industriellen Kontext. Eine Kombination von Ansätzen der KI und Wertschöpfungsnetzwerken zur Maximierung der Potenziale zur Reduktion von Lebensmittelverschwendung erfolgte bisher aber nicht.

**TP V Bedarfsgerechte Produktionspläne:**

Keine.

**TP VI Zuverlässigkeit der Produktion:**

Schutzrechte: Patentfamilie EP 4111866 / DE 102021116879, Priorität: 2021-06-30, Erfinder: Holger Schwenk, Anmelderin: Inotec GmbH Maschinenentwicklung und Vertrieb.

**TP VII Rückverfolgbarkeit:**

GS1 Germany (GS1G) brachte für die Prozessoptimierungen und KI-Anwendungen seine Arbeiten für die Grundlage gemeinsamer Datenstrukturen und Prozessmodelle ein. Aus Sicht von GS1G als Standardisierungsorganisation ist ein entscheidender Erfolgsfaktor für das Management komplexer Produktionsprozesse die Effizienz der Datenerhebung, -integration und -analyse, nicht zuletzt auch für den Einsatz von KI-Technologien.

Das Fehlen offener Standards, Schnittstellen und Open-Source-Softwarekomponenten stellt hier derzeit eines der größten Hemmnisse dar. Von den relevanten Stakeholdern werden heutzutage unterschiedliche technische Lösungen zur Prävention und zum Management von verlustoptimierten Beschaffungs- und Verkaufsstrategien bei Lebensmitteln eingesetzt. Die gesetzliche Grundlage der Rückverfolgbarkeit von Lebens- und Futtermitteln (EU-Verordnung 178/2002) besagt, dass diese über alle Stufen der Produktion, Verarbeitung und Verteilung gewährleistet zu sein hat; Lebens- und Futtermittelunternehmer müssen hierfür Systeme etablieren, die Daten zu direkten Kunden und Lieferanten vorhalten und sie den zuständigen Behörden übermitteln können (Europäisches Parlament und Rat, 2002). Beide Umstände überlagern sich und führen zusammen dazu, dass aktuell Informationsaustausch, -integration und -analyse zum Nutzen ganzheitlicher Wertschöpfungsketten, wie z. B. den ressourcenschonenden Produktionsweisen, sehr schwierig ist.

Um die oben genannten Ziele zu erreichen, bedarf es einer Zusammenarbeit entlang der gesamten Wertschöpfungskette. Die zur – ganzheitlichen wie lokalen – Optimierung der Lebensmittelproduktion benötigten Daten existieren zwar oftmals bereits, sind allerdings über die einzelnen Wertschöpfungsstufen verteilt. Um diesen Missstand zu beheben, haben sich verschiedene für die Herstellung und den Vertrieb von Milch, Fleisch und Backwaren relevante Stakeholder im REIF-Ökosystem zusammengefunden. Dieses Ökosystem, welches von innovativen KI-Start-ups, Forschungseinrichtungen, GS1G als Standardisierer sowie einem führenden Plattformanbieter komplettiert wird, bildete den technischen sowie organisatorischen Rahmen für den vertrauensvollen Austausch wettbewerbsensibler Daten.

Im Rahmen des REIF-Projektes sollten sowohl eine Plattform für den Datenaustausch und die Bereitstellung KI-basierter Dienste als auch einzelne KI-Applikationen anhand von Beispielen aus der Lebensmittelbranche entwickelt werden. Ein besonderes Augenmerk lag hier auf der Entwicklung von übertragbaren Lösungskonzepten, die nach Projektabschluss weiter nutzbar und auf andere Anwendungsfälle übertragbar sind. Darüber hinaus wird ein Weiterbetrieb der zu entwickelnden Plattform auch über das Projektende hinaus angestrebt.

**TP VIII Qualitätsgeführte Verarbeitungsprozesse:**

Die Fa. Kuchenmeister hat am 28.08.2014 ein Patent unter der Bezeichnung „Verfahren und Vorrichtung zur Prozesssteuerung einer Anlage zur kontinuierlichen Herstellung von Schäumen“ eingereicht. Die Erteilung des Europäischen Patent unter der Europäischen Patentnummer 3096931 erfolgte am 31.07.2019 (Veröffentlichung des Erteilungstages).

## 1.5 Zusammenarbeit mit Externen

Lfd. Nr.	TP	Stelle, Inhalt
1	I	Begleitforschung
2	I	Andere Projekte des KI-Innovationswettbewerbs
3	II	Dialogforum Groß- und Einzelhandel im Rahmen der Nationalen Strategie zur Reduzierung der Lebensmittelverschwendung (koordiniert von CSCP): Fachlicher Austausch zu aktuell im Handel getesteten Maßnahmen, um die Lebensmittelverschwendung zu reduzieren.
4	II	A. Liedke, Head of CSR Sourcing, Lidl Deutschland: Austausch über erste Erfahrungen und Markttest mit dem Eco-Score (s. Kennzeichnung vom Umwelt-Fußabdruck auf ausgewählten Handelsmarken inkl. Markttest in Deutschland)
5	II	S. Asal, Directeur associé et consultant en stratégies RSE et Carbone, Eco2Initiative: Austausch über Konzeption vom Eco-Score und anderen Berechnungsmethoden für Fussabdrücke
6	II	Y. Goossens, Researcher – Sustainability assessments   Sustainable food & Plant-based diets   Food waste reduction measures, Thünen-Institut: Austausch über Berechnungsmethoden für Fussabdrücke PEF und über Agribalise Datenbank
7	II	V. de Laurentiis, Scientific Officer, European Commission – Joint Research Centre: Austausch über den „Calculator for impacts for food waste prevention actions“, der zur Bewertung des TP II Markttests herangezogen werden soll
8	II	European Consumer Food Waste Forum: Einbringen der Erkenntnisse des REIF-Projekts in die europäische Arbeit
9	IV	KI-Experten des Mittelstand 4.0 Kompetenzzentrum Augsburg: Austausch über die verwendeten KI-Methoden
10	IV	Mitarbeitende des Forschungsprojekts SmartB4P: Erfahrungsaustausch zu Multiagentensystemen mit Deep Reinforcement Learning
11	IV	Mitarbeitende des Lehrstuhls für Produktionsinformatik der Universität Augsburg: Austausch zum Einsatz von Methoden des maschinellen Lernens in der Produktion
12	VI	Steinbeis-Transferzentrum: Smart Polymer Solutions, Messtechnik Spektroskopie Fluoreszenz, NIR, VIS, Versuchsplanung und -durchführung, Auswertung der Spektren, Dokumentation der Ergebnisse der Messungen
13	VI	BAV Institut GmbH: Untersuchung mikrobiologischer Proben
14	VII	Begleitforschung
15	VII	Andere Projekte des KI-Innovationswettbewerbs
16	VII	Projekträger

Tabelle 1: Zusammenarbeit mit anderen Stellen oder außerhalb des Forschungsprojektes

## Literatur

- BMWK. Programm. [https://www.digitale-technologien.de/DT/Redaktion/DE/Standardartikel/ki\\_programm.html](https://www.digitale-technologien.de/DT/Redaktion/DE/Standardartikel/ki_programm.html). Zugegriffen: 11. April 2023.
- Breyer, Michel; Furrer, Fadri; Novkovic, Tonci; Siegwart, Roland; Nieto, Juan (2018): Flexible Robotic Grasping with Sim-to-Real Transfer based Reinforcement Learning. Online verfügbar unter <http://arxiv.org/pdf/1803.04996v2>.
- Bundesverband der deutschen Ernährungsindustrie (2019): „Ernährungsindustrie.2019“. <https://www.bve-online.de/download/bve-statistikbroschuere2019>. Zugegriffen: 6. April 2023.
- Friedli, Thomas; Mundt, Andreas; Thomas, Stefan (2014): Strategic Management of Global Manufacturing Networks. Aligning Strategy, Configuration, and Coordination. Aufl. 2014. Cham: Springer International Publishing.
- Friedli, Thomas; Schuh, Günther (2012): Wettbewerbsfähigkeit der Produktion an Hochlohnstandorten. Berlin, Heidelberg: Springer Berlin Heidelberg.
- Gaafar, Lotfi K.; Choueiki, M. Hisham (2000): A neural network model for solving the lot-sizing prob-

- lem. In: *Omega* 28 (2), S. 175–184. DOI: 10.1016/S0305-0483(99)00035-3.
- Gatteschi, Valentina; Lamberti, Fabrizio; Demartini, Claudio; Pranteda, Chiara; Santamaria, Victor (2018): To Blockchain or Not to Blockchain: That Is the Question. In: *IT Prof.* 20 (2), S. 62–74. DOI: 10.1109/MITP.2018.021921652.
  - Geffner, Hector (2018): Model-free, Model-based, and General Intelligence. Online verfügbar unter <http://arxiv.org/pdf/1806.02308v1>.
  - IBM (2019): IBM Food Trust. Online verfügbar unter <https://www.ibm.com/de-de/marketplace/food-trust>, zuletzt geprüft am 26.02.2019.
  - IFH Institut für Handelsforschung GmbH (2018): Handelsreport Lebensmittel: Fakten zum Lebensmittel Einzelhandel. [https://einzelhandel.de/images/HDE-Publikationen/HDE\\_IFH\\_Handelsreport\\_Lebensmittel\\_2018.pdf](https://einzelhandel.de/images/HDE-Publikationen/HDE_IFH_Handelsreport_Lebensmittel_2018.pdf). Zugegriffen: 11. April 2023.
  - Jacob, Frank (2006): Quantitative Optimierung dynamischer Produktionsnetzwerke. Aachen: Shaker (Darmstädter Forschungsberichte für Konstruktion und Fertigung).
  - Jacob, Frank; Strube, Gernot (2008): Why Go Global? The Multinational Imperative. In: Eberhard Abele, Tobias Meyer, Ulrich Näher, Gernot Strube und Richard Sykes (Hg.): *Global Production*. Berlin, Heidelberg: Springer Berlin Heidelberg, S. 2–33.
  - Laptev, Nikolay; Yosinski, Jason; Erran Li, Li; Smyl, Slawek (2017): Time-series Extreme Event Forecasting with Neural Networks at Uber: CML Time Series Workshop.
  - Mnih, Volodymyr; Kavukcuoglu, Koray; Silver, David; Rusu, Andrei A.; Veness, Joel; Bellemare, Marc G. et al. (2015): Human-level control through deep reinforcement learning. In: *Nature* 518 (7540), S. 529–533. DOI: 10.1038/nature14236.
  - Möller, Klaus; Klatt, Tobias; Drees, Alexander (2011): Heutige und zukünftige Paradigmen des Produktionsstandorts Deutschland. In: Jürgen Gausemeier und Hans-Peter Wiendahl (Hg.): *Wertschöpfung und Beschäftigung in Deutschland*. Berlin, Heidelberg: Springer Berlin Heidelberg, S. 19–33.
  - Roland Berger: The Supply Chain Excellence Study. Online verfügbar unter <https://www.rolandberger.com/de/Publications/Supply-Chain-Excellence-Study.html>, zuletzt geprüft am 23.02.2023.
  - Rudberg, Martin; Martin West, B. (2008): Global operations strategy: Coordinating manufacturing networks. In: *Omega* 36 (1), S. 91–106. DOI: 10.1016/j.omega.2005.10.008.
  - Sager, Benedikt (2019): Konfiguration globaler Produktionsnetzwerke. München: utzverlag (Forschungsberichte IWB, Band 344).
  - Schmid, Martin (2018): Kognitive Prozesssteuerung zur Steigerung der Ressourceneffizienz in der Druckindustrie. München: Herbert Utz Verlag (Forschungsberichte IWB, Band 335).
  - Susto, Gian Antonio; Schirru, Andrea; Pampuri, Simone; Pagano, Daniele; McLoone, Sean; Beghi, Alessandro (2013): A predictive maintenance system for integral type faults based on support vector machines: An application to ion implantation. In: 2013 IEEE International Conference on Automation Science and Engineering (CASE). 2013 IEEE International Conference on Automation Science and Engineering (CASE 2013). Madison, WI, USA, 17.08.2013 – 20.08.2013: IEEE, S. 195–200.
  - Sutton, Richard S.; Barto, Andrew (2018): Reinforcement learning. An introduction. Second edition. Cambridge, Massachusetts, London, England: The MIT Press (Adaptive computation and machine learning).
  - Teng, Dan; Dasgupta, Sakyasingha (2018): Continuous Time-series Forecasting with Deep and Shallow Stochastic Processes. In: 32nd Conference on Neural Information.
  - Thomas, Stefan (2013): Produktionsnetzwerksysteme: Ein Weg zu effizienten Produktionsnetzwerken. Dissertation, St. Gallen.
  - Tian, Feng (2016): An agri-food supply chain traceability system for China based on RFID & blockchain technology. In: 2016 13th International Conference on Service Systems and Service Management (ICSSSM).
  - VDMA Volkswirtschaft und Statistik. Maschinenbau in Zahl und Bild 2018. <http://www.metalonia.com/w/documents/Mechanical%20engineering%20-%20figures%20and%20charts%202018.pdf>. Zugegriffen: 11. April 2023.
  - Waschneck, Bernd, André Reichstaller, Lenz Belzner, Thomas Altenmüller, Thomas Bauernhansl,

Alexander Knapp und Andreas Kyek (2018): Optimization of global production scheduling with deep reinforcement learning. *Procedia CIRP* 72: 1264–1269. doi: 10.1016/j.procir.2018.03.212.

- Zeng, Andy; Song, Shuran; Welker, Stefan; Lee, Johnny; Rodriguez, Alberto; Funkhouser, Thomas (2018): Learning Synergies between Pushing and Grasping with Self-supervised Deep Reinforcement Learning. Online verfügbar unter <http://arxiv.org/pdf/1803.09956v3>.

## 2 Projektarbeit REIF

### 2.1 Inhalte und Ergebnisse der Teilprojekte

#### 2.1.1 Teilprojekt I – REIF-Ökosystem

Mayer, Dirk (Software AG), Braun, Hans-Martin, und Braunreuther, Stefan (Technische Hochschule Augsburg), Kaufmann, Klaus (GS1 Germany GmbH), Pils, Christian (ARXUM GmbH), Weber, Beatrix, Zaritzky, Fabian, und Özdemir, Julia (Hochschule Hof, iisys)

Aktive Partner: **Software AG**, Arxum GmbH, BayWa AG, CSCP, GS1 Germany, Fraunhofer IGCV, Technische Hochschule Augsburg, Hochschule Hof, Jade Hochschule, Technische Universität München.

Assoziierte Partner: Bayerischer Bauernverband, Company Mind, DLG e.V., Infoteam, IVLV e.V., Winnow.

Um in REIF eine ganzheitliche Betrachtung der Lebensmittelverschwendung zu gewährleisten, wurde im Teilprojekt I (TP I) der Aufbau eines KI-Ökosystems angestrebt, das die Stakeholder sämtlicher Wertschöpfungsstufen integriert. Zur vollständigen Erfassung und Beschreibung des Ökosystems in der Lebensmittelbranche bedarf es der Berücksichtigung sowohl organisatorischer und wirtschaftlicher als auch technischer Perspektiven. Um eine möglichst optimale Abstimmung dieser einzelnen Dimensionen zu gewährleisten und einen holistischen Ansatz zur Ökosystem-Entwicklung zu verfolgen, wurden die organisatorischen, wirtschaftlichen und technischen Voraussetzungen in sechs Arbeitspaketen (AP) innerhalb des TP I: REIF-Ökosystem geschaffen.

Kern des REIF-Ökosystems bildet hierbei die REIF-Plattform (AP1), welche die zentrale Instanz innerhalb des Ökosystems zur Integration sämtlicher Stakeholder darstellt. Die konkrete Interaktion der einzelnen Stakeholder innerhalb des Ökosystems wurde im Rahmen der Governance (AP2) definiert. Die Wichtigkeit der Weiterentwicklung und Anwendung von Verfahren der KI in der Lebensmittelindustrie sollte hierbei durch das zentral organisierte Expertenforum Künstliche Intelligenz (AP3) hervorgehoben werden. Zur Sicherstellung des zum Aufbau eines KI-Ökosystems elementaren Datenaustauschs unter den Wertschöpfungspartnern wurde der Fokus in den weiteren Arbeitspaketen auf die Datenverfügbarkeit und die Standards (AP4), die Datenübertragung (AP5) und den Datenschutz sowie das Datenrecht (AP6) gelegt.

##### 2.1.1.1 AP I.1 Konzeption und Entwicklung der REIF-Plattform

Ziel des AP I.1 waren die (technische) Entwicklung und Umsetzung der REIF-Plattform sowie die Analyse und Eruiierung eines Betreiberkonzeptes für den potenziellen Betrieb der Plattform über das Projekt hinaus. Das Arbeitspaket gliederte sich in vier Unterarbeitspakete, welche im Folgenden hinsichtlich Ziel und Ergebnis näher erläutert werden.

###### 2.1.1.1.1 AP I.1.1 Konzeptionierung und Entwicklung der REIF-Plattform

Im AP I.1 wurde gemeinsam mit allen Konsortialpartnern und den assoziierten Anwendern eine intensive Analyse der Anforderungen durchgeführt. Diese erfolgte

- einerseits nach dem Top-down Prinzip: Prozessanalyse, Ableitung von Unterprozessen und Informationsflüssen mit anschließender Synthese eines Gesamtsystems (Plattform) aus den benötigten Komponenten (dies erwies sich aber im Projekt durch die Vielzahl der Partner und unterschiedlichen Prozessdokumentationsständen als nicht zielführend),



- wie auch einem Bottom-up Ansatz, in dem die einzelnen Use Cases/Informationsbedürfnisse erfasst wurden und die spezifischen Daten und deren Verfügbarkeit für diesen Use Case identifiziert wurden, um daraus ein ideales Gesamtsystem (Plattform) aus der Summe der Use Cases zu abstrahieren. Es wurde ein Fragenkatalog entwickelt und ausgearbeitet, der in die verschiedenen Teilprojekte (Anwendungsszenarien Milch, Fleisch und Backwaren) geleitet wurde, um deren spezifische Anforderungen zu erfassen.

Auf Grundlage dieser Analyse entstand ein Konzeptdokument der REIF-Plattform, welches sukzessive um weitere Ergebnisse aus Abstimmungs- und Erhebungsarbeitstreffen erweitert und verfeinert und in eine konsolidierte Version der Plattformkonzeption übertragen wurde. Es wurde eine Abgrenzung und Abklärung der technischen Basisfunktionalität durchgeführt und das technische Basiskonzept niedergeschrieben.

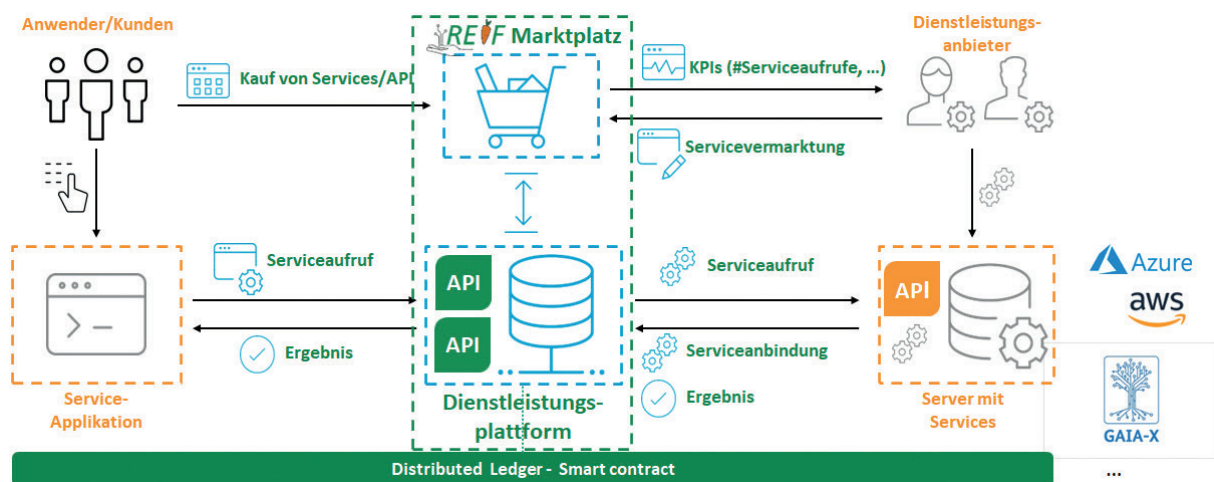


Abbildung 4: Technisches Konzept der REIF-Plattform (eigene Darstellung)

Nach den Ergebnissen der Analyse sollte die Plattform keine Daten speichern, sondern als Vermittlungsplattform den Zugang zu benötigten Daten regeln, die für die Erreichung der Gesamtvorhabensziele ausgewertet werden müssen. Dabei ist noch einmal festzuhalten, dass die Plattform lediglich als Vermittlerin von Daten und KI-Services fungieren und den Datentransfer über die Bereitstellung von Schnittstellen möglich machen soll. Vertragsverhandlungen zwischen den Daten- und Serviceanbietern und den Nachfragenden sollten hingegen bilateral – außerhalb der Plattform – abgewickelt werden, sodass die Plattform weder einen Preisfindungsmechanismus noch ein Datenrechtenmanagement enthält. Aufgrund der Auswirkungen des Data Governance Acts (DGA) auf das für die REIF-Plattform gewählte, hybride Gestaltungsmodell fanden im Jahr 2022 verschiedene Workshops zum Betreiber- und Bezahlkonzept und zu möglichen alternativen Geschäftsmodellen der REIF-Plattform statt. Im Rahmen dieser Workshops wurde vereinbart, dass die Plattform nur noch als Vermittlerin von KI-Services durch die Bereitstellung von APIs fungieren soll. Dabei wurde festgehalten, dass aufgrund der rechtlichen Gegebenheiten kein übergreifender Datenaustausch auf der Plattform an sich stattfindet. Die Daten werden lediglich außerhalb des REIF-Ökosystems vom Servicenehmer an den Serviceanbieter transferiert, um die Bereitstellung des KI-Services zu ermöglichen. Hierzu wurde gemeinsam mit der Software AG, ARXUM und weiteren Partnern ein entsprechendes Plattformkonzept erarbeitet. Ein relevanter Teil der Arbeiten waren hier die Aufteilung der Prozessschritte im Detail und die datentechnische Anbindung der Blockchain-Infrastruktur an das von SAG bereitgestellte webMethods Portal. Die Arbeiten wurden eng verzahnt mit AP I.5 (Datenübertragung in die REIF-Plattform), da hier das entwickelte Smart Contract Konzept Einfluss auf die Interaktion mit der Plattform hat.

### 2.1.1.1.2 AP I.1.2 Komponenten der REIF-Plattform

Basierend auf dem Plattformkonzept des AP I.1.1 wurden in AP I.1.2 entsprechende Komponenten der Software AG ausgewählt, welche die Basistechnologie zur Verfügung stellen. Es wurde von der Software AG eine interne REIF-Entwicklungsplattform aufgesetzt und im nächsten Schritt entsprechende Komponenten installiert. Diese waren im Einzelnen das webMethods API-Gateway zur Verwaltung der Schnittstellen und Möglichkeit des Datenzugriffs sowie das API-Portal, welches den Zugang zum API-Gateway ermöglicht und die Basis zur Umsetzung des Marktplatzes darstellt. Hintergrund dieser Auswahl war, dass kein Partner Daten außerhalb seines Verfügungsrahmens zur Verfügung stellen wollte oder konnte. Aus diesem Grund ist die REIF-Plattform keine Daten-Plattform in dem Sinne, dass sie die zu verarbeitenden Daten speichert bzw. vorhält, sondern lediglich den Zugriff auf Daten und Services über sogenannte Programmierschnittstellen – APIs (Application Programming Interface) – bereitstellt.

In der internen Entwicklungsumgebung konnte eine erste Integration einer prototypischen API des Teilprojektes II getestet werden und erste Ergebnisse waren vielversprechend.

Das Frontend des API-Portals erwies sich für die Anforderungen als weniger geeignet, sodass entschieden wurde, ein REIF-spezifisches Portalfrontend auf Basis von Angular<sup>1</sup> zu entwickeln. Weiterhin wurde ein Rollenkonzept entwickelt und umgesetzt, welches im Portal die unterschiedlichen Teilnehmenden der Plattform (Daten-API-Anbieter, KI/Prognoseergebnis-API-Anbieter, Daten-API-Konsument, Prognose-API-Konsument sowie die Mischform, also Anbieter als auch Konsument) abbildet. Somit wurde ermöglicht, sich als Anbieter oder Konsument bzw. beides (sowohl um Daten für KI-Services bereitzustellen als auch Ergebnisse der Services zu erhalten/erwerben) auf der Plattform zu registrieren.

Um sichere und dokumentierte, revisionssichere Transaktionen über die REIF-Plattform zu gewährleisten, wurden entsprechende DLT (Distributed-Ledger Technologie)-Komponenten von ARXUM umgesetzt, welche die Kerntechnologie zur Verfügung stellen. Diese wurden in einer internen Entwicklungsumgebung (Amazon Web Services) aufgesetzt, angepasst und nach bestehenden Anforderungen weiterentwickelt. (siehe AP I.5).

Es wurde eine Verbindung der DLT-Infrastruktur mit den API-Schnittstellen der REIF-Basis-Plattform entwickelt und implementiert.

Der gesamte Software-Aufbau konnte durch eine Integration einer prototypischen Programmierschnittstelle (API) des Teilprojektes II getestet werden. Somit wurden die Arbeiten an der internen Entwicklungsplattform abgeschlossen!

### 2.1.1.1.3 AP I.1.3 „Prototypische Umsetzung“

Mit der Fertigstellung der Komponenten wurde das AP I.1.3 „Prototypische Umsetzung“ sukzessive erweitert. Für das im Rahmen des AP I.1.2 entwickelte REIF-Portal wurde die Benutzeroberfläche gemäß dem REIF-Branding überarbeitet sowie die erforderlichen Nutzerrollen prototypisch implementiert. Analog wurde der Marktplatz REIF-spezifisch angepasst. Zudem wurde die interne Entwicklungsumgebung auf einen durch die anderen Partner erreichbaren externen Server repliziert sowie mit dem Partner ARXUM die Anbindung der DLT-Infrastruktur entwickelt, implementiert und die Datenübertragung getestet. Nachdem die Plattform einen robusten Status erreicht hatte, wurde im Oktober 2022 den weiteren Teilprojekten im Rahmen eines Workshops die Integration der APIs vorgestellt und die Plattform für die Registrierung und die Tests freigegeben. Nachdem verfügbare APIs registriert werden konnten, auftretende Fehler behoben bzw. angepasst wurden, konnte die Entwicklung der prototypischen REIF-Plattform erfolgreich abgeschlossen werden und Projektpartner können sukzessive weitere APIs integrieren und testen. Die Plattform bzw. der für Endbenutzer verfügbare Teil – der REIF-Marktplatz – ist derzeit unter <https://reif.sagresearch.de> aufrufbar.

<sup>1</sup> <https://angular.io/>



Abbildung 5: Startseite REIF-Marktplatz (eigene Darstellung)

Interessenten können sich registrieren und ggf. eigene APIs hochladen bzw. die Buchung einer API testen. Die Integration der APIs ist, sofern diese der OpenAPI Spezifikation folgen oder ein SWAGGER<sup>2</sup> File zur Verfügung steht, relativ einfach zu bewerkstelligen.

Abbildung 6: REIF-Plattform API-Registrierung (eigene Darstellung)

Zur Information und zur Erläuterung des Marktplatzes wurde von CSCP und der Software AG eine zusätzliche Informationsseite entwickelt und publiziert. Diese ist unter <https://ki-lebensmittelretter.de/> erreichbar.

<sup>2</sup> <https://swagger.io/specification/>

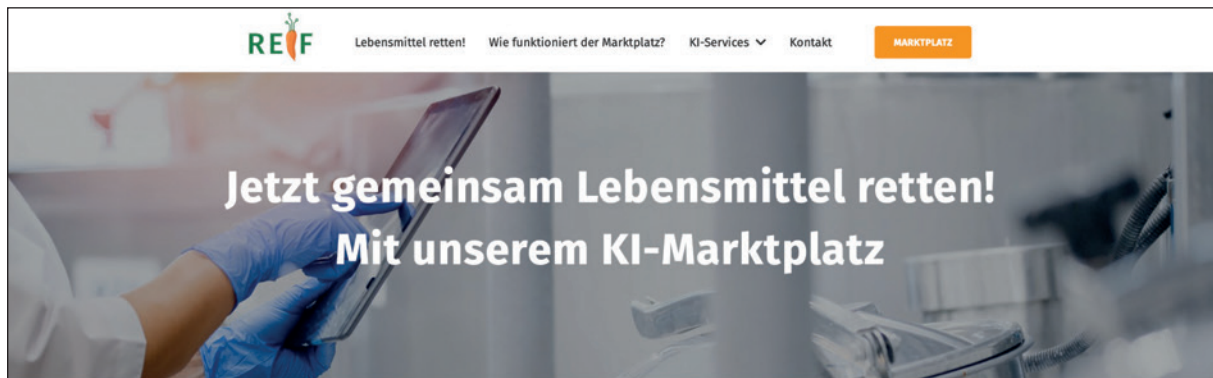


Abbildung 7: REIF-Informationseite (eigene Darstellung)

#### 2.1.1.1.4 AP I.1.4 Betreiber- und Bezahlkonzept

Für die REIF-Plattform wurde eine vergleichende Analyse „Datenplattformen als Geschäftsmodell“ hinsichtlich Leistungsversprechen, Datenportfolio, Preisfindung für Daten und Preismodell erfolgreich durchgeführt. Zur Mitte der Projektlaufzeit kamen erste Vorzeichen und Entwürfe des Data Governance Acts (DGA) der EU aufs Tapet. Zwar wird dieser erst nach der Projektlaufzeit in Kraft treten, dennoch musste, im Hinblick auf einen potenziellen Betrieb der Plattform, dieser berücksichtigt werden. TP I.1.4 hat sich intensiv mit dem im Frühjahr 2022 beschlossenen und ab Herbst 2023 geltenden DGA auseinandergesetzt und dieses im Dokument „Implikationen des Data Governance Act auf das Geschäftsmodell der REIF-Plattform“ zusammengefasst. Dabei hat sich gezeigt, dass der DGA weitreichende Konsequenzen für die REIF-Plattform hat, da er es ihr entgegen dem ursprünglichen Konzept untersagen wird, sowohl Daten als auch KI-Services zu vermitteln. Um DGA-konform zu sein, musste das Geschäftsmodell entsprechend angepasst werden. Unter anderem hierfür wurde in enger Zusammenarbeit mit der Begleitforschung der Workshop „Das Leben nach der Förderung“ durchgeführt. Auf dem Workshop wurde von den REIF-Partnern die Grundsatzentscheidung getroffen, die REIF-Plattform als KI-Marktplatz auszurichten und dafür auf die Vermittlung von Daten zu verzichten. Davon ausgehend wurden, mit Hilfe des von der Universität St. Gallen entwickelten „Magischen Dreiecks“, Zielgruppe, Leistungsversprechen, Wertschöpfung sowie potenzielle Ertragsmodelle des Marktplatzes im Dokument „Grundzüge des Geschäftsmodells der REIF-Plattform“ erarbeitet. Hierbei wurden auch die für einen etwaigen kommerziellen Betrieb der Plattform zu klärenden Fragen – insbesondere Wahl des Ertragsmodells – sowie die sich grundsätzlich stellenden Herausforderungen – vor allem die Gewinnung einer kritischen, die Netzwerkeffekte auslösenden Masse an Nutzern – benannt. Ferner wurden im Dokument Attraktivität und Erfolgsaussichten des durch den DGA buchstäblich halbierten Geschäftsmodells der REIF-Plattform analysiert.

Ergebnisse: „Implikationen des Data Governance Act auf das Geschäftsmodell der REIF-Plattform“, „Grundzüge des Geschäftsmodells der REIF-Plattform“, „Folgen des Data Governance Act auf das Geschäftsmodell der REIF-Plattform“.

#### 2.1.1.2 AP I.2 Governance

Das Ziel des Arbeitspakets I.2 – Governance, die Entwicklung einer Governance für das REIF-Ökosystem, wurde im Rahmen des Projekts erreicht. Im Kontext der Governance kann das REIF-Ökosystem mit der REIF-Plattform gleichgesetzt werden. Die Arbeiten im Rahmen des AP I.2 konzentrierten sich somit auf die Entwicklung einer Plattform Governance unter der Berücksichtigung aller Interessen potenzieller Stakeholder der REIF-Plattform.

Analog zur Business Governance kann Plattform Governance als Beschreibung der Plattformführung, Rahmenbedingungen, Maßnahmen und Instrumente zur zielgerichteten Steuerung einer Plattform angesehen werden. Innerhalb einer Plattform steuert und verwaltet die Plattform Governance das Zusammenwirken der Plattformakteure durch Plattform-Governance-Mechanismen (Evans 2012; Tiwana

2014; Manner et al. 2013). Alle Aktivitäten und Prozesse zur Steuerung der Plattformakteure durch den Plattformbetreiber werden als Plattform-Governance-Mechanismen bezeichnet (Wiesche et al. 2018).

(Hein et al. 2016) identifizierten in ihrer Literaturrecherche (Untersuchung von allgemein akzeptierten und peer-reviewed Veröffentlichungen) verschiedene Plattform-Governance-Mechanismen, ähnliche Mechanismen fassten sie zu Governance Dimensionen zusammen (Tabelle 2, erste und zweite Spalte).

Aus der durch (Hein et al. 2016) durchgeführten Multi-Case-Analyse wurden für alle Governance Dimensionen bzw. der untergeordneten Mechanismen verschiedene Ausprägungen abgeleitet. Die Ausprägungen ermöglichen einen Eindruck, wie die Mechanismen in der Praxis umgesetzt werden können. Um möglichst allen potenziellen Plattformarten gerecht zu werden, erfolgte eine Abstraktion der Umsetzungsbeispiele der Studie hin zu verallgemeinerten Ausprägungsstufen, z. B. Verallgemeinerung zu den Ausprägungen des Mechanismus „Input-Kontrolle und Sicherung“ sind: keine Input-Kontrolle – mittelstarke Input-Kontrolle – starke Input-Kontrolle. Die Ausprägungsstufen aller Mechanismen sind in Tabelle 2 (dritte Spalte) ersichtlich.

(Hein et al. 2016) verknüpften die Ergebnisse ihrer Multi-Case-Analyse mit bereits bekannten Eigenschaften (hier im Sinne von Auswirkungen, z. B. großes Benutzerwachstum) der untersuchten Plattformen und beschrieben auf diese Weise die Zusammenhänge zwischen den Governance Ausprägungen und deren Auswirkungen auf die Plattform. Nach einer Verallgemeinerung konnten diese durch die Bildung von Überkategorien gruppiert werden. Tabelle 2 stellt die abstrahierten und gruppierten Auswirkungen dar (erste und zweite Zeile).

Die abgeleiteten Governance Ausprägungen und ihre möglichen Auswirkungen auf die Plattform und deren Nutzer wurden durch einen paarweisen Vergleich verknüpft. Das Ergebnis dieses Vergleichs ist eine Übersicht über die Auswirkungen verschiedener Ausprägungsformen auf die Plattform (Tabelle 2). Teile des Vergleichs finden sich in der Diskussion der Multi-Case-Analyse von (Hein et al. 2016) wieder. Alle weiteren Abhängigkeiten wurden durch Befragungen und Diskussionen mit Experten erarbeitet.

Basierend auf den beschriebenen theoretischen Grundlagen erfolgte im Rahmen des REIF-Projekts eine Untersuchung fünf bestehender Plattformen: GS1 ECOTraxx, ADVANEO, DAWEX Global Data Marketplace, Telkom Data Intelligence Hub, Caruso Marketplace.

Die Erarbeitung der REIF-Plattform-Governance erfolgte in einer Workshop-Serie mit den AP I.2-Partnern. Durch die Zusammensetzung der AP I.2-Partner wurde sichergestellt, dass alle potenziellen Stakeholder der REIF-Plattform an der Ausarbeitung beteiligt waren. Grundlage für diese Workshops bildeten die vorhergehend beschriebenen theoretischen Grundlagen sowie die Untersuchung bereits bestehender Plattformen. Auf Grund des Inkrafttretens des Data Governance Acts im Jahr 2023 erfolgte eine Anpassung der bereits erarbeiteten Plattform Governance, um den zukünftigen rechtlichen Gegebenheiten Rechnung zu tragen.

			Kontrolle			Sicherheit			Transparenz			Wachstum			Aufwand			Sonstiges		
			Plattform	Informationen	Prozesse	tatsächliches Risiko	wahrgenommenes Risiko	Anonymität der PF-Teilnehmer	Prozesse	Entscheidungen	Benutzerfreundlichkeit	Nutzer	Anwendungsvielfalt	Märkte/Geschäftsmodelle	Plattformbetreiber/Verwaltung	Anwender	Benutzerzufriedenheit	Qualität der Inhalte/ Anwendungen	Kommerzialisierung/ Monetarisierung	
Governance-Struktur	Eigentümerstatus	ein Eigentümer	↑	↑	↑			↘	↘					↑				↑		
		mehrere Eigentümer	✓	✓	✓			↗	↗					○				○		
		viele Eigentümer	↓	↓	↓			↗	↗					↓				↓		
	Entscheidungsrechte	zentrale	↑		↑				↓		✓	✓	✓	↑	✓			↑		
		stärker dezentral	✓		✓				↗		○	○	○	✓	↗			○		
		dezentral	↓		↓				↑		↗	↗	↗	↓	↑			↓		
Ressourcen und Dokumentation	Transparenz	vollständige Transparenz				✓		↑	↑	↑	↗	↗	↑		↗		↗			
		teilweise Transparenz				↗		↘	↘	↘	○	○	✓		○		○			
		keine Transparenz				↑		↓	↓	↓	✓	✓	↓		✓		✓			
	Platform Boundary Resources	Ja	✓		↗	↗			↗	↗	↗	↗	↗	↗	✓			↗		
		Nein	↑		✓	✓			✓	✓	✓	✓	✓	✓	↗			✓		
	Zugang und Kontrolle	Offenheit	offen	✓		↗	↗	↗			✓	↑	↗	↗		✓	✓			
geschlossen			↗		✓	✓	✓			↗	↓	✓	✓		↗	↗				
Zugänglichkeit		keine Zugangsbeschränkungen				↑	↑	↑			↗	↑	↗	↗	✓	✓		✓		
		Zugangsbeschränkungen				✓	✓	✓			✓	✓	✓	✓	↗	↗		↗		
		starke Zugangsbeschränkungen				↓	↓	↓			↓	↓	↓	✓	↗	↗		↑		
Kontrolle über den Zugangsprozess		Plattformbetreiber/-eigentümer	↗		↑				✓	✓				↗	✓			↗		
		Plattformteilnehmer	✓		↓				↗	↗				✓	↗			✓		
Input-Kontrolle und Sicherung		keine/"Laissez-faire"	✓		○	↗	↑				↗	↗		✓	✓			✓		
		mittel	↗		○	✓	↗				✓	✓		○	○			↗		
Output-Kontrolle und Monitoring		keine/"Laissez-faire"	✓		○	↗	↑				✓	↗	↗		✓	✓		✓		
		mittel	↗		○	✓	↗				↗	✓	✓		○	○		↗		
Vertrauen und Risiko		Sicherheitsmaßnahmen	keine/"Laissez-faire"	✓		○	↑	↑	↑						✓	✓				
	mittel		↗		○	✓	✓	✓						↗	↗					
	stark		↗		○	✓	↓	↓						↗	↗					
Preisgestaltung	Preisgestaltung auf der Plattform	Plattformbetreiber/-eigentümer	↗		↗					↘	↘			↗	✓					
		Angebot und Nachfrage	✓		✓					↗	↗			✓	↗					
	Vergütung der Plattformnutzung	Vergütung durch Nutzer													↗	↗	✓	↗		
		Vergütung durch Anbieter				✓									↗	↗	✓	↗		
		Vergütung durch Dritte										↗	↗		✓	✓	↗	✓		
Externe Beziehungen	Ja	✓								↗	↗	↗	↗			↗	○			
	Nein	↗								✓	✓	✓	✓			✓	○			

Tabelle 2: Übersicht über die Zusammenhänge von Governance-Mechanismen und deren Auswirkungen (eigene Darstellung)

↑	↗	✓	↓	○
hoch	zunehmend	abnehmend	niedrig	abhängig von der Umsetzung

Folgendes Governance-Konzept wurde für die REIF-Plattform ausgearbeitet:

Governance Struktur	<p><b>Eigentümerstatus:</b> ein/mehrere Eigentümer (rechtlich präziser: Betreiber) Der Betrieb der REIF-Plattform soll durch eine zentrale Institution, die sowohl die Infrastruktur und die Support-Services einkauft und orchestriert als auch für die Einhaltung der Regeln und der gesetzlichen Vorgaben verantwortlich ist, geführt werden. Eine solche zentrale Institution kann ein einzelner Betreiber oder eine Betreibergesellschaft sein.</p>
	<p><b>Entscheidungsrechte:</b> zentral Da für REIF eine zentrale Institution als Datenmittler definiert wurde, ist es naheliegend, dass die Entscheidungsgewalt über die Plattform bei dieser Institution liegt. Zu den Entscheidungsbereichen zählen alle grundsätzlichen Plattform-Themen, z. B. AGBs, sowie der Funktionsumfang der Plattform. Demgegenüber stehen die dezentralen Entscheidungsrechte der Teilnehmenden, z. B., ob sie KI-Services anbieten oder an einen potenziellen Kunden verkaufen möchten.</p>
Ressourcen und Dokumentation	<p><b>Transparenz:</b> vollständige Transparenz Die REIF-Plattform muss für alle Teilnehmenden vollständig transparent sein, da es sich um eine Business-to-Business-Plattform handelt. Für jeden Teilnehmer muss ersichtlich sein, wer die weiteren Teilnehmenden sind, wer als potenzieller Partner die eigenen Daten einsehen bzw. verwerten kann (Stichwort: Einblick in Geschäftsdaten von Konkurrenten) und wie die Entscheidungen des Datenmittlers in Bezug auf Plattformfragen zustande kommen.</p>
	<p><b>Platform Boundary Resources:</b> es wird PBR geben Da auf der REIF-Plattform APIs gehandelt werden, müssen Plattform Boundary Resources integriert werden. Neben Application Boundary Resources (APIs) sind Social Boundary Resources für die REIF-Plattform unerlässlich, da diese zu einer besseren Benutzerfreundlichkeit der REIF-Plattform beitragen und die technischen Hürden für die Teilnahme herabsetzen.</p>
Zugang und Kontrolle	<p><b>Offenheit:</b> offen Die REIF-Plattform soll offen gestaltet sein. Kein Interessent bzw. potenzielle Teilnehmende soll ausgeschlossen werden. Dies würde einer möglichst großen Teilnehmendenzahl, welche für die bestmögliche Nutzung von Netzwerkeffekten im Rahmen von Wertschöpfungsnetzwerken erforderlich ist, entgegenstehen. Eine grundsätzliche Offenheit der REIF-Plattform soll jedoch nicht als „Freifahrtschein“ für alle Arten von Teilnehmenden zu verstehen sein.</p>
	<p><b>Zugänglichkeit:</b> starke Zugangsbeschränkungen Der Zugang zur REIF-Plattform soll starken Zugangsbeschränkungen unterliegen, da zum einen die Lebensmittelbranche im Fokus steht und zum anderen zwischen den Plattformnutzenden sensible Geschäftsdaten ausgetauscht werden (siehe auch „Vertrauen und Risiko“). Neben Zugangsbeschränkungen, z. B. in Abhängigkeit der Branche, können auch qualitative Beschränkungen Anwendung finden, wenn diese keine ausschließende Wirkung haben.</p>
	<p><b>Kontrolle über Zugangsprozess:</b> Plattformbetreiber Die Kontrolle des Zugangsprozesses der REIF-Plattform liegt in den Händen des Plattformbetreibers, da dieser gesetzlich verpflichtet ist, den Zugang nach den FRAND-Regeln fair, zumutbar und diskriminierungsfrei zu gestalten.</p>
	<p><b>Input-Kontrolle und Sicherung:</b> mittel/stark Die „Zugänglichkeit“, „Input-Kontrolle und Sicherung“ und „Kontrolle über den Zugangsprozess“ sind durch die gesetzliche Verpflichtung zur Kontrolle des Zugangsprozesses durch den Datenmittler untrennbar vereint. Für die REIF-Plattform besteht lediglich die Möglichkeit, die Inhalte über die AGBs und Nutzungsbedingungen sowie über Vorgaben zu den zu verwendenden Datenformaten zu steuern. Aktiv kontrollieren kann der Datenmittler lediglich, ob die technischen Rahmenbedingungen eingehalten werden und ob die Datenprodukte aktiv sind bzw. funktionieren. Darüber hinaus wird der Datenmittler die KI-Service-Beschreibungen auf inhaltliche/thematische Daseinsberechtigung auf der REIF-Plattform (Lebensmittelbranche) hin überprüfen.</p>
	<p><b>Output-Kontrolle und Monitoring:</b> mittel/stark Für die Output-Kontrolle gilt, wie für die Input-Kontrolle, dass der Datenmittler die Inhalte der Datenprodukte nicht einsehen und kontrollieren kann. Die Maßnahmen für die Kontrolle des Outputs sind mit den Maßnahmen der Input-Kontrolle (Überprüfung der technischen Rahmenbedingungen und Funktion der Datenprodukte) deckungsgleich. Darüber hinaus wird die REIF-Plattform ein einsehbares Monitoring in Form von Zugriffszahlen, Mehrfachbuchungen und weiteren nachvollziehbaren Kriterien zur Verfügung stellen. Darüber hinaus kann ein System zur Nutzung einer Bewertungsfunktion zugekauft und implementiert werden.</p>

Tabelle 3: Governance-Konzept (eigene Darstellung)

<b>Vertrauen und Risiko</b>	<p><b>Sicherheitsmaßnahmen:</b> stark</p> <p>Auf Grund der über die REIF-Plattform gehandelten KI-Services bzw. des nicht über die Plattform selbst stattfindenden, aber jedoch angebahnten Datenaustausches der Teilnehmenden, muss die REIF-Plattform starke Sicherheitsmaßnahmen wahrnehmen, um sowohl das wahrgenommene als auch das tatsächliche Risiko zu reduzieren.</p> <p>Die Verwendung der Block--c Chain-Technologie auf der REIF-Plattform bietet eine inhärente Sicherheitsmaßnahme. Zusätzlich zur Verwendung der Block--c Chain wird die REIF-Plattform Verschlüsselungslösungen zum Datentransport anbieten. Eine weitere Maßnahme zur Steigerung der Sicherheit besteht darin, dass die Teilnehmenden selbstständig entscheiden, welchen Teilnehmenden sie Zugriff auf ihre eigenen Daten gewähren.</p>
<b>Preisgestaltung</b>	<p>Wurde im Rahmen des AP I.4.1 (Betreiber- und Bezahlkonzept) erarbeitet</p>
<b>Externe Beziehungen</b>	<p><b>Verwaltung externer Beziehungen:</b> Ja</p> <p>Die REIF-Plattform muss auf Grund ihrer Konzeption externe Beziehungen eingehen. So stellen die Beziehungen zu den Teilnehmenden bereits externe Beziehungen dar. Die Bereitstellung der Datenprodukte stellt bereits eine Serviceerweiterung der Plattform dar.</p>

Fortsetzung Tabelle 3

### 2.1.1.3 AP I.3 Expertenforum Künstliche Intelligenz

Die Ziele des Arbeitspakets I.3 – Expertenforum Künstliche Intelligenz – die Dokumentation, Diskussion und Weiterentwicklung des generierten Wissens in einem Wissens-Wiki, durch Diskussionsforen und die Verbreitung in Form von Veröffentlichungen – wurden im Rahmen des Projekts erreicht.

Zu Beginn des Projekts wurde ein Wissens-Wiki auf Grundlage der frei verfügbaren Verwaltungssoftware MediaWiki eingerichtet und allen Projektpartnern zugänglich gemacht. Die Nutzung und Funktion von MediaWiki sind vergleichbar mit der freien Enzyklopädie Wikipedia. Die zu Beginn eingerichteten Seiten wurde zusammen mit den neu hinzugekommenen Seiten im Rahmen des AP I.3 betreut und moderiert. Die Eintragung des im REIF-Projekt generierten Wissens oblag den Teilprojektleitern bzw. den jeweiligen Teilprojekten. Darüber hinaus entstand eine von der Projektseite losgelöste Internetseite zur Beschreibung der in REIF entstandenen KI-Services und des KI-Marktplatzes.

Zur Diskussion und Weiterentwicklung des generierten Wissens erfolgte in der Projektlaufzeit eine kontinuierliche Sammlung und Auswahl von Diskussionsthemen aus dem REIF-Konsortium. Hieraus entstand neben einem internen und einem externen Expertenaustausch ein Austausch auf europäischer Ebene. Im Rahmen des internen Expertenforums wurden die Ergebnisse der im REIF-Konsortium durchgeführten Interviews zum Thema „Hemmnisse bei der Datenbereitstellung“ diskutiert. Das externe Expertenforum beschäftigte sich mit Themenstellungen aus der REIF-Projektarbeit, so wurden z. B. erste Ergebnisse aus einzelnen Teilprojekten vorgestellt und aufgezeigt, wo Probleme aufgetreten sind und wie diese gelöst werden konnten. Ein Gastbeitrag zeigte auf, wie Lebensmittelverluste in der Praxis erfasst werden können.

Im europäischen Austausch blickte das REIF-Projekt über die deutschen Grenzen hinweg. So wurden zum einen Erfahrungsberichte zur Nutzung von KI sowie der praktische Einsatz von KI am Beispiel der Systemgastronomie und Großküche in Österreich betrachtet. Darüber hinaus stellte die VDI/VDE Innovation + Technik GmbH einen Deep Dive zu datenrechtlichen Aspekten vor.

Zur Verbreiterung des generierten Wissens aus dem REIF-Projekt sowie zur Entgegennahme des gesellschaftlichen Feedbacks erfolgten Veröffentlichungen auf verschiedenen Publikationswegen und gegenüber verschiedensten Publikumskreisen. Inhalte dieser Veröffentlichungen waren zumeist Ergebnisse und Erkenntnisse aus dem REIF-Projekt sowie dessen Vorstellung. Eine Auswahl an Veröffentlichungen aus dem AP I.3 heraus können Sie folgender Liste entnehmen:

- DLG-Bitcom-Themenfrühstück – Lebensmittelretten 2.0 – Digital gegen die Verschwendung: Verschwendungsminimierung in der Lebensmittelindustrie durch künstliche Intelligenz (November 2020)



- „Siblers Denkräume – Spannendes aus Wissenschaft und Forschung in Bayern“ des bayerischen Staatsministeriums für Wissenschaft und Kunst: Wie Künstliche Intelligenz Lebensmittelverschwendung reduzieren kann (Mai 2021)
- Bayern fit for Partnership: Waste minimisation in the food industry through artificial intelligence (Mai 2021)
- Forschungsbericht Jade HS – Mit Künstlicher Intelligenz gegen Lebensmittelverschwendung (Juni 2021)
- Industr.com – Mit Künstlicher Intelligenz gegen Lebensmittelverschwendung (Oktober 2021)
- Lebensmittelnetzwerk Rhein-Neckar – food.net.z: Verschwendungsminimierung in der Lebensmittelindustrie durch künstliche Intelligenz (November 2021)
- Mittelstand 4.0 – KI Coffeebreak 2022: Verschwendungsreduzierung in der Lebensmittelindustrie durch künstliche Intelligenz (Februar 2022)
- Anuga FoodTec: Smart solutions to reduce food waste – Mit KI Lebensmittelverschwendung reduzieren (April 2022)
- Handelsblatt Journal: Nachhaltiger Umgang mit Lebensmitteln durch KI (Juni 2022)
- Lange Nacht der Wissenschaft Augsburg: KI gegen Lebensmittelverschwendung (Juni 2022)
- Molkerei-Industrie: Einsatz künstlicher Intelligenz – Mit KI Lebensmittelverschwendung reduzieren (August 2022)
- Impulsvortrag 2023 – Bayerischer Volkshochschulverband – KI gegen Lebensmittelverschwendung (Februar 2023)
- Journal of Transport and Supply Chain Management – Bull-whip effect: Modelling and simulation of a sinusoidal stimulus considering food waste (März 2023)

#### 2.1.1.4 AP I.4 Datenverfügbarkeit und Standards

Ziel des Arbeitspaketes war die Identifikation von Standardisierungslücken und Entwicklung von Lösungen zu ihrer Schließung. Die Aufgaben und Ergebnisse waren im Einzelnen:

1. Übersicht der vorhandenen Datenquellen,
2. Report zu etablierten Standards und deren Lücken und
3. Report zu neuen Standardisierungslösungen,

welche in drei TAPs erarbeitet und erfolgreich abgeschlossen wurden. Im **AP I.4.1 Analyse der Datenquellen und der Datenverfügbarkeit** wurde zur Schaffung der Voraussetzungen für eine horizontale und vertikale Vernetzung im Wertschöpfungsnetzwerk mit den Partnern die Datenstandards in Lebensmittelketten anhand der drei in REIF in Bezug genommenen Beispiel-Sektoren skizziert und diskutiert. Die zusammengetragenen Informationen wurden aufbereitet und in Bezug auf das REIF-Ökosystem ausgewertet und dort eingebracht.

Darauf aufsetzend wurde im **AP I.4.2 „Analyse bestehender Standards“** mit den Projektpartnern ein Fragenkatalog zur Abfrage eingesetzter Standards entwickelt, an alle Konsortialpartner versandt und die Rückmeldungen ausgewertet. Dieser wurde validiert und mit weiteren Rückmeldungen, auch außerhalb des Konsortiums, erweitert und ein detaillierter Bericht erstellt. Im Detail wurden folgende Arbeiten durchgeführt:

- Untersuchung globaler und offener Standards zur Identifikation von Produkten
- Untersuchung von Standards zur Einbindung automatischer Erfassungssysteme und Formaten zum elektronischen Datenaustausch, einschließlich event-basierter Datenlösungen (EPCIS)
- Untersuchung von Standards für Traceability-Systeme

Diese Fragestellungen stellten die Basis für den im **AP I.4.3 Lösungen zur Schließung von Standardisierungslücken** erarbeiteten Bericht, wie und in welcher Weise den identifizierten Lücken im Rahmen des REIF Projektes, bzw. im Anschluss, erfolgreich begegnet werden muss bzw. wie diese geschlossen werden können und welche Maßnahmen zu ergreifen sind. Diese Maßnahmen wurden mit den Partnern in Form von Vorschlägen für konkrete Erweiterungen und Neuschaffung von Standards, einschließlich Priorisierung, Roadmap und Empfehlungen an die Meinungsführer eingeholt, diskutiert

und aufbereitet. Als Ergebnis wurde ein Report zu neuen Standardisierungslösungen und der zugehörigen Vorgehensweise erstellt.

### 2.1.1.5 AP I.5 Datenübertragung

Ziel und Ergebnisse des Arbeitspaketes waren die Entwicklung der DLT für die Datenübertragung, welche sich in AP I.5.1 Detaillierte Beschreibung der in Smart Contracts hinterlegten Regeln zum firmenübergreifenden Datenaustausch, AP I.5.2 Übersicht der DLT-Architektur sowie in AP I.5.3 Betrieb und Dokumentation der umgesetzten DLT-Lösung gliederte.

Das elaborierte und verabschiedete Konzept der Plattform sieht kein Speichern von Daten zentral auf der Plattform vor. Die Plattform wird Daten von allen Partnern zugänglich machen, wird aber keine vollständige Datentransparenz (mit vollem Zugriff auf Rohdaten) herstellen. Die Plattform liefert wichtige Kennwerte (KPI) zur Verschwendungsvermeidung und Prozesssteuerung, ohne das Geschäftsmodell des Datenlieferanten zu verletzen. Ein Schutz von Rohdaten ist für alle Plattformteilnehmenden von extrem hoher Bedeutung, da sie sich andernfalls ggf. Forderungen von Geschäftspartnern gegenübersehen, die sie durch den Schutz ihrer Daten vermieden hätten. Dieser Aspekt spielt eine große Rolle bei der industriellen Anwendbarkeit der Plattform.

Daher sollen **Zugänge** über APIs an vorhandene Datensilos mittels Zugriffskontrollen durch Smart Contracts etabliert werden. Der Datenzugang erfolgt über sog. „Services“ der Plattform, die zur Datendrehscheibe für die unterschiedlichen Partner wird. ARXUM hat über die Blockchain-Technologie mittels Smart Contracts die Datenzugriffe der Services implementieren und hat hierzu die Konzeption der Smart Contract Architektur (**AP I 5.1**) erstellt. Eine DLT-Test-Infrastruktur wurde aufgesetzt, um die Umsetzung von verschiedenen Smart Contract Architekturen zu testen und ein geeignetes Smart Contract Konzept für die Realisierung der Plattform festzulegen.

Das Ergebnis der Kooperation ist ein sogenanntes „Big Picture“, das alle Hauptprozesse (z. B. Produktionsplanung, Einkauf, Produktion, Verkauf etc.) umfasst und alle benötigten Komponenten der Plattform und die Datenflüsse darstellt.

Gemeinsam mit dem Partner Software AG wurde im Dezember 2020 ein technischer Workshop durchgeführt, in dem die Schnittstellen (APIs) der webMethods Software der SAG und der Smart Contract Umgebung von ARXUM analysiert und abgeglichen wurden.

Es fanden im Rahmen des AP I.1.2 diverse bilaterale Workshops mit der SAG statt, um zu evaluieren, welche Schnittstellen der von SAG genutzten Software „webMethods“ zur Verfügung stehen, um diese mit der von ARXUM eingesetzten EOS.IO Blockchain-Technologie zu verbinden.

Die sehr fruchtbare Zusammenarbeit mit dem Partner Hochschule Hof ergab unter anderem, dass ein blockchain-basierter Smart Contract nicht für die Vertragsanbahnung geeignet ist, allerdings die Vertragsdurchführung technisch unterstützen und regeln kann. Smart Contracts sind (aktuell noch) keine Verträge im rechtlichen Sinne. Als Ergebnis wurden in der REIF-Plattform innerhalb der Smart Contracts die Business Regeln für den Datenaustausch festgelegt und gespeichert.

Rechtliche Rahmenbedingungen wie Zahlungsvereinbarungen, Kündigung etc. sind Teil der Anbahnungsphase und wurden bilateral geschlossen bzw. werden ggf. später Teil der „Nutzungsbedingungen“ der REIF-Plattform.

Auf Grundlage dieser Erkenntnisse wurde ein Smart Contract Konzept evaluiert und allen Projektpartnern am 4. Konsortialtreffen im November 2021 vorgestellt.

Der Meilenstein M I.7 „Entwicklung der Smart Contracts“ ist erfolgreich am 01.11.2021 abgeschlossen worden.

**IM AP I.5.2 Auslegung der DLT-Infrastruktur** hat ARXUM innerhalb des Gesamtvorhabens erfolgreich eine erste Testumgebung für die eingesetzte DLT-Technologie aufgesetzt und getestet. Somit wurde sichergestellt, dass die entwickelten Smart Contracts getestet werden können. Im Rahmen dieses Projektes wurde von ARXUM eine öffentlich und frei verfügbare DLT-Technologie eingebracht (EOS. IO). Um in einem späteren Produktivbetrieb nach Projektende auch den Einsatz von anderen DLT-

Technologien zu ermöglichen und die Plattform insgesamt möglichst interoperabel aufzusetzen, hat ARXUM im Rahmen des AP I.5.1 über *Smart Contract Locator* und *Smart Contract Description Language* recherchiert und die Erkenntnisse in die weitere Entwicklung einfließen lassen.

ARXUM hat erfolgreich eine Testumgebung für die eingesetzte DLT-Technologie aufgesetzt und getestet. Somit wurde sichergestellt, dass die entwickelten Smart Contracts entwickelt, getestet und veröffentlicht werden konnten und die Voraussetzung für AP I.5.3 bilden.

Die eingesetzte Infrastruktur wurde auf Amazon Web Services (AWS) gestartet und fortlaufend an die neuen Anforderungen aus **AP I.5.3 „Anbindung und Betrieb einer industrietauglichen Infrastruktur“** angepasst, überwacht und gewartet.

Die Smart Contracts aus AP I.5.1 wurden innerhalb der eingesetzten EOS.IO Blockchain genutzt, um Kunden-API-Zugangsdaten auszuwerten und zu speichern.

Zur Diskussion stand, in welchem System das Tracking der Smart Contract Parameter stattfinden sollte. Innerhalb der DLT-Infrastruktur oder aber innerhalb der REIF-Plattform (webmethods der SAG). Es wurden beide Alternativen getestet und entschieden, dass das Tracking der Smart Contract Parameter innerhalb der DLT-Infrastruktur stattfindet. So konnten Ressourcen und Zeit gespart werden, da die Daten ohnehin an die DLT gesendet werden und diese dann bei Vertragserfüllung (z. B. maximale Anzahl der erlaubten Zugriffe erreicht) die Bestätigung oder Ablehnung an die Plattform sendet und diese den Zugriff unterbindet oder bestätigt. Ansonsten hätte die Plattform diese Bestätigung/Ablehnung erst an die DLT gesendet, würde durch die Smart Contracts geprüft und das Ergebnis zur Vertragserfüllung wieder an die Plattform gesendet. Es wurde hier die effizientere Vorgehensweise implementiert.

Daraus erfolgte folgender Ansatz, um die DLT-Infrastruktur mit webMethods der SAG zu integrieren. Die Prozessschritte sind:

1. webMethods API Gateway stellt eine API-Anfrage an die ARXUM EOS.IO Blockchain-Benutzerverwaltung, um den Benutzer zu authentifizieren.
2. Nach erfolgreicher Authentifizierung sendet webMethods die Transaktion über einen weiteren API-Aufruf an die ARXUM-Blockchain.
3. Eine Transaktion kann dazu dienen, einen API-Zugangsplan eines Kunden zu registrieren, den Zugang zu überprüfen oder den Zugangsplan zurückzusetzen.

Um diesen Ansatz zu realisieren, hat ARXUM die vorhandenen Smart Contracts angepasst und auf der vorhandenen Blockchain Infrastruktur implementiert.

Die für REIF verwendeten Smart Contract bestehen aus zwei Speichertabellen. Eine, um die API-Zugangsdaten zu speichern, und eine weitere, um zu bestimmen, welcher Benutzer welche Aktionen auf dem Smart Contract ausführen darf.

Der Smart Contract beinhaltet dabei folgende drei Aktionen:

1. Benutzerplan registrieren (Benutzerauthentifizierung)
2. Abrufen des aktuellen Zugangsstatus (Registrierung am Smart Contract)
3. Zugangsstatus zurücksetzen (Überprüfung der Zugriffsberechtigung)

Der Zugriff auf die Smart Contract Actions steht nur für die in der Plattform angelegten und authentifizierten Benutzer zur Verfügung, die ebenfalls in der Smart Contract Tabelle eingetragen sind.

Alle oben genannten Punkte wurden zusammen mit der SAG getestet und in die REIF-Plattform integriert.

Nachdem die Plattform einen robusten Status erreicht hatte, wurde im Oktober 2022 den Teilprojekten im Rahmen eines Workshops die Integration der APIs vorgestellt und die Plattform für die Registrierung sowie Tests freigegeben. API-Integrationen verliefen erfolgreich, auftretende Fehler konnten behoben werden.

Veröffentlichungen waren zumeist Ergebnisse und Erkenntnisse aus dem REIF-Projekt sowie dessen Vorstellung. Eine Auswahl an Veröffentlichungen aus dem AP I.5 heraus können Sie folgender Liste entnehmen:

- 04.02.2020, Markus Jostock; Blockchain Hype or Reality? Application Scenarios in the Food supply-chain; ProSweets Fair, Cologne 2020
- 15.10.2020, Markus Jostock; Wie kann Lebensmittelverschwendung durch eine Optimierung über die gesamte Lebensmittel-Lieferkette reduziert werden?; IIT Berlin 2020
- 02.09.2021, Markus Jostock; Blockchain Deepdive\_ Deepdive Kaiserslautern 2021
- 22.11.2021, Markus Jostock; INNOVATIVE TECHNOLOGIEN ALS BEFÄHIGER FÜR MEHR NACHHALTIGKEIT IN KOMPLEXEN LIEFERKETTEN; ZIRP 2021
- 27.04.2022, Markus Jostock; Optimierung der digitalen Lieferkette; Anuga FoodTec, Köln 2022

### 2.1.1.6 AP I.6 Datenschutz und Datenrecht

Ziel des APs war die Sicherstellung der rechtskonformen Umsetzung von REIF, vor allem vor dem Hintergrund daten- und datenschutzrechtlicher Aspekte. Das Arbeitspaket gliederte sich in die Unterarbeitspakete

- AP I.6.1: Datenschutzrechtliche Bewertung von Datenverarbeitungsmaßnahmen vor allem vor dem Hintergrund, dass über die Plattform Daten gehandelt werden sollten
- AP I.6.2: Datenschutzkonforme Lösungen für die neuen Technologien
- AP I.6.3: Rechtssichere Konzeption hinsichtlich Datenherrschaft und -kontrolle, welche sich mit sogenannten Smart Contracts in Zusammenarbeit mit TP I.5 befasste
- AP I.6.4: Fortentwicklung und Sicherstellung der rechtssicheren Nachhaltigkeit, welche auf die Zeit nach dem Projekt und einem rechtssicheren Betrieb fokussierte.

Die Arbeiten im Einzelnen:

#### **(Legal) Data Governance**

Aufbauend auf dem hybriden Gestaltungsmodell der REIF-Plattform wurden durch umfassende Recherche mögliche Governance-Mechanismen für die REIF-Plattform herausgearbeitet sowie anhand von rechtlichen Anforderungen und Folgen dargestellt. Daraus wurden Gestaltungsmöglichkeiten für die Rechts- und Lizenzbedingungen abgeleitet und im Projekt sowie in der Begleitforschung präsentiert. Hierbei hat sich das hybride Modell herauskristallisiert, welches in der weiteren Projektarbeit verfeinert und mit möglichen rechtlichen Lizenzmodellen konkretisiert wurde. Zudem wurden Vorarbeiten für die Gestaltung der Plattform im Hinblick auf Streitschlichtungsmechanismen geleistet. Es wurden im Rahmen der Ausarbeitung der Plattform die Governance-Mechanismen und -Dimensionen zunächst ökonomisch (Software AG) und rechtlich (HSH) untersucht. Die erarbeiteten Governance-Mechanismen und -Dimensionen wurden als Grundlage für die Analyse von bereits bestehenden Plattformen herangezogen. Zudem wurden die bereitgestellten Datenbestände und die damit verbundenen Rechte überprüft. Dazu wurden mögliche Rechts- und Nutzungsbeschränkungen der Datenbestände, Lizenzmodelle, ihre Einsatzmöglichkeiten und Nutzergruppen untersucht und eingeordnet. Die daraus hervorgegangenen theoretischen Grundlagen und praxisbezogenen Ergebnisse wurden im darauffolgenden Jahr im Rahmen einer Workshop-Serie zur REIF-Ökosystem-Governance weiterentwickelt.

Ebenfalls erfolgte in diesem Jahr zur rechtskonformen Umsetzung der Data Governance eine stetige Analyse des jeweils aktuellen Entwurfs des Data Governance Acts (DGA-E), wobei kontinuierlich geprüft wurde, inwieweit die REIF-Plattform in dessen Anwendungsbereich fällt und welche rechtlichen Anforderungen sich daraus für die Plattform-Governance ergeben. Außerdem wurde eine Erfassung und Bewertung der rechtlichen Anforderungen hinsichtlich Authentizität und Qualität der Datenbestände im Zusammenspiel mit den anderen Anwendungspartnern herausgearbeitet. Des Weiteren konnte die geplante datenrechtliche Einordnung erfolgen. Dazu wurde zur Abfrage und Erfassung der im Projekt verwendeten Daten eine Data-Governance-Tabelle entwickelt, an alle Teilprojekte versendet und anschließend ausgewertet. Darüber hinaus wurden die notwendigen Parameter zur Beschreibung der auf der Plattform angebotenen Daten und Services unter Berücksichtigung der Digitalen-Inhalte-Richtlinie und der damit einhergehenden Schuldrechtsreform erarbeitet. Zudem wurden im Ansatz auch die sich

aus dem DGA-E ergebenden Voraussetzungen und Anforderungen an die Datenportabilität im Zusammenspiel von Recht und Technik erarbeitet. Dies konnte jedoch noch nicht final spezifiziert werden, da der DGA-E zu diesem Zeitpunkt noch nicht verabschiedet war.

Auf dieser Basis wurden erste Modellansätze für die Data-Governance-Konzeption entwickelt, welche neben datenschutzrechtlichen Aspekten auch die rechtskonforme Nutzung von Daten sowie marktrelevante Kriterien und Wettbewerbspositionen in der Konzeption der Plattform berücksichtigen, wodurch eine weitestgehende Offenheit gesichert werden soll.

Aufgrund der weiteren Entwicklungen und der unmittelbaren Auswirkungen des DGA auf das ursprüngliche Vorhaben wurde die Analyse der rechtlichen Einflüsse bis zum Projektende fortgeführt. So stand nach Inkrafttreten des DGA im Jahr 2022 endgültig fest, dass der gewählte Ansatz eines hybriden Plattformmodells mit der gemäß Art. 12 lit. a) DGA erforderlichen Trennung der Datenvermittlung von anderen Services, die nicht nur der Erleichterung des Datenaustauschs dienen (Art. 12 lit. d) und e) DGA), nicht vereinbar ist.

Zudem wurde die im Vorjahr stattgefundenene Erfassung und Bewertung der rechtlichen Anforderungen hinsichtlich Authentizität und Qualität der Datenbestände in diesem Jahr zusammen mit den anderen Anwendungspartnern untersucht und die neuen rechtlichen Herausforderungen (Data-Act-E, DGA, DSA, DMA) im gleichen Zug herausgearbeitet. Aufgrund der Vorarbeiten wurde in einem gemeinsamen Workshop durch das Projekt beschlossen, dass sich das Angebot auf der Plattform aufgrund der Änderungen durch den DGA auf Services beschränken soll. Vor diesem Hintergrund wurde in diesem Arbeitspaket nach alternativen Konzepten für den Betrieb der Plattform recherchiert, welche anschließend im Konsortium vorgestellt und diskutiert wurden.

Im Jahr 2023 wurden ergänzend die rechtlichen Anforderungen an die Plattformzugänglichkeit und eine mögliche Plattformbewertungsfunktion rechtlich überprüft und eine entsprechende, umfassende Anpassung an die rechtlichen Gegebenheiten vorgenommen. Die Zulieferung des Outputs erfolgte über einen schriftlichen Beitrag zum Governance-Konzeptpapier des TP I, das in diesem Jahr durch die Konsortialführung veröffentlicht wird. Darüber hinaus erfolgte in diesem Jahr die Erstellung der Data-Governance-Konzeption sowie des Ergebniskontroll- und des Abschlussberichts unter Berücksichtigung der vorangegangenen Ergebnisse bzw. unter Adaption der damit einhergehenden Abweichungen. Eine rechtliche Plattform-Gesamtkonzeption wird mit einer zu diesem Thema geplanten Veröffentlichung Ende 2023 vorgelegt.

### **Anforderungen an die technische Gestaltung**

Im Jahr 2021 erfolgte eine Erfassung und Bewertung der rechtlichen Anforderungen hinsichtlich Authentizität und Qualität der Datenbestände in Zusammenarbeit mit anderen Anwendungspartnern. Hierbei wurden rechtliche Anwendungsmöglichkeiten von Smart Contracts zur vertraglichen Abwicklung am Beispiel eines Lizenzvertrages rechtlich untersucht und in diesem Zuge gemeinsam mit der ARXUM GmbH die technische Darstellbarkeit sowie die Bewertung und Umsetzbarkeit überprüft. Dadurch kam man zu dem Ergebnis, dass auf der REIF-Plattform unechte Smart Contracts eingesetzt werden sollen, bei denen der Vertragsschluss individuell, die Vertragsdurchführung dagegen automatisiert über die Blockchain ausgeführt wird.

Dazu bildete die HSH zusammen mit den Partnern (Fraunhofer, Tiki, Spicetech) eine Fachgruppe zum Thema Datenqualität. Im Rahmen dieser Zusammenarbeit wurden unter anderem auch die Definitionen des Datenqualitätsbegriffes untersucht und erste Ansätze zur Leistungsbeschreibung eines Datenproduktes mit verschiedenen Dimensionen erarbeitet. Außerdem wurde die mögliche Anbindung der REIF-Plattform an das Gaia-X-System untersucht, weshalb die Anwendbarkeit des Federation Services „Contract“ von Gaia-X auf den Datenlizenzvertrag der REIF-Plattform rechtlich überprüft wurde. Nach umfassender rechtlicher Prüfung wurde im Projekt festgelegt, dass eine Anbindung zwar grundsätzlich möglich wäre, für die REIF-Plattform aufgrund mangelnder zeitlicher Kapazitäten jedoch nicht umgesetzt werden kann.

Im Jahr 2022 wurde die Recherche zu den Smart Contracts vor allem im Hinblick auf den Stand der Technik sowie die rechtlichen und technischen Sicherheitsanforderungen fortgeführt und auf weitere

Vertragstypen (Datenlieferungs- und Dienstvertrag) ausgeweitet. Dabei erfolgte die Prüfung der technischen Darstellbarkeit sowie der Bewertung und Umsetzbarkeit in Zusammenarbeit mit der ARXUM GmbH. Im Ergebnis wurde für die REIF-Plattform festgehalten, dass Smart Contracts auf der REIF-Plattform, trotz umfassender technischer Umsetzungsmöglichkeiten, ausschließlich für die Benutzer-Authentifizierung, die Registrierung und die Überprüfung der Zugriffsberechtigung zum Einsatz kommen sollen.

Zur Erarbeitung der rechtlichen Anforderungen an ein KI-System wurden im Jahr 2020 unterschiedliche Reifegradmodelle rechtlich recherchiert und deren Einsatz im Projekt geprüft. Hierbei zeigte sich, dass die Vernetzung im Ökosystem und die unterschiedliche Struktur von Daten, Rechten und Inhabern ein individuelles Modell und ein modulares Vorgehen erfordern. Die rechtliche Recherche zu den KI-Reifegradmodellen wurde im darauffolgenden Jahr fortgesetzt, wozu die HSH die rechtliche Entwicklung in Form von Gesetzen, Rechtsprechung und Best Practices überwachte. Hierbei wurden auch die Anforderungen an eine Vorabprüfung für eine Datenschutzfolgenabschätzung mitberücksichtigt.

In den Jahren 2022 und 2023 erfolgte zunehmend die stetige rechtliche Prüfung des aktuellen Entwurfs des KI-Gesetzes (KI-VO-E) sowie dessen rechtliche Auswirkungen und Konsequenzen auf die verschiedenen Teilbereiche des Projekts. Gleichwohl diese kontinuierlich herausgearbeitet und den Partnern entsprechend kommuniziert wurden, konnte auch bis zum Ende des Projekts keine finale Aussage zu den konkreten Auswirkungen getroffen werden, da die KI-VO-E noch nicht in Kraft getreten ist und der Gesetzesentwurf ggf. weiteren, einschlägigen Änderungen unterworfen werden könnte.

## Literatur

- Evans, D. S. 2012. Governing Bad Behavior by Users of Multi-Sided Platforms. In *Berkeley Technology Law Journal*.
- Hein, A., M. Schrieck, M. Wiesche und H. Krcmar. 2016. Multiple-Case Analysis on Governance Mechanisms of Multi-Sided Platforms. In *Multikonferenz Wirtschaftsinformatik*. Ilmenau.
- Manner, J., D. Nienaber, M. Schermann und H. Krcmar. 2013. Six Principles for Governing Mobile Platforms. In *Proceedings of the 11th International Conference on Wirtschaftsinformatik*. Leipzig.
- Tiwana, A. 2014. *Platform ecosystems: Aligning architecture, governance, and strategy*. Waltham, MA: Morgan Kaufmann.
- Wiesche, M., P. Sauer, J. Krimmling und H. Krcmar (Hrsg.). 2018. *Management digitaler Plattformen: Konzeption und Realisierung eines offenen Ökosystems für intelligente Mobilitätsdienste in der Smart City*. Wiesbaden: Springer Gabler.

## 2.1.2 Teilprojekt II – Verlustoptimierte Beschaffungs- und Verkaufsstrategie

Weber, Judith (Spicetech GmbH), Petrausch, Ralf (tegut... Logistik GmbH & Co. KG), Barthelmé, Nicolas (CSCP), Maier, Sebastian (Fraunhofer IGCV)

Aktive Partner: **Spicetech GmbH**, CSCP, Fraunhofer IGCV, tegut... GmbH & Co. KG

Assoziierte Partner: V-Markt

Als Ausgangspunkt für die Verschwendungsreduzierung entlang der Wertschöpfungskette ist eine optimierte Prognostizierung von Bedarfen des Endverbrauchers unerlässlich. Unter Einbezug des Handels wurden im Teilprojekt II zunächst KI-basierte Prognoseverfahren entwickelt. Diese dienen als Ausgangspunkt für ein sogenanntes „Dynamic Pricing“, bei dem Lebensmittel in Abhängigkeit ihres Mindesthaltbarkeitsdatums (MHD) rechtzeitig so weit im Preis reduziert werden, dass sie verkauft werden können, bevor der Einzelhandel sie entsorgen muss.

### 2.1.2.1 Bedarfsprognose

Die Bedarfsprognose in REIF wurde basierend auf dem bestehenden Prognosesystem PREDECY der Spicetech GmbH entwickelt. PREDECY ist ein webbasierter Prognoseservice für zeitlich veränderliche Größen, der ursprünglich dazu konzipiert wurde, unter Einbeziehung insbesondere der Wettervorhersage tägliche Absatzprognosen für Getränkehersteller mit einem Prognosehorizont entsprechend der Wettervorhersage, d. h. in der Regel 16 Tage, zu liefern. Im Rahmen des REIF-Projekts wurde der Service umfangreich erweitert, um auch den Bedürfnissen anderer Unternehmen aus der Lebensmittelindustrie gerecht zu werden.

Daher war das erste Ziel bezüglich der Bedarfsprognose eine **Erhebung der Anforderungen an KI-basierte Prognosen** seitens des Lebensmitteleinzelhandels und verschiedener Lebensmittelhersteller aus dem REIF-Ökosystem (AP II.1.1). Dazu wurden in mehreren Workshops die Anforderungen von tegut... an ein Prognosesystem erhoben. Diese Anforderungen wurden anschließend mit den weiteren Use Case Partnern Westfleisch, Hochland und V-Markt komplettiert. Darüber hinaus wurden Interviews mit externen Industrieakteuren wie Metro, Alnatura, Danone oder Nestlé geführt, um ein breiteres Anforderungsprofil an Prognosewerkzeugen zu erhalten. Konkret wünschten sich die befragten Partner die Möglichkeit, neben Einzelprodukten auch ganze Produktgruppen vorhersagen zu können. Insbesondere Partner in den vorgelagerten Wertschöpfungsstufen benötigen darüber hinaus oft langfristige Prognosen mit Prognosehorizonten von 3 bis 18 Monaten. Um das bestehende System PREDECY auch für Großkunden wie tegut... nutzen zu können, musste dieses darüber hinaus in die Lage versetzt werden, die entsprechenden Datenmengen performant und sicher handzuhaben und nächtlich Prognosen für mehrere 10.000 Artikel bereitzustellen. Darüber hinaus sind gerade für Unternehmen mit mehr als einer Handvoll Produkten effiziente Auswertungs- und Monitoringfunktionen unabdingbar, um schnell einen Überblick über die aktuelle Prognosegüte erhalten zu können, ohne jeden Artikel einzeln ansehen zu müssen. Spezifisch für den Kontext von REIF ergab sich außerdem die Notwendigkeit, Prognosen sicher und anonymisiert zwischen den Akteuren des Wertschöpfungsnetzes austauschen zu können.

Auf Basis dieser Anforderungen sollten im nächsten Schritt **spezifisch für die Anwendungsfälle in REIF optimale KI-Algorithmen bzw. Kombinationen dieser konzipiert (AP II.2.1) und implementiert (AP II.2.3)** werden. Insgesamt wurden sechs wesentliche Bausteine konzipiert und im weiteren Projektverlauf umgesetzt:

1. Das **sichere Lernen aus Prognosen anderer Wertschöpfungsebenen**, z. B. firmenübergreifend, wurde prototypisch implementiert. Für das firmenübergreifende Lernen werden Prognosen eines Partners datenbankseitig über eine  $n \times m$  Abbildung als Feature-Vektor für die Prognosen eines anderen Kunden anonymisiert bereitgestellt. Auf diese Weise kann nachvollziehbar gewährleistet werden, dass immer nur aus Daten gelernt werden kann, für welche auch eine explizite Freigabe

vorliegt. Zusätzlich öffnen sich Optionen zur Integration der Verwaltung von Freigaben und Rechten über externe Services.

2. **Nachvollziehbarkeit und Monitoringprozesse** werden durch systematisches Speichern aller KI-Trainingsläufe und Verlinkung auf alle Daten, aus denen gelernt wurde, ermöglicht. Alle KI-Entscheidungen – und Fehlentscheidungen – werden so auch retrospektiv analysier- und nachvollziehbar. Die Monitoringprozesse wurden durch interaktive Nutzerfunktionen zur Analyse der IST-Performance (Genauigkeit) von KI-Prognosen im laufenden Betrieb über Monate, Wochen und Tage hinweg sowie im Direktvergleich mit anderen Produkten oder Standorten erweitert.
3. Die Notwendigkeit einer **automatischen Trenderkennung und -korrektur** wurde durch eine Analyse der Fourierkoeffizienten bei zeitlicher Verschiebung des Analyseintervalls automatisiert ermöglicht. Langfristtrendkorrekturen wurden erzeugt, erprobt und prototypisch genutzt.
4. **Skalierung:** Die Ausführung von PREDECY wurde derart weiterentwickelt, dass zu berechnende Prognosen anhand der jeweiligen Lizenz automatisiert erkannt und eingeplant werden. Die Abarbeitung dieser sogenannten „task queue“ erfolgt derzeit parallel durch zwei Server, die jeweils bis zu 32 Prognosen gleichzeitig berechnen können. Bei Bedarf kann die Berechnung auf nahezu beliebig viele Server verteilt werden. Dadurch kann PREDECY schnell und sicher auf eine größere Anzahl Kunden erweitert werden.
5. Die **Vorhersage von Produktgruppen** wird über ein gesondertes Produkthierarchiekonzept ermöglicht. Optionen zur Aggregation von Daten zu aggregierten KI-Prognosen für Produktgruppen wurden für Produkte mit einer beliebigen Anzahl an Hierarchieebenen implementiert. Nach dem gleichen Prinzip können mehrere Standorte und Kundengruppen zu einer übergeordneten Einheit aggregiert werden.
6. Die Anforderung hin zu **Langfristprognosen** wird dadurch erfüllt, dass die limitierenden Einflussvektoren aus der Wettervorhersage, die klassischerweise den Prognosehorizont auf 16 Tage begrenzt, automatisiert in ein klimatisches Saisonmodell überführt werden. Dies erfolgt auf Basis der realen Wetterdaten und hat sich u. a. bei Jahresprognosen für Hochland bewährt. Eine Automatisierung dieses Prozesses ist ebenso erfolgt.

Als Nächstes mussten **die entwickelten Algorithmen um passende Tuning-Verfahren ergänzt** werden (AP II.2.5). Alle KI-Modelle und die für die Tuningverfahren maßgeblichen Validierungszeiträume können seit der Erweiterung direkt in der REST-API auf ihre Prognosegenauigkeit hin geprüft werden. Jegliche Verfahren zum systematischen Tuning, d. h. zur Prüfung, ob andere KI-Modelle und Pre- und Postprocessing Konfigurationen zu besseren Ergebnissen führen, wurden so verbessert, dass das Tuning auf separaten Rechner-Ressourcen vorgenommen werden kann. Hierbei ist auch wichtig zu akzentuieren, dass die metrische Überwachung des Erfolgs durch Tuning direkt persistent in der Datenbank sichergestellt wird. Im weiteren Verlauf wurden die **Prozesse zur Validierung und zum Tuning zu großen Teilen automatisiert** (AP II.3.3). Die Berechnung der Validierungsgüte und der Genauigkeit historischer Prognosen wurde zudem vom Frontend in einen separaten Backend-Prozess verlagert, dessen Ausführungslogik analog zur oben beschriebenen Berechnung der Prognosen über eine Task Queue abläuft. Dadurch kann einerseits die Performance der Webapplikation weiter verbessert werden und die Prognosegüten können auch in der Vergleichsansicht zwischen verschiedenen Prognoseläufen angezeigt werden; andererseits erlaubt diese Änderung das kundenspezifische Definieren relevanter Kenngrößen für die Prognosegüte.

Ein weiteres Zwischenziel war die **Weiterentwicklung der PREDECY-Datenbank**, die sicherstellt, dass die Skalierung und Automatisierung gewährleistet ist (AP II.3.1). Dafür wurden unter anderem Archivierungsfunktionen programmiert, die alte Prognosen in eine separate Tabelle auslagern, um Performance-Problemen durch zu große Tabellen vorzubeugen. Daneben wurde eine Funktionalität eingebaut, die es ermöglicht, einzelne Vektoren in der Datenbank als deaktiviert zu kennzeichnen.

Die Backup- und Recovery-Strategie wurde ebenfalls auf ein inkrementelles Vorgehen umgestellt.

Basierend auf dem Kundenfeedback wurden, **wie in AP II.3.2 geplant, weitere Funktionen zur Datenanalyse und zum Datenaupload und -download in das Frontend integriert**. Diese Funktionen



beinhalten: Anpassung der Benutzeroberfläche an die jeweilige Branche und Benutzer für eine einfache Verständlichkeit, konfigurierbare und aggregierte Exporte von Prognosen direkt aus dem Frontend, klare und einfache Anzeige der aktuellen Leistung für nicht technische Benutzer sowie verbesserte Leistung und Navigation der Webanwendung, wie beispielsweise schnelleres Laden von Drop-Down-Menüs und die Möglichkeit, Feature-Vektoren aus CSV-Dateien hochzuladen.

Abschließend mussten **alle spezifischen Weiterentwicklungen getestet und integriert** werden (**AP II.2.6**). Zur Abdeckung der hohen Varianz an Produkten und der damit einhergehenden hohen Anzahl von Prognosen wurde ein systematisches persistentes Logging in der Datenbank implementiert. Um ein Relearning der Tausenden KI-Modelle konzertieren zu können, wurden Methoden implementiert, die z. B. wochentagsabhängig oder nach Überschreiten eines KI-Modellalters ein Relearning triggern. Operative Gesamtintegrationstests sicherten insbesondere ein effizientes Zusammenspiel zwischen Prognosen und dynamischen Preisen ab.

Neben der Weiterentwicklung der Softwareapplikation hatte auch die **praktische Erprobung und Bewertung der KI-basierten Absatzprognosen** bei den Partnern **tegut...** (**AP II.1.3**), **V-Markt** (**AP II.1.4**), **Westfleisch und Hochland** (**AP II.1.5**) einen hohen Stellenwert.

Um den Einstieg in PREDECY zu erleichtern, wurden vom CSCP umfangreiche Schulungsunterlagen sowohl für PREDECY als auch für das Pricing Modul DYNAMICS erstellt (Abbildung 8). Eine auf die Datenmenge und bestehende IT-Landschaft von tegut... angepasste Schnittstelle zum Austausch insbesondere der komplexen „Bewegungsdaten“ (Lieferungen, Bruch und Verderb, Bestände ...) wurde spezifiziert und implementiert. Diese sogenannte „ZEITREIF-API“ wurde in mehreren Optimierungsschleifen auf Funktion und Performance optimiert. Für die Bewertung der KI-Prognosen wurden zunächst für etwa 500 Produkte Validierungsläufe durchgeführt. Prognosen wurden wöchentlich operativ durchgeführt und etwaige Edge Cases systematisch analysiert. Die Hochland-Jahresprognosen wurden unter Verwendung von tegut...-Prognosen über den implementierten Modus „Shared-Learning“ erzeugt. Die zusätzlich zu den Hochland-internen Daten dadurch bereitgestellten Feature-Vektoren wurden im KI-Prozess überwiegend mit hohen Korrelationen zum Lernen verwendet. Diese Erprobung zeigt das hohe Potential für firmen- und wertschöpfungsübergreifendes Lernen von KI-Modellen. Allerdings besteht in der Praxis die Schwierigkeit, dass der Planungs- und damit auch der Prognosezeitraum immer kurzfristiger wird, je weiter hinten in der Wertschöpfungskette man sich befindet. In unserem Beispiel beträgt der Prognosehorizont bei Hochland normalerweise zwölf Monate, bei tegut... dagegen nur zwei Wochen. Daher müsste in der Praxis vom „Prognosespender“ oft zum Zwecke des Prognoseaustauschs eine längerfristige Prognose erstellt werden, als für dessen eigene Zwecke notwendig ist. Auch die Daten der Fa. V-Markt erreichen vollautomatisiert und nächtlich aktualisiert das Prognose-Backend von PREDECY. V-Markt hat hierfür unter Anleitung der Spicetech eine eigenständige Implementierung der PREDECY-API vorgenommen. Einzelne Produkte zeigten ohne weitere V-Markt interne Feature-Vektoren Prognosegenauigkeiten von über 90 Prozent. Daten der Fa. Westfleisch wurden ebenfalls erfolgreich in das Prognose-Backend importiert. Die Prognosequalität für die umsatzbezogenen stärkere Hälfte der Produkte war in diesem Fall ausreichend, um eine gezieltere Planung zu ermöglichen.



Abbildung 8: Schulungsunterlagen für PREDECY (eigene Darstellung)

### 2.1.2.2 Dynamische Preisanpassung

Das zweite Kernelement des Teilprojekts war die Entwicklung eines Algorithmus zur Preisreduktion in Abhängigkeit des Mindesthaltbarkeitsdatums (MHD) für den Lebensmitteleinzelhandel.

Im Zuge der **Erhebung der Anforderungen an eine dynamische Preisgestaltung aus Sicht des Handels und der Endkunden** (AP II.1.2) im Rahmen von Anforderungsworkshops wurde schnell klar, dass die größte Herausforderung darin besteht, zu ermitteln, wie viele Artikel mit welchem MHD aktuell im Regal stehen, da das MHD in den aktuell gebräuchlichen Barcodes nicht verschlüsselt wird. Alternative Barcode-Technologien, die dazu in der Lage sind, das MHD zu erfassen, sind aufgrund der in aller Regel inklusive Barcode vorproduzierten Verpackungen aktuell wirtschaftlich nicht darstellbar.

Als weitere wichtige Ergebnisse stellten sich die notwendigen Prozessänderungen am PoS dar.

Außerdem stand die technische Realisierbarkeit im Zusammenspiel Barcode (auf dem Produkt), Preisschild (am Regal) sowie Kassensystem im Schwerpunkt der Diskussion. Am 21. April 2020 wurden die Ziele zu Prognoseverbesserung und dynamischer Preisgestaltung im Dialogforum Groß- und Einzelhandel zur Reduzierung von Lebensmittelverschwendung vorgestellt und Anforderungen der anwesenden Akteure abgefragt. Zum besseren Verständnis der Kundenperspektive auf dynamische Preisgestaltungen wurde eine Literaturanalyse durchgeführt und existierende Modelle und Anbieter analysiert und verglichen (Abbildung 9).



Markt					
Software	✓	✓	✓	✓	✓
KI-Algorithmus	✓	✓	✓	✓	✓
Elektronische Preisschilder	✓	✓	✓		
Manuelle Aufkleber	✓			✓	✓
Erweiterter Barcode		✓	✓		
App-Ergänzung			✓		✓

Abbildung 9: Vergleich bestehender Anbieter für dynamisches Markdown Pricing (eigene Darstellung)

Der für das REIF-Projekt identifizierte USP ist die Ermittlung einer positiven Liste aller sogenannten MHD-Artikel, die im Markt reduziert werden müssen: Mitarbeitende im Handel müssen entsprechend nicht mehr alle Artikel und Regale auf MHD-Gefährdung prüfen, sondern reduzieren gezielt und effizient die von der KI identifizierten Produkte zu den von der KI berechneten Preisen.

Als wichtige Zielsetzung für die praktische Erprobung wurde zusätzlich definiert, wie Kunden auf unterschiedliche Preisänderungen bei unterschiedlichen Produkten reagieren und wie die Kommunikation am PoS optimalerweise erfolgen sollte.

#### Auf Basis der gewonnenen Erkenntnisse erfolgte im nächsten Schritt die **Konzeption des Systems zur dynamischen Preisreduktion (AP II.2.2)**.

Das CSCP hat unterschiedliche vergleichbare Konzepte und Anbieter zur Preisreduktion in Supermärkten in ganz Europa analysiert und Erfolgsfaktoren für eine praktikable Umsetzung im Markt (im Hinblick auf Arbeitsprozesse, Wissen der Mitarbeitenden, technischen Voraussetzungen: s. Matrix oben) sowie notwendige Erläuterungen und Kommunikanten an den/die KundInnen untersucht. Diese Erkenntnisse haben die Konzeption des Systems zur dynamischen Preisanpassung bei tegut... geleitet.

Für den Gesamtprozess der Preisreduktion wurde ein Konzept unter Berücksichtigung der Erfordernisse aus IT, Filiale, PoS, Marketing und Kommunikation erarbeitet. Daraus ergibt sich ein optimaler

Ablauf aller Prozesse zur Bestandsreduzierung in der Frische unter Berücksichtigung aller Einflussfaktoren. Dieser Prozess bedingt ein Zusammenspiel zwischen KI und Filialmitarbeitenden. Für eine mögliche schnelle Umsetzung im Projekt wird eine Minimalversion dieses Konzepts erarbeitet, das folgende Dimensionen berücksichtigt:

1. **Praktische Umsetzbarkeit im Markt:** Die drei Testmärkte wurden mit ESL-Preisschildern (elektronische Anzeige von unterschiedlichen Preisen am Regal) sowie tragbaren Etikettendruckern (Sticker-Druck für die von der KI berechneten und reduzierten Preise) ausgestattet
2. **Kommunikation an den Endkunden:** Dynamische Preise sind in Deutschland neu und für die meisten Verbraucher noch unbekannt und ungewohnt. Dazu werden MHD-gefährdete Produkte eher misstrauisch betrachtet und oft vom Handel als Ramschware präsentiert und abverkauft. Wie sollten also dynamisch reduzierte Preise und MHD-gefährdete Ware am PoS so kommuniziert werden, dass Verbraucher Vertrauen in Produkten mit kurzer Haltbarkeit und reduzierten Preisen schöpfen und zusätzlich dank positiver Anreize zur Lebensmittelrettung motiviert werden? Hierfür wurden Kommunikationsinhalte entwickelt:
  - Kreation einer neuen PoS-Figur, die Konsumenten einen vereinfachten Zugang zu den Themen der Lebensmittelverschwendung und der getesteten Preisdynamik am Regal sowie Vertrauen und positive Assoziationen zu kurzen MHDs und Preisreduktionen schafft (Abbildung 10). Die Figur verkörpert die KI und rechtfertigt auf spielerische Weise das Vorhandensein von unterschiedlichen Regalpreisen für ein Produkt.
  - Integration der PoS-Figur auf relevanten PoS-Materialien und Kommunikationsflächen bis hin zu den von der KI reduzierten Produkten



Abbildung 10: Die Werbefigur „Zorrero“ wurde aus dem REIF-Logo abgeleitet und wird zusätzlich auf der neu entwickelten REIF-Informationssseite [www.ki-lebensmittelretter.de](http://www.ki-lebensmittelretter.de) (inkl. Erklärvideo) eingesetzt (eigene Darstellung)

3. **Schulung des Marktpersonals:** Umfangreiche Schulungsinhalte wurden in Zusammenarbeit mit tegut... entwickelt, um das Marktpersonal für den Test der dynamischen Preise sowie die dazu gehörenden Maßnahmen und neue Vorgehensweise am PoS zur Reduzierung MHD-gefährdeter Ware zu schulen. Auch die wichtigsten Q&As zur Beantwortung möglicher Konsumentenrückfragen im Markt wurden ausgearbeitet.
4. **Wirkungsmessung:** Zusätzlich zu den „klassischen“ Kosten-KPIs erfolgte eine erste Analyse möglicher KPI zur Berechnung eines positiven Fußabdrucks (CO<sub>2</sub>, Umwelt ...) für die dank KI und dynamischen Preisen geretteten Lebensmittel. In einem KPI-Workshop mit Spicetech und tegut... wurden die verschiedenen Optionen (u. a. PEF und „Calculator for impacts for food waste prevention actions“) vorgestellt sowie die Verfügbarkeit der für die KPI-Berechnung erforderlichen Daten diskutiert.

Algorithmisch war ein zweistufiges Verfahren zu entwickeln, welches anhand der bekannten Daten (Lieferung inkl. MHD, Verkäufe, Bruch und Verderb) einen Bestand pro MHD abschätzt. Auf Basis dieser Schätzung und der prognostizierten Verkäufe bis zum Ablauf des MHD wird im zweiten Schritt eine Preisreduktion ermittelt. Hierzu wurde ein neuartiger KI-Algorithmus entworfen, der aus historischen Offline-Verkaufsdaten optimale Modellparameter erlernt, welche später als Grundlage für die Preis-anpassung in den Filialen genutzt werden. Hierbei erfolgt eine Simulation sämtlicher relevanter Vorgänge in einer virtuellen Supermarktfiliale über eine vordefinierte Zeitspanne (Abbildung 11). Über ein mathematisches Modell, welches die Nachfrage gezielt über das Alter der Produkte steuert, wird in der virtuellen Filiale das Einkaufsverhalten von Kunden simuliert und produktspezifisch eine dynamische Preis-anpassungsstrategie verfolgt. Durch maschinelles Lernen können bereits in der Simulation die Modellparameter für die Preis-anpassungsstrategie derart ermittelt werden, dass die Lebensmittelver-schwendung reduziert wird.

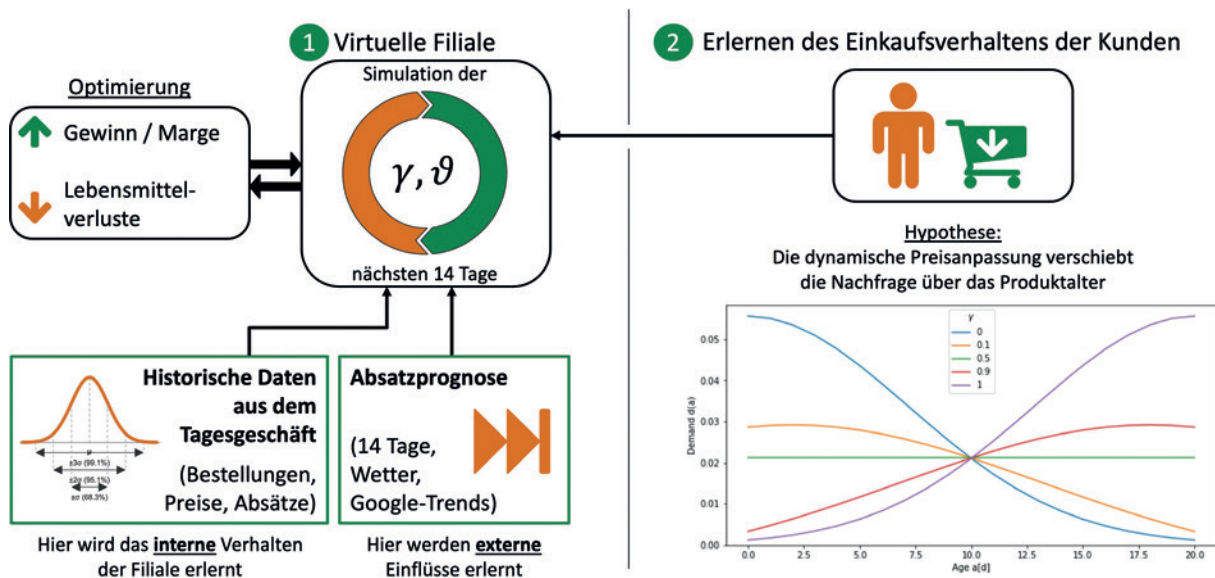


Abbildung 11: Systemelemente des Dynamic Pricing-Algorithmus (eigene Darstellung)

Für den Datenaustausch wurde eine Feinspezifikation der für die Preisintegration notwendigen Erweiterungen aufgenommen und konsolidiert. Besonders relevant war hier die Anforderung, dass nur eine Schnittstelle gesamtheitlich Absatz- und Preisdaten synchronisieren muss. Dazu zählen insbesondere die für die Bestandsschätzung notwendigen Artikelbewegungsdaten (Lieferungen, Verkäufe, Mindesthaltbarkeitsdaten, Bestand, Bruch und Verderb) und spezifische Preisinformationen (Verkaufspreis, Verlustvorgriffe, Aktionen). Hierbei wurde insbesondere die Notwendigkeit eines einfachen Standards identifiziert. Dieser wurde unter dem Namen ZEITREIF-API im Jahr 2021 neu implementiert.

Auf Basis der Spezifikation wurde in (AP II.2.4) **das entwickelte Konzept zur dynamischen Preisreduktion in einen für den Pilotversuch einsatzfähigen Algorithmus überführt**. Grundlage für die Entwicklung des DYNAMICS-Algorithmus ist die von Adenso-Díaz et al. (2017) entwickelte Formel zur Modellierung der Nachfrage für verderbliche Produkte in Abhängigkeit von Produktalter und Preis:

$$\text{Nachfrage (Alter)} = \text{Nachfrage}_{\text{neu, voller Preis}} \times \left[ \frac{\text{Preis (Alter)}}{\text{Preis (neu)}} \right]^{-\text{Preiselastizität}} \times \left[ 1 - \left( \frac{\text{Alter}}{\text{Lebensdauer}} \right)^\beta \right]$$

Die Autoren vereinen in dieser Formel zwei grundlegende Nachfragemechanismen:

1. Die Nachfrage nach einem Produkt nimmt bei einem sinkenden Preis zu. Die Stärke dieser Abhängigkeit wird durch den bereits in der Literatur etablierten Faktor der Preiselastizität beschrieben. Bei einer hohen Preiselastizität ist der Einfluss des Preises auf die abgesetzte Menge besonders hoch.

2. Die Nachfrage nach einem begrenzt haltbaren Produkt nimmt ab, je näher das Produkt seinem Mindesthaltbarkeitsdatum kommt. Der neu eingeführte Faktor  $\beta$  beschreibt auch in diesem Fall die Stärke des Effekts: bei  $\beta = 1$  nimmt die Nachfrage linear ab; bei  $\beta > 1$  bleibt die Nachfrage über einen längeren Zeitraum nahezu stabil und nimmt erst kurz vor Erreichen des MHD ab, während bei  $\beta < 1$  sehr frische Produkte stark bevorzugt werden.

Die im Original von Adenso-Díaz et al. (2017) veröffentlichte Simulationsstudie geht davon aus, dass immer nur ein Produktalter gleichzeitig im Regal steht und dass sich die insgesamt abgesetzte Menge in Abhängigkeit von Preis und Alter stark verändern kann. Beide Bedingungen treffen in einer realen Supermarktsituation in aller Regel nicht zu: Da Supermärkte über keine separaten Lagerkapazitäten außerhalb der Regale verfügen, werden die Regale nach dem First-in-first-out-Prinzip von hinten her mit frischen Produkten aufgefüllt, sodass in aller Regel mehr als ein MHD pro Produkt im Regal steht und vom Kunden gekauft werden kann. Darüber hinaus entscheiden sich Kunden bei Lebensmitteln selten dazu, ein Produkt gar nicht zu kaufen, weil es zu teuer oder zu alt ist. Außerdem achten einige Kunden überhaupt nicht auf das MHD und kaufen einfach das Produkt, das im Regal vorne steht. Trotzdem ist der Modellierungsansatz sinnvoll, um die grundlegenden Mechanismen abzubilden.

Für DYNAMICS wurde daher nicht wie bei Adenso-Díaz et al. (2017) die tatsächlich nachgefragte Menge modelliert, sondern die Wahrscheinlichkeit, dass ein Produkt mit einem bestimmten Alter und Preis bei gegebener Nachfrage ausgewählt wird:

$$\text{Kaufwahrscheinlichkeit} \sim \left[ \frac{\text{Preis (Alter)}}{\text{Preis (neu)}} \right]^{-\text{Preiselastizität}} \times \left[ 1 - \left( \frac{\text{Alter}}{\text{Lebensdauer}} \right)^\beta \right]$$

Um zu berücksichtigen, dass es Kunden gibt, denen das MHD in erster Näherung egal ist, wurden die Kunden in zwei Gruppen aufgeteilt:

1. MHD- und preisbewusste Kunden, deren Kaufwahrscheinlichkeit sich nach der oben definierten Formel richtet
2. Kunden, die mit 100 Prozent Wahrscheinlichkeit das Produkt kaufen, das vorne im Regal steht, d. h. das Produkt mit der geringsten Haltbarkeit.

In der realen Situation sind die Faktoren Preiselastizität und  $\beta$  sowie das Verhältnis der beiden Kundengruppen nicht bekannt. Ebenso wenig ist für einen bestimmten Tag bekannt, aus welchen MHDs sich der aktuelle Bestand zusammensetzt. Hier kommt der Bestandsschätzer ins Spiel: Für die Vergangenheit ist bekannt, wie viel insgesamt jeden Tag verkauft wurde, wie viele Produkte aufgrund einer Überschreitung des MHDs entsorgt werden mussten und wann wie viele Produkte mit welchem MHD geliefert wurden. Nimmt man Werte für die drei unbekannt Faktoren an, dann kann mithilfe der Formel ein begrenzter Zeitraum in der Vergangenheit „nachsimuliert“ werden.

Dazu nehmen wir an, dass am ersten Tag des Simulationszeitraums alles Inventar älter war als die erste im Zeitraum gelieferte Charge. Anschließend kann man ab diesem Tag mithilfe der Formel berechnen, welche Mengen pro Charge und Tag abgesetzt wurden. Wenn nach Ablauf des MHD in der Simulation noch Bestände übrig sind, werden diese als „virtueller Verderb“ gezählt. Mithilfe mathematischer Optimierung kann nun eine Kombination der drei Unbekannten gefunden werden, deren „virtueller Verderb“ den tatsächlich entsorgten Mengen möglichst nahekommt. Gleichzeitig ergibt sich als Ergebnis der Simulation mit den optimalen Parametern auch der tatsächliche Bestand pro MHD für jeden Tag.

Die so ermittelten Faktoren und der aktuelle Bestand pro Charge bilden dann in Kombination mit der Bedarfsprognose die Grundlage für die Preisberechnung: Jetzt wird mithilfe einer Simulation in die Zukunft mit den bekannten Faktoren der optimale Preis pro MHD berechnet.

Aufgrund der aufwendigen Kombination aus Optimierung und Wahrscheinlichkeitsrechnung benötigt DYNAMICS derzeit Rechenzeiten von mehreren Stunden pro Filiale. Daher werden Bestände und Prei-

se schon am Vortag berechnet. Die Artikel werden einzeln bearbeitet, sodass bei einem Abbruch des Algorithmus aufgrund technischer Probleme (Serverausfall o. Ä.) zumindest die bis dahin berechneten Daten vorliegen. Darüber hinaus lässt sich der Workflow auf diese Art parallelisieren.

DYNAMICS ist auch dazu in der Lage, Preisreduktionen für Artikel zu berechnen, von denen nur eine Charge vorhanden ist, indem die Originalformel von Adenso-Diaz et al. (2017) angesetzt wird, sobald der prognostizierte Gesamtabsatz den aktuellen Bestand unterschreitet. Die Chargenbestände und Preise lassen sich sowohl über die ZEITREIF-API als auch über ein webbasiertes Dashboard abrufen.



Abbildung 12: Informations- und Schulungsunterlagen zum DYNAMICS-Algorithmus (eigene Darstellung)

Die Entwicklung des Algorithmus wurde flankiert von der Ausarbeitung einer geeigneten Kommunikationskampagne und Mitarbeiterschulungen am PoS (Abbildung 12). Hierzu führten CSCP, tegut... Marketing, tegut... Werbung und tegut... Bildungsakademie mehrere Workshops und Termine durch. In enger Abstimmung mit tegut... wurden erste Schulungsmaterialien für Mitarbeitende in den Märkten entwickelt, die alle relevanten Aspekte der dynamischen Preisreduktion umfassen. Die Schulungen sollen über das unternehmenseigene digitale Trainingstool umgesetzt werden, und werden durch zusätzliche gedruckte Materialien für die jeweiligen Märkte ergänzt.

Basierend auf einer Konkurrenzanalyse anderer Anbieter und ihrer Kommunikation dynamischer Preissenkungen an die KundInnen sowie der Auswertung von wissenschaftlichen Studien, die Ergebnisse vergleichbarer Fälle bewerten, wurden anhand der oben erarbeiteten Kommunikationsschwerpunkte für die Pilotierung Informationsmaterialien wie ein Regalstopper, ein Informationsflyer und ein Produktaufkleber (Abbildung 13) für die Testmärkte sowie einige Informationsmaterialien für die Kommunikation an die breitere Öffentlichkeit vorbereitet.



Abbildung 13: Produktaufkleber für dynamisch preisreduzierte Produkte (eigene Darstellung)

Im nächsten Schritt wurden alle Ergebnisse konsolidiert, **um sicherzustellen, dass ein Prototyp des Gesamtsystems im Markt zu Testzwecken eingesetzt werden kann** (AP II.2.7).

In Vorbereitung der Erprobung wurde im ersten Quartal 2022 die Lieferung der fürs Pricing notwendigen Artikelbewegungsdaten über die ZEITREIF-API automatisiert, sodass seither alle notwendigen Da-

ten in der erforderlichen Qualität nachtlich fur vier tegut...-Filialen zugeliefert werden. Seit August 2022 erfolgte eine tagliche Berechnung von Chargenbestanden und dynamischen Preisen fur die tegut...-Filiale in Eichenzell, seit Dezember 2022 auch fur die Filiale Fulda-Kaiserwiesen.

Die erste Testfiliale, Eichenzell, wurde in den Sortimenten der Frische mit elektronischen Preisschildern (ESL) und dem dafur notwendigen Zubehor ausgestattet. Dies geschah unter Nutzung maximaler Synergien, indem tegut... die gesamte Filiale mit ESL ausrustete. Es wurde ein IT-technisches Konzept zur Versorgung der ESL mit reduzierten Preisen vorbereitet.

Im Rahmen eines gemeinsamen Workshops wurde gemeinsam mit allen Partnern im TP erarbeitet, anhand welcher Kennzahlen der Test im Markt evaluiert wird. Es wurden quantitative und qualitative Messgroen zur Messung des Erfolgs von KI-gestutzten Prognosen und Preisreduzierungen erarbeitet. Ein Konzept zur Konsumentenbefragung im Rahmen der Erprobung in den Testmarkten wurde entwickelt.

Die erste Moglichkeit ist eine Validierung durch Vergleich von Preisvorschlagen und Filialprozess ohne Preisvorschlage. Dazu werden vier Gruppen gebildet:

- Ein *potenziell gerettetes Lebensmittel* ist ein Lebensmittel, fur das Bruch und Verderb angefallen ist und fur das DYNAMICS eine Preisreduktion berechnet hat.
- Ein *gerechtfertigt reduziertes Lebensmittel* ist ein Lebensmittel, fur das Verderb angefallen ist, aber das die Filiale im Preis reduziert hat und fur das DYNAMICS einen reduzierten Preis vorgeschlagen hat.
- Ein *unnotig preisreduziertes Lebensmittel* ist ein Lebensmittel, fur das kein Verderb angefallen ist und das nicht zu einem reduzierten Preis verkauft wurde, fur das DYNAMICS aber einen Preisvorschlag gemacht hat.
- Ein *nicht gerettetes Lebensmittel* ist ein Lebensmittel, fur das Bruch und Verderb angefallen ist und fur das DYNAMICS keine Preisreduktion berechnet hat.

Ziel ist es, die Gruppen *potenziell gerettetes Lebensmittel* und *gerechtfertigt reduziertes Lebensmittel* moglichst gro und die Gruppen *unnotig preisreduziertes Lebensmittel* und *nicht gerettetes Lebensmittel* moglichst klein zu machen. Der Ansatz kam insbesondere zur Bewertung inkrementeller Verbesserungen am DYNAMICS-Algorithmus im Rahmen der Entwicklung zur Anwendung.

Eine weitere Moglichkeit ist der Vergleich betriebswirtschaftlicher Kennzahlen, wie Bruch und Verderb oder Verlustvorgriff, uber einen definierten Zeitraum. Dabei kann entweder mit der gleichen Filiale im Vorjahreszeitraum verglichen werden, was sich aktuell aufgrund der vielen Sondereffekte (Corona, Ukraine-Krieg) schwierig gestaltet. Eine andere Moglichkeit bietet der Vergleich mit einer anderen Filiale oder einer Gruppe ahnlicher Filialen, die sich in Bezug auf die Kennzahlen normalerweise ahnlich verhalt und die im Untersuchungszeitraum kein Dynamic Pricing anwendet.

Zur weiteren Evaluation des Testmarktes wurden Interviews am PoS mit tegut...-Kunden vorbereitet. Ziel der Evaluation ist, die Akzeptanz von dynamisch reduzierten Preisen und MHD-gefahrdeten Produkten zu messen. Die Kundenbefragung erfolgt in allen drei Test-Filialen an verschiedenen Einkaufsstagen sowohl unter der Woche als auch am Wochenende. Sie wird anhand eines digitalen Fragebogens durchgefuhrt. Die Kundenteilnahme wird uber den Gewinn von Einkaufsgutscheinen incentiviert.

Daruber hinaus hat das CSCP unterschiedliche Methoden zur Auswertung und Wirkungsmessung untersucht, die zur Berechnung der Fuabdrucke der im Test geretteten Lebensmittel angewandt werden:

1. „Calculator for impacts for food waste prevention actions“, das vom Joint Research Center (JRC) von der Europaischen Kommission entwickelt wurde.
2. „Product Environment Footprint“ (PEF), das ebenso von der Europaischen Kommission entwickelt wurde.

Beide Methoden gehen davon aus, dass Einsparungen im Ressourceneinsatz erst erzielt werden konnen, wenn die Manahmen zur Rettung von Lebensmitteln dazu fuhren, dass uberflussige Mengen gar nicht mehr produziert werden. Um die durch REIF ermoglichten Einsparungen dennoch beurteilen zu konnen, wurden folgende Annahmen getroffen:

- Das reduzierte Produkt wird „gerettet“, indem es rechtzeitig abverkauft wird.
- Das reduzierte Produkt ersetzt den Kauf eines nicht reduzierten (und entsprechend nicht MHD-kritischen) Produkts.
- Die Berücksichtigung dieser „Ersatz-Verkäufe“ in den Absatzprognosen führt langfristig dazu, dass die Überschussmengen nicht produziert und entsprechend eingespart werden können.
- Die eingesparten Mengen in der Produktion entsprechen den Mengen an „geretteten“ Lebensmitteln. Deren eingesparte Fußabdrücke können mit dem Calculator berechnet werden.

Auch die dynamische Preisanpassung wurde in einem Pilotversuch erprobt und ihr Nutzen bewertet (AP II.1.6).

Die praktische Testphase umfasste zunächst die Bewertung der Qualität der Bestandsschätzungen. Tägliche Bestands- und Preisvorschläge wurden für die tegut...-Filiale in Fulda-Kaiserwiesen erstellt. Über einen Zeitraum von etwa drei Monaten wurden die Bestände für alle Artikel aus der Preisvorschlagsliste mit einer Restlaufzeit von bis zu drei Tagen physisch gezählt. Der Chargenbestand wurde für etwa 80 Prozent der Artikel mit einer Genauigkeit von maximal plus/minus drei Artikeln abgeschätzt. Die Bestandsschätzung funktionierte besonders gut für „langsam drehende“ Artikel mit weniger als zehn Verkäufen pro Woche. Die Prognosegenauigkeit der Bestandsschätzung erwies sich jedoch als verbesserungswürdig für Aktionsartikel und Doppelplatzierungen. Die wichtige Erkenntnis aus der ersten Evaluation ist somit, dass zu reduzierende Artikel prinzipiell vorhergesagt werden können.

Als nächster Schritt wurde die Validierung der Preisvorschläge durchgeführt. Die Filiale arbeitete dafür die Preisvorschlagsliste aus dem DYNAMICS-Algorithmus ab und passte bei Bedarf die Preisvorschläge nach eigenem Ermessen an. Anschließend wurden die Regalmarkierungen im Rahmen des normalen Filialprozesses durchgegangen und überprüft, welche Artikel vom Pricing-Algorithmus übersehen wurden.

Die Ergebnisse zeigten, dass der Algorithmus etwa 5–10 Prozent der zu reduzierenden Artikel über sah, wobei der häufigste Grund eine fehlgeschlagene Bestandsschätzung war. In einigen Fällen kam es zu Inkonsistenzen zwischen Bestand und Artikelbewegungsdaten, die eine Bestandsschätzung verhinderten. In anderen Fällen passte das Nachfragemodell nicht gut genug zu den Daten, sodass der Gesamtbestand nach der Schätzung um mehr als 30 Prozent vom realen Bestand abwich und es in der Folge zu einem Abbruch des Algorithmus kam.

Die Preisreduktionen durch den Algorithmus fielen in den meisten Fällen höher aus, als es die Filiale aus ihrer praktischen Erfahrung für angemessen hielt. Die Gründe hierfür waren vielfältig: Zum einen lernt der Algorithmus die Preiselastizität aktuell noch nicht aus den Daten, sondern es wird ein fester Wert von außen vorgegeben. Zum anderen passt das Modell u. U. nicht zur Realität und Konsumentende greifen zwar zu einem Artikel, weil er preisreduziert ist, aber die Höhe der Preisreduktion ist für die Entscheidung eher zweitrangig. Zudem fällt die Absatzprognose für langsam drehende Artikel oft sehr gering aus, weshalb der preisabhängige Faktor sehr hoch sein muss, damit der Pricing-Algorithmus überhaupt einen Verkauf annimmt. Ein Beispiel: Wenn ein Artikel nur alle drei Tage verkauft wird, ist die Prognose für jeden Tag nur 0,33; der Algorithmus möchte jedoch einen ganzen Artikel verkaufen und wird deshalb versuchen, die Nachfrage um Faktor 3 zu erhöhen, was eine massive Preissenkung bedeutet.

Im Zeitraum vom 12. bis 30.06.2023 wurde das gesamte Konzept, bestehend aus Bestandsschätzung, Preisvorschlägen und Marketing, jedoch ohne Darstellung der dynamischen Preise auf den elektronischen Preisetiketten, in den tegut...-Märkten Eichenzell, Marburg-Wehrda und Marburg-Cappel erprobt.

Die begleitende Werbekampagne wurde auf vier PoS-Materialien umgesetzt (Abbildung 14). Alle entwickelten Materialien und Sticker wurden vom Marktpersonal eingesetzt und erzeugten so eine gute Sichtbarkeit der Kampagne und eine gute Warenpräsentation der MHD-gefährdeten Produkte. Teilweise wurden die identifizierten MHD-Produkte in den Kühltheken nach vorne gestellt, sodass diese noch besser von den Konsumentinnen und Konsumenten gefunden werden konnten.





Abbildung 14: PoS-Werbematerialien der Zorrero-Kampagne (von links nach rechts): Wobblers mit Vorstellung des Zorrero, Regalstopper mit Zorrero und Kampagnen-Claim, Produktsticker mit Zorrero und Kampagnen-Claim, Flyer mit weiteren Informationen zum Thema „Dynamische Preise“ (eigene Darstellung)

Vom Personal in den Testmärkten gab es gemischtes Feedback zum Testlauf. Der größte Kritikpunkt war der gestiegene Aufwand, der sich vor allem dadurch ergab, dass in der Testphase sowohl mit dem herkömmlichen Prozess als auch mit den Listen aus dem DYNAMICS-Algorithmus parallel gearbeitet werden musste. Darüber hinaus ist das Ausdrucken der Sticker mit dem neuen Preis und das Kleben von neuem Preisetikett plus „Zorrero“-Sticker deutlich aufwendiger als lediglich ein „30%/50%/70% reduziert“-Schild zu kleben (Abbildung 15). Dadurch entstand der subjektive Eindruck, dass der DYNAMICS-unterstützte Prozess, auch wenn er den aktuellen Prozess zu hundert Prozent ersetzen würde, nicht zwangsläufig schneller wäre.

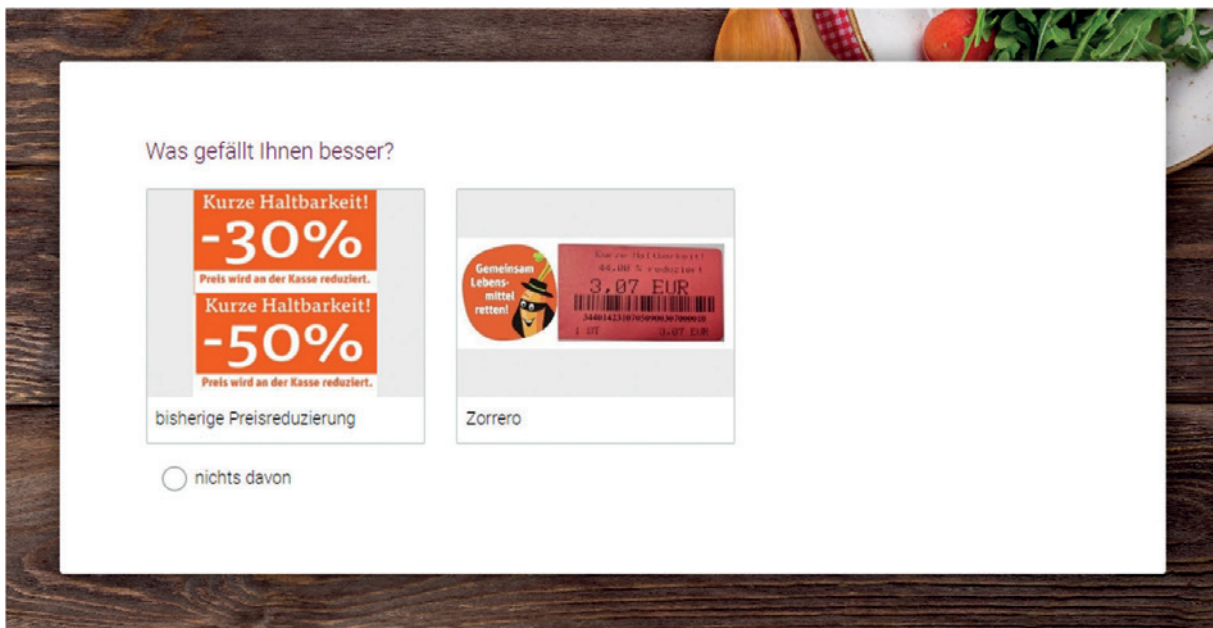


Abbildung 15: Vergleich bisherige Rabatt-Sticker mit Werbematerialien aus der Kampagne (Screenshot aus der Online-Kundenbefragung) (eigene Darstellung)

Sofern für einen Artikel eine Bestandsschätzung vorlag, war diese i. d. R. sehr gut; deutliches Verbesserungspotenzial besteht weiterhin bei der Höhe und beim Zeitpunkt der Preisreduktion. Hier war der Wunsch, den frühestmöglichen Reduktionszeitpunkt pro Sortiment einzeln festlegen zu können.

Die begleitende Marktforschung konnte aufgrund der knappen Zeit gegen Projektende nur online stattfinden. Dadurch hatten die Probanden nicht die Chance, die Kampagne am PoS zu entdecken und zu erleben. Die „Zorrero“-Onlinebefragung lief in der KW 25 (19. bis 25.6.2023) und wurde in die reguläre tegut...-Kundenfilialbefragung integriert. Die gesondert entwickelten Fragen zur Zorrero-Kampagne

wurden Verbrauchern und Shoppers der drei ausgewählten Testmärkte sowie sieben weiteren Filialen ausgespielt. Die Kunden wurden dabei zur Relevanz von MHD-reduzierten Produkten und zum Verständnis und zur Akzeptanz der Zorrero-Kampagne befragt. Darüber hinaus wurde die Kundenpräferenz im direkten Vergleich mit den bisherigen Stickern verglichen.

Von den befragten 113 Personen kaufen 82 Prozent MHD-reduzierte Ware; 30 Prozent gaben an, sogar gezielt danach zu suchen. Die Zorrero-Kampagne erreichte mit durchschnittlich 4,5 von 5 möglichen Punkten sehr gute Akzeptanzwerte und erhielt eine sehr positive Resonanz. Besonders gute Werte erreichte die Kampagne bei den MHD-interessierten Kundinnen und Kunden. Etwas weniger überzeugen konnte sie bei denjenigen, die MHD-Ware nur in Ausnahmefällen kaufen.

Im Vergleich mit den alten Aufklebern erreichte die Zorrero-Kampagne vor allem höhere Sympathiewerte. Die bisherige Reduzierung war bei Verständlichkeit deutlich überlegen, punktete aber auch bei „hilft beim Sparen“ und „regt zum Kauf an“. Im direkten Vergleich befürworteten die Testpersonen die bisherige Form der Preisreduzierung. Aus Kundensicht war der größte Kritikpunkt an der neuen Art der Preisauszeichnung, dass die neuen Etiketten schlecht lesbar sind (schwarzer Druck auf rot) und sowohl die prozentuale Reduzierung als auch der neue Produktpreis auf den ersten Blick schwer zu identifizieren sind. Positiv aufgenommen wurde der neue EAN-Code, der absichert, dass der Rabatt an der Kasse nicht vergessen oder übersehen wird.

Für den Markt in Eichenzell erfolgte im Zeitraum vom 13. bis 23.06.2023 eine quantitative Auswertung des Bestandsschätzungs- und Pricing-Algorithmus hinsichtlich der unterschiedlichen möglichen Berechnungsergebnisse (Abbildung 16).




Abbildung 16: Abbruchgründe für den DYNAMICS-Algorithmus am Beispiel Eichenzell (eigene Darstellung)

Zusätzlich gab die Filiale über einen Abgleich mit dem manuellen Prozess für acht MHD-Daten an fünf Verkaufstagen eine Rückmeldung darüber, welche MHD-Artikel vom Algorithmus nicht identifiziert und für eine Preisreduktion vorgeschlagen wurden. Diese Artikel wurden ebenfalls mit den Logs des DYNAMICS-Algorithmus abgeglichen (Abbildung 17).

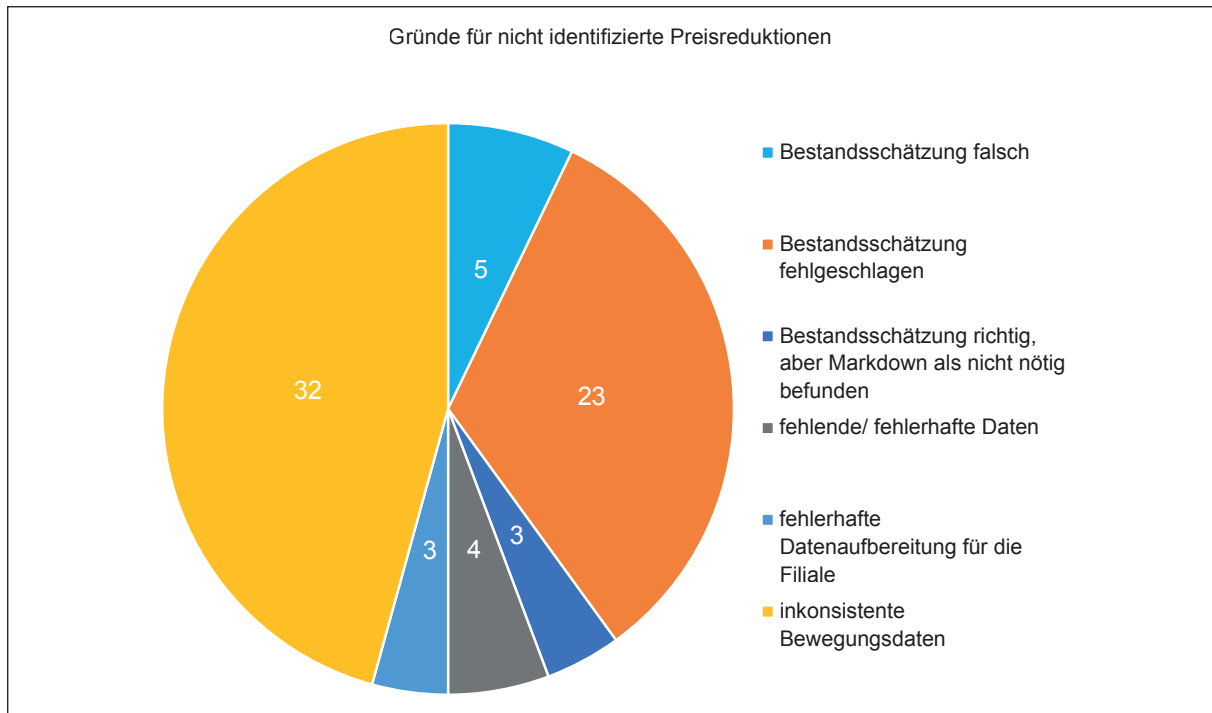


Abbildung 17: Gründe für nicht identifizierte MHD-Artikel am Standort Eichenzell im Zeitraum vom 13.–23.06.2023 (eigene Darstellung)

Aus den Diagrammen ist deutlich zu erkennen, dass der Algorithmus aktuell noch häufiger aufgrund von Fehlern abbricht, als dass er zu einer erfolgreichen Bestandsschätzung und ggf. einem Preisvorschlag kommt. Die relevanten Fehlerfälle sind:

**Inkonsistente Bewegungsdaten:** Für die Bestandsschätzung ist DYNAMICS darauf angewiesen, dass sich die gemeldeten Lieferungen, Verkäufe, Bruch & Verderb, sowie der aktuelle Bestand in einen konsistenten zeitlichen Zusammenhang bringen lassen, d. h. dass sich der Bestand für jeden Tag im Simulationszeitraum wie folgt ergibt:

$$\text{Bestand}_{\text{heute}} = \text{Bestand}_{\text{gestern}} + \text{Lieferung}_{\text{gestern}} - \text{Verkauf}_{\text{gestern}} - \text{Bruch\&Verderb}_{\text{gestern}}$$

Insbesondere dadurch, dass das genaue Lieferdatum aus den von tegut... gelieferten Daten nicht exakt bekannt ist (es liegen lediglich die Warenausgänge vom Zentrallager vor, die die Filiale mit einem Zeitverzug von 0–2 Tagen erreichen können), und aufgrund von Inventurfehlern lässt sich dieser Zusammenhang oftmals nicht konsistent über längere Zeiträume herstellen.

Gegen Ende des Testzeitraums kam es in der Filiale darüber hinaus zu einem Komplettausfall aller Kühlschränke, was zu einer vollständigen Entsorgung aller kühlpflichtigen Produkte führte. Diese Entsorgungsmengen werden auf tegut...-Seite allerdings anders verbucht und tauchten deshalb nicht als Bruch & Verderb in den Daten auf. In der Folge kam es zu einem massiven Anstieg von Abbrüchen aufgrund inkonsistenter Daten.

**Fehlgeschlagene Bestandsschätzung:** In diesem Fall können in der Optimierungsrechnung keine Werte für die Unbekannten ( $\beta$ , Verhältnis Kundengruppen) ermittelt werden, die sicherstellen, dass der in der Simulation entstandene Bruch & Verderb in Summe in etwa dem real entstandenen Bruch & Verderb entspricht. Dadurch weicht die Bestandsschätzung für den letzten Tag in Summe deutlich vom tatsächlichen Gesamtbestand ab und es kann keine zuverlässige Aussage über den Bestand pro MHD getroffen werden. Eine fehlgeschlagene Bestandsschätzung kann unterschiedliche Gründe haben, die sich nicht einzeln auswerten lassen. Auf algorithmischer Seite kann die Optimierung in einem lokalen

Optimum enden, oder das reale Kundenverhalten wird vom Modell nicht hinreichend genau abgebildet. Auf Seite der Eingangsdaten besteht das Problem, dass der gemeldete Bruch & Verderb nicht nur Artikel enthält, die aufgrund einer MHD-Überschreitung entsorgt wurden, sondern beispielsweise auch Artikel, die aufgrund einer unterbrochenen Kühlkette oder beschädigten Verpackung entsorgt werden mussten. Der Algorithmus geht jedoch davon aus, dass jeglicher Bruch & Verderb aufgrund von MHD-Überschreitungen entstanden ist.

Durch die hohe Fehlerrate „erwischt“ der Algorithmus daher nach Angabe der drei Testfilialen nur etwa 30–70 Prozent der zu reduzierenden Artikel und ist daher für einen dauerhaften Einsatz noch nicht geeignet.

Für zukünftige Weiterentwicklungen ergeben sich auf Basis der Testphase insgesamt folgende Empfehlungen:

#### **Qualität der Bewegungsdaten verbessern**

- Bessere zeitliche Zuordnung von Lieferungen
- Getrennte Erhebung von MHD-bedingten Entsorgungsmengen und anderweitig verursachtem Verderb sowie adäquate Berücksichtigung dessen im Algorithmus

#### **Notwendige algorithmische Verbesserungen vornehmen**

- Preiselastizität anhand der durchgeführten Preisreduktionen mitlernen
- Möglichkeit schaffen, Reduktionszeitpunkte pro Sortiment einzugrenzen
- Preise nicht mehrfach reduzieren, um ein doppeltes Kleben von Stickern zu vermeiden

#### **Prozess für die Filiale vereinfachen**

- Dadurch, dass der Algorithmus auf Modellvorstellungen beruht und nicht immer zu einem positiven Berechnungsergebnis kommt, ist eine 100%ige Identifikation aller MHD-gefährdeten Artikel nicht möglich. Daher müssen die Listen für die Filialen in Zukunft so aufbereitet sein, dass sie für die Artikel, bei denen die Berechnung fehlgeschlagen ist, zumindest einen Hinweis auf die gelieferten MHDs enthalten, anhand derer die Filiale gezielt prüfen kann, ob sich noch Restbestände im Regal befinden.
- Vereinfachtes Ausdrucken von neuen Preisetiketten (z. B. durch direkte Übertragung der Preisdaten an den Etikettendrucker) und Zusammenlegen von Zorrero & neuem Barcode auf einen Sticker

#### **Kampagnen-Design & Produktpräsentation**

- Um die Sichtbarkeit der zu rettenden MHD-Produkte weiter zu erhöhen, könnte zukünftig eine Art „Retter-Regal“ getestet werden.
- Der neue rote Preis-Sticker, der in Kombination mit dem Zorrero auf die MHD-Produkte geklebt wird, sollte hinsichtlich Lesbarkeit optimiert werden, sodass neben einem verbesserten Kontrast des Druckes der %-Wert der Preisreduzierung schnell erkannt werden kann und der neue Produktpreis lesbarer wird.
- Auch aus Marketingsicht ist die Integration von Preisreduktion & Zorrero auf einem Sticker sinnvoll, denn diese Informationen gehören zusammen und ergeben erst Sinn, wenn sie im Zusammenhang wahrgenommen und verstanden werden.

### **2.1.2.3 Integration**

Ziel der letzten beiden Arbeitspakete war eine Integration der Ergebnisse des Teilprojekts in die REIF-„Plattform“ über lesende sowie schreibende Schnittstellen (AP II.4.1, AP II.4.2).

Basierend auf den Applikationen der Absatzprognose und der dynamischen Preisanpassung wurde in Zusammenarbeit mit TP I ein Beispielservice auf der REIF-Plattform konzeptioniert, wie er in Abbildung 18 dargestellt ist.

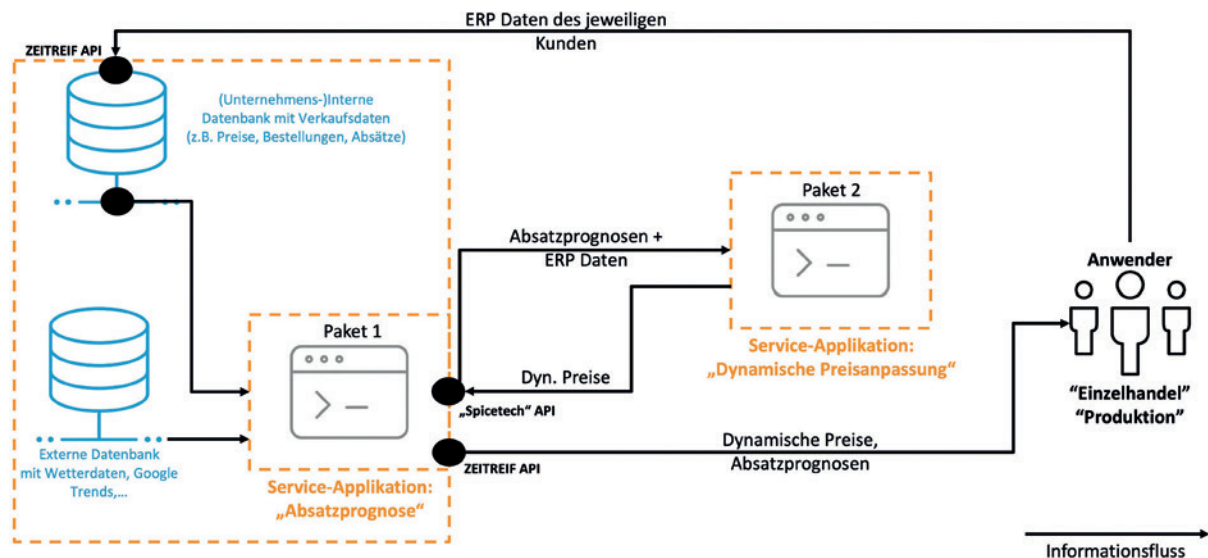


Abbildung 18: Konzept für die Integration von Absatzprognose und Dynamic Pricing in die REIF-Plattform (eigene Darstellung)

Auf Basis der Erkenntnisse aus der Entwicklung der ZEITREIF-API wurde anschließend eine kundenfreundlichere API für PREDECY entwickelt. Die neue API erfüllt die technischen Anforderungen der REIF-„Plattform“ und wurde im ersten Quartal 2023 vollständig entwickelt und im Rahmen der Möglichkeiten der „Plattform“ in diese integriert. Ein dazugehöriges automatisierbares Lizenzmodell wurde ebenfalls erstellt.

Um eine einheitliche Darstellung von PREDECY und dem Preisfindungs-Algorithmus DYNAMICS zu gewährleisten, wurden unter Zuhilfenahme der Ergebnisse und Vorlagen aus TP I einheitliche Kurzbeschreibungen erstellt. Diese können sowohl auf der „Plattform“ als auch auf der REIF-Infoseite zum Einsatz kommen.

Ein weiteres Ziel des Projekts war es, **Business Cases durch Integration und Kombination mehrerer Verfahren zu etablieren (AP II.4.3)**. Neben dem in Abschnitt 2.1.2.1 erläuterten Cross-Learning Ansatz innerhalb von PREDECY, können Prognosen oder andere Daten, die in strukturierter Form im PREDECY-Backend vorliegen, auch für Anwendungsfälle außerhalb von PREDECY relevant sein. Um die Weitergabe spezifischer Daten an Dritte zu ermöglichen, wurden PREDECY-Backend und API so erweitert, dass ein API-Key erzeugt werden kann, der nur für bestimmte Endpunkte eines bestimmten Kunden genutzt werden kann. Auf diese Art konnten beispielsweise die Prognosen für tegut... mit TP III geteilt und dort für die Produktionsplanung bei Hochland genutzt werden, ohne dass Hochland Zugriff auf andere Daten, wie etwa historische Absätze oder Artikelbewegungsdaten, erhält.

## Literatur

- Adenso-Díaz, Belarmino; Lozano, Sebastián; Palacio, Antonio: Effects of dynamic pricing of perishable products on revenue and waste, Applied Mathematical Modelling, Jahrgang 45, 2017, Seite 148-164, <https://doi.org/10.1016/j.apm.2016.12.024>.
- Aschemann-Witzel, Jessica; Giménez, Ana; Ares, Gastón: Consumer in-store choice of suboptimal food to avoid food waste: The role of food category, communication and perception of quality dimensions, Food Quality and Preference, Volume 68, 2018, Seite 29–39, ISSN 0950-3293, <https://doi.org/10.1016/j.foodqual.2018.01.020>.
- Moustafa, G. Y., N. M. Galal und K. S. El-Kilany. 2018. „Sustainable Dynamic Pricing for Perishable Food with Stochastic Demand“. 2018 IEEE International Conference on Industrial Engineering and Engineering Management (IEEM). IEEE.
- Theotokis, Aristeidis; Pramataris, Katerina; Tsiros, Michael: Effects of Expiration Date-Based Pricing on Brand Image Perceptions, Journal of Retailing, Volume 88, Issue 1, 2012, Seite 72–87, ISSN 0022-4359, <https://doi.org/10.1016/j.jretai.2011.06.003>.

### 2.1.3 Teilprojekt III – Koordination im Wertschöpfungsnetzwerk

Barthelmé, Nicolas (CSCP), Colombo, Michael (TI.KI GmbH), Gaßner, Günther (Technische Universität München), Kalchschmid, Vincent (Fraunhofer IGCV)

Aktive Partner: **Technische Universität München**, BayWa AG, CSCP, Hochland Deutschland GmbH, Fraunhofer IGCV, Kuchenmeister GmbH, TI.KI GmbH, Westfleisch SCE mbH,

Assoziierte Partner: Infoteam, Winnow Solutions Ltd

Das Ziel der Koordination ist die Minimierung der Lebensmittelverschwendung im Wertschöpfungsnetzwerk durch optimierte Planung, Steuerung und Kontrolle des Material- und Informationsflusses innerhalb einzelner Wertschöpfungsstufen sowie über unterschiedliche Wertschöpfungsstufen hinweg.

#### 2.1.3.1 AP III.1 Analyse des Status quo

Für die Abbildung der Aufgaben und der Struktur des in TP III betrachteten Wertschöpfungsnetzwerks wurden verschiedene bestehende Modelle miteinander verglichen. Die Koordinationsaufgabe im REIF-Wertschöpfungsnetzwerk ist branchenunabhängig, jedoch müssen branchenspezifische Eigenschaften bei der Entwicklung des Koordinationsansatzes berücksichtigt werden.

Zunächst wurden bestehende Modelle und Systeme mit Hilfe von Experteninterviews analysiert und erste Informationen für eine Grobauswahl eingeholt (Abbildung 19). Im Folgenden wurde nach Konsolidierung der Ergebnisse mit AP-Partnern und anschließender Modellierung der Ergebnisse Übersichten für die Einordnung erstellt.

	Kooperations-Ziel	Kooperations-Objekt/Prozess	SCM-Referenzmodell	Branchen-Fokus	SCM-Standard	Relevanz für TP III
Supply Chain Design	Effektives Mgmt. der Kooperation	Collaboration Framework	Supply Chain Operation Reference Model	übergreifend	global	
		Forecast Collaboration	Collaborative Planning Forecasting & Replenishment	Konsumgüter	global	
Supply Chain Planning	Synchronisation von Demand & Supply	Capacity Collaboration	Demand Capacity Planning	Automobil	europäisch	
		Transportation Collaboration	Collaborative Transportation Management	Konsumgüter, Logistik	nord-amerikanisch	
Supply Chain Execution	Effizientes Bestands-Mgmt.	Inventory Collaboration	Supply Chain Monitoring	Automobil	europäisch	
			Collaboration Managed Inventory		global	
	Effizientes Auftrags-Mgmt.	Order Collaboration	Distributed Order Management	übergreifend	...	

Abbildung 19: Einordnung der untersuchten Modelle und Systeme (eigene Darstellung)

Abbildung 20 zeigt die Modellierung bestehender Daten- und Informationsflüsse für die Identifikation und Systematisierung der Branchenspezifika sowie die Einordnung in Betrachtungsräume.

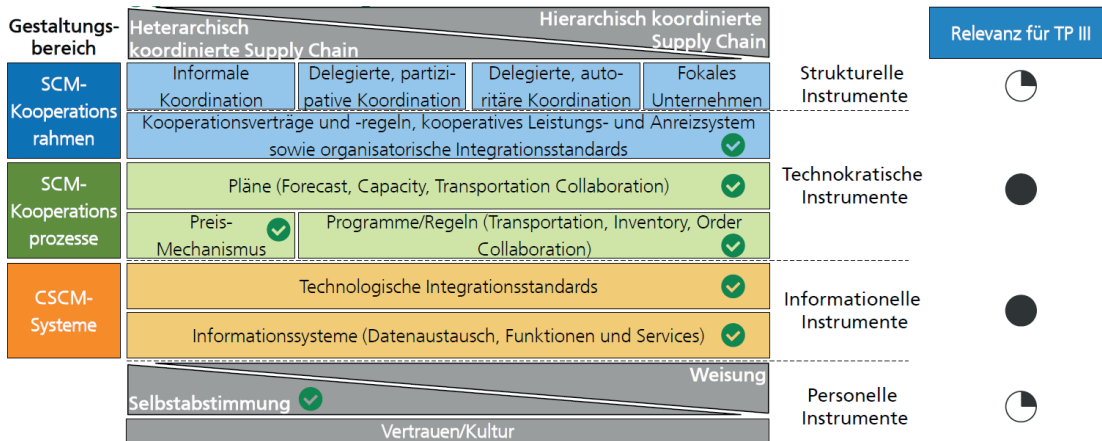


Abbildung 20: Betrachtungsräume für die Modell- und Systemauswahl (eigene Darstellung)

Auf Basis von Anforderungen, die sich einerseits aus den technischen Rahmenbedingungen ergeben und andererseits aus solchen, die von den Projektpartnern genannt und dann zusammengeführt wurden, wurde das Collaborative Planning, Forecasting and Replenishment Framework ausgewählt. Dieses ermöglicht die in REIF zu erarbeitende gemeinsame Steuerung von Planungs-, Prognose- und Bevorratungsprozessen durch Austausch unternehmensspezifischer Informationen. Die aus den Workshops und Recherchen hervorgegangene Modell- und Systemauswahl (Abbildung 21) dient im weiteren Verlauf als Wegweiser für den Aufbau des Gesamtsystems und dessen Strukturierung.

	SCM-Referenzmodell	Relevanz für TP III	SCM- Koop. rahmen	SCM-Koop. Prozesse	CSCM- Systeme	Relevanz für TP III			Gesamt
						Rahmen	Prozesse	CSCM	
Supply Chain Design	Supply Chain Operation Reference Model	1/4	1/2	1/4	1/2	1/2	1/4	1/2	1/4
	Collaborative Planning Forecasting & Replenishment	1/2	1/2	1/2	1/2	1/2	1/2	1/2	1/2
Supply Chain Planning	Demand Capacity Planning	?	1/2	1/2	1/2	X	X	X	X
	Collaborative Transportation Management	1/4	1/2	1/2	1/2	1/2	1/2	1/2	1/4
Supply Chain Execution	Supply Chain Monitoring	?	1/2	1/2	1/2	X	X	X	X
	Collaboration Managed Inventory	?	1/2	1/2	1/2	X	X	X	X
	Distributed Order Management	1/2	1/2	1/2	1/2	1/2	1/2	1/2	1/2

Abbildung 21: Bewertete Modell- und Systemauswahl (eigene Darstellung)

Des Weiteren erfolgte eine Netzwerkanalyse (Abbildung 22). Diese ergab eine generische Struktur und Basis für das Wertschöpfungsnetzwerk und den Gesamtsystemaufbau.

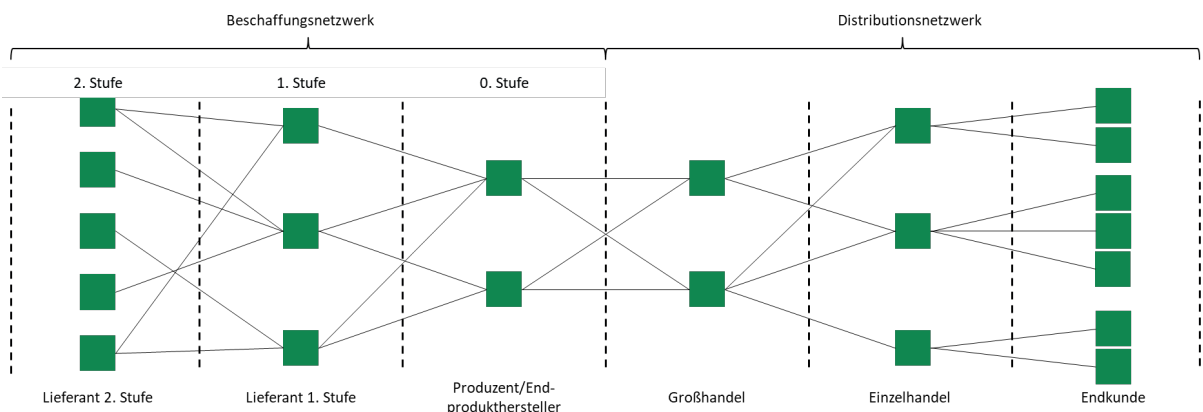


Abbildung 22: Elementarmodell eines Wertschöpfungsnetzwerks (eigene Darstellung)

Die Supply-Chain-Optimierung ist eine Einzelbetrachtung einer Supply Chain (= Lieferkette) in einem Wertschöpfungsnetzwerk, auch von mehreren Partnern je Wertschöpfungsstufe. Die globale Optimierung hingegen berücksichtigt alle Betriebe aus den Wertschöpfungsebenen (Abbildung 23). Sie assistiert bei der Zuteilung von Aufträgen, um jedem Betrieb die optimalen Produktionsmengen für das Wertschöpfungsnetzwerk zuzuordnen.

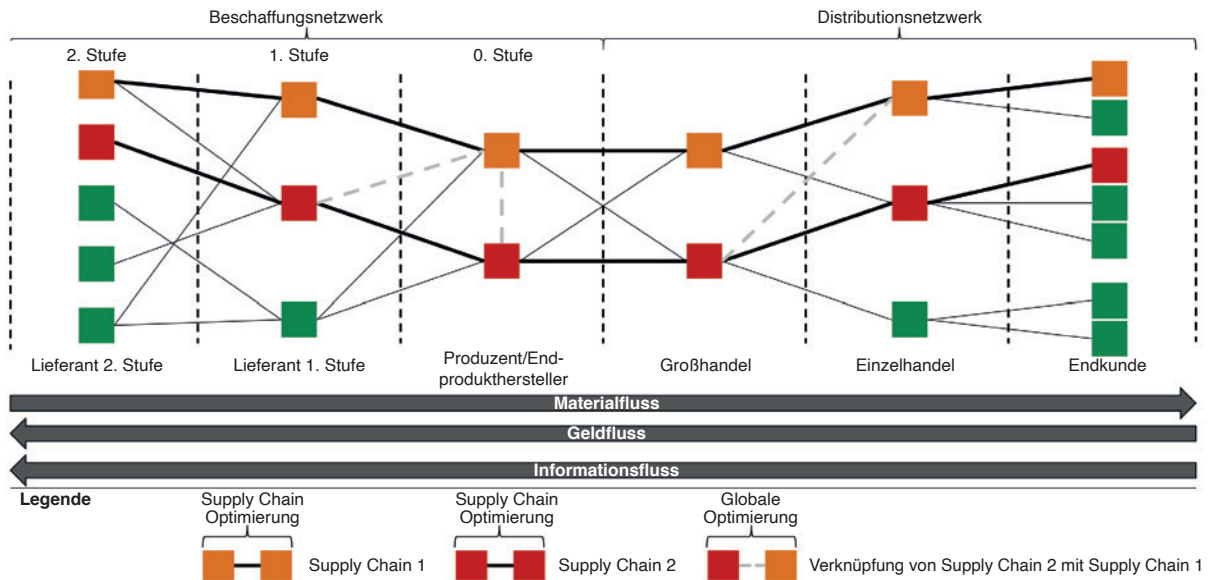


Abbildung 23: Einordnung der Supply-Chain-Optimierung und der globalen Optimierung (eigene Darstellung)

Neben der Informationsverarbeitung ist auch die Anpassung an die vorhandenen Standards zur Datenerhebung, -übertragung und -bevorratung ein wichtiger Aspekt.

### 2.1.3.2 AP III.2 Konzeptionierung der Koordination

Zum Austausch von Informationen über die verschiedenen Stufen der Wertschöpfung hinweg ist eine Plattform und Systemarchitektur notwendig, welche die Verwendung dieser größeren Menge an Informationen zur Koordination durch Künstliche Intelligenz und Methoden des maschinellen Lernens ermöglicht.

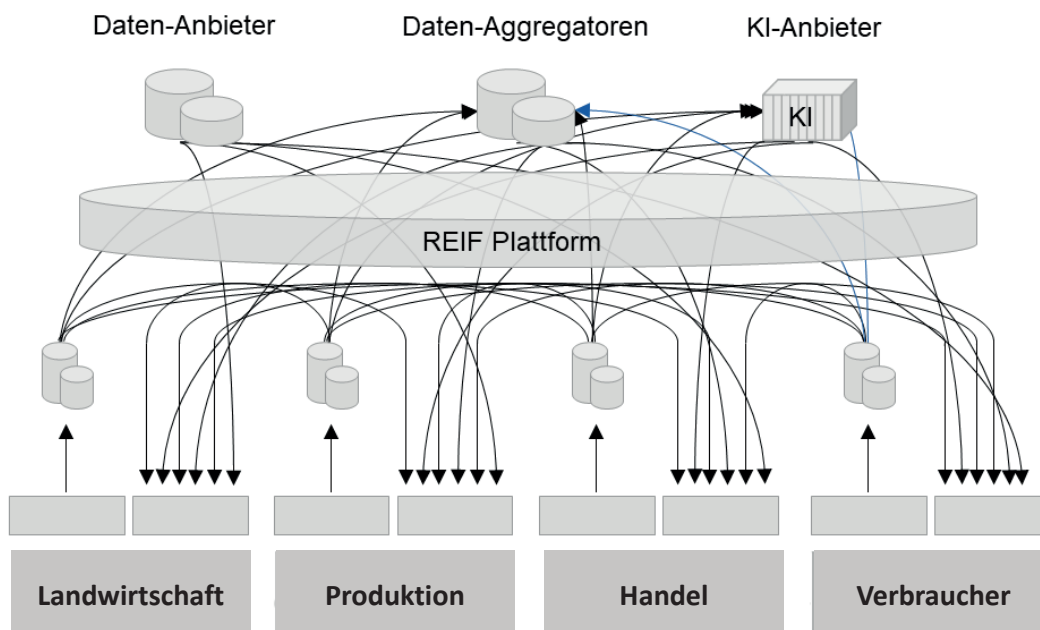


Abbildung 24: Illustrative Übersicht der Datenflüsse (Quelle: TI.KI)



Abbildung 24 zeigt, wie die erzeugten Daten durch Teilen, Aggregation bzw. Anreicherung und Veredelung, etwa durch die Verwendung in einem KI-Modell, entlang der Wertschöpfungskette fließen. Ein Pfeil repräsentiert einen möglichen Datenfluss entlang der Wertschöpfungskette: Landwirtschaft, Produktion, Handel, Verbraucher mit Dienstleistern, z. B. Datenanbietern, Datenaggregatoren, KI-Anbietern, zu einer koordinierenden Instanz – der ‚Plattform‘.

Die Teilnehmenden treten meist sowohl als Datenanbieter („auslaufende“ Pfeile) als auch als Datennutzer („einlaufende Pfeile“) auf. Die Daten können ‚roh‘, ‚veredelt‘ oder ‚Vorhersagen‘ aus KI-Modellen sein; sie können als Einzeldaten, große bis sehr große Dateien oder laufende Datenströme auftreten.

Diese Daten haben zwei verschiedene Qualitäten:

- **Operative Rohdaten**, die es insbesondere durch den Austausch über verschiedene Spieler hinweg erlauben, mit Methoden des maschinellen Lernens KI-Anwendungen zu bauen, um operative Entscheidungen im Sinne der Ziele besser zu unterstützen.
- **Angebots- und Nachfragedaten** über die verschiedenen Stufen der Wertschöpfung hinweg, die als Eingangsgröße für ein intelligentes Multiagentensystem die Marktbedingungen so verbessern, dass produzierte Lebensmittel auf den verschiedenen Stufen zuverlässiger Abnehmer finden.

Allein schon durch die Kombinatorik der Beziehungen zwischen verschiedenen Typen von Teilnehmenden wie in Abbildung 24 dargestellt, aber noch vielmehr durch die einzelnen Repräsentanten dieser Typen, entsteht eine unüberschaubare Zahl von Beziehungen, die die Systemarchitektur unterstützen muss.

Jeder der Teilnehmenden im Wertschöpfungsnetzwerk hat seine individuelle Geschäftsarchitektur aus Prozessen, IT-Anwendungen, Daten und IT-Infrastruktur, die zwar möglicherweise für die Zwecke angepasst wird, aber grundsätzlich als gegeben angenommen werden muss.

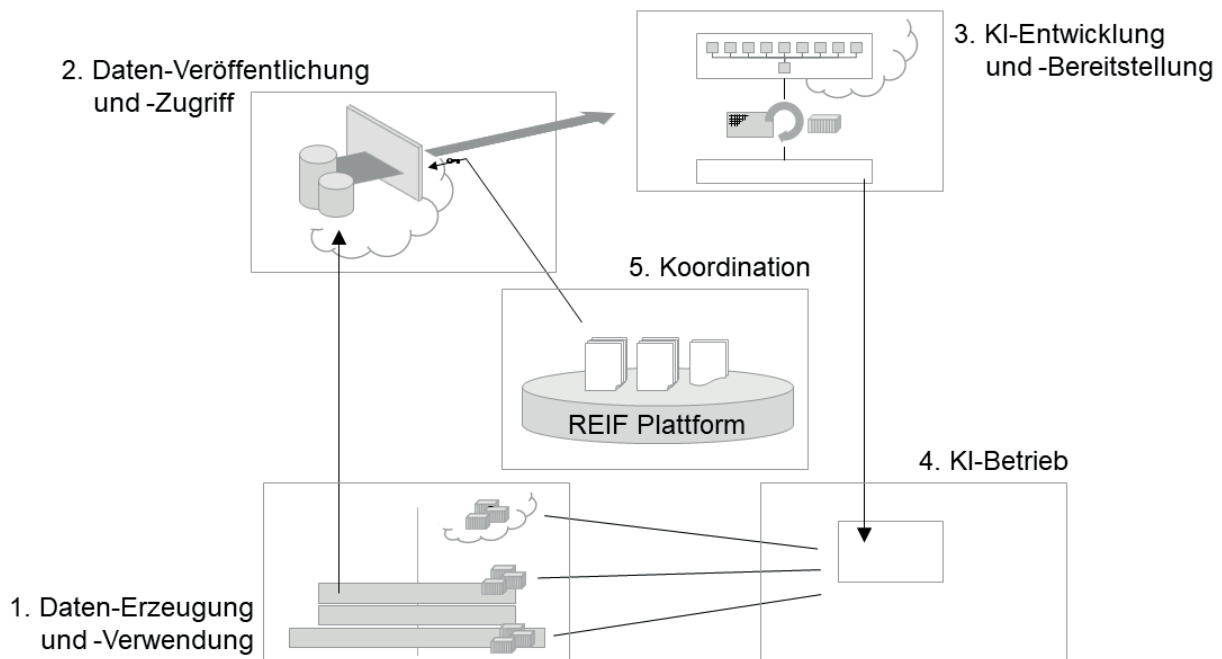


Abbildung 25: Elemente der Systemarchitektur aus Sicht der verschiedenen KI-bezogenen Aufgaben (Quelle: TI.KI)

Die Systemarchitektur soll deshalb den verbindenden Rahmen für die Zusammenarbeit der Teilnehmenden beschreiben (Abbildung 25), um die übergeordneten Ziele zu erreichen. Sie muss dabei die folgenden Anforderungen erfüllen:

- Technische Offenheit, um den vielen Teilnehmenden mit ihren unterschiedlichen IT-Umgebungen den Zugang zu erlauben
- Zugänglichkeit der Daten durch einfache Auffindbarkeit und ggf. logische Harmonisierung

- Skalierbarkeit in Bezug auf Speicherfähigkeit, Bandbreiten und Rechenleistungen
- Vertraulichkeit, um angesichts wettbewerblicher Beziehungen oder anderweitig schützenswerter Informationen die grundsätzliche Bereitschaft zum Teilen von Daten zu fördern.

Die im Kontext von maschinellem Lernen hauptsächlich relevanten Datenarten werden typischerweise in der Cloud – meist in der Form Write Once Read Many (WORM) – abgespeichert. Die operativen Systeme liefern die Daten nicht direkt in die Cloud, sondern über eine Edge Komponente. Auf dieser können die Daten vor der Speicherung noch verarbeitet werden, etwa zur Transformation in ein definiertes Schema, aber insbesondere auch unter Verwendung eines KI-Modells, bspw. zur Dimensionsreduktion. Auf diese Weise bleiben die sensiblen Datenbanken im Rechenzentrum vor dem Zugang von Dritten abgeschirmt (Abbildung 26). Im Kontext der Teilnehmenden der Wertschöpfungskette steht hauptsächlich die Verwendung von Daten als Eingangsgröße für produktive KI-Modelle.

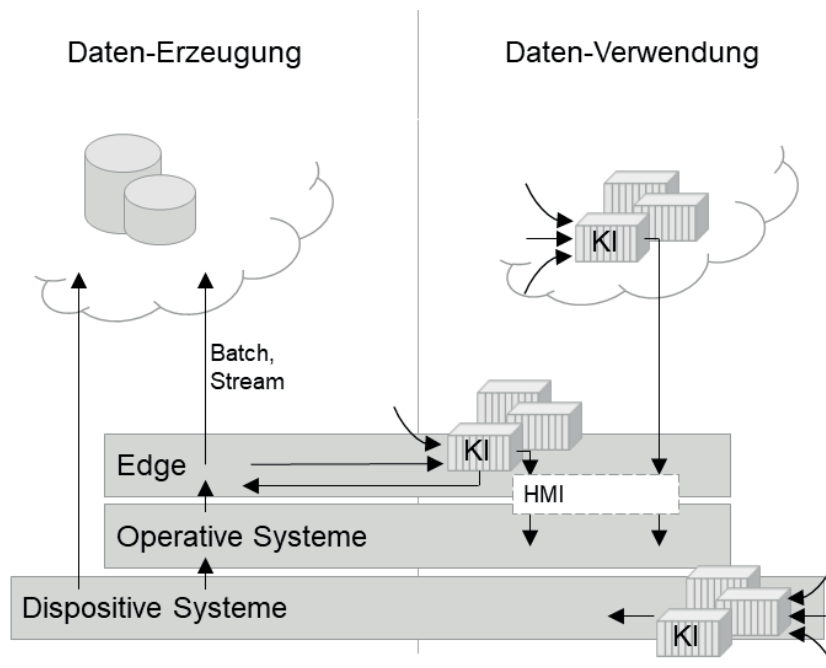


Abbildung 26: Daten-Erzeugung und -Verwendung für die Teilnehmenden entlang der Wertschöpfungskette (Quelle: TI.KI)

Die KI-Modelle werden jeweils in einem Container betrieben und können deshalb an (fast) beliebigen Stellen der IT-Landschaft des Datenverwenders betrieben werden, insbesondere in der Cloud und auf der Edge-Komponente. Eingangsdaten für das Modell – möglicherweise auch aus verschiedenen Quellen – werden dem KI-Modell über eine API-Schnittstelle übergeben. Das Ergebnis des KI-Modells wird ebenfalls als API zur Verfügung gestellt. Durch die Verwendung von API ist keine ‚echte‘ Integration der KI-Anwendungen in die IT-Landschaft des Datenverwenders erforderlich.

Gerade in der Einführungsphase von KI werden die Verantwortlichen für die operativen Systeme vermeiden wollen, dass eine KI-Anwendung direkt die Steuerung der operativen Systeme anspricht. Die KI-Anwendung wird deshalb als Assistenzsystem ausgelegt, das etwa auf dem Human Machine Interface (HMI) des operativen Systems läuft.

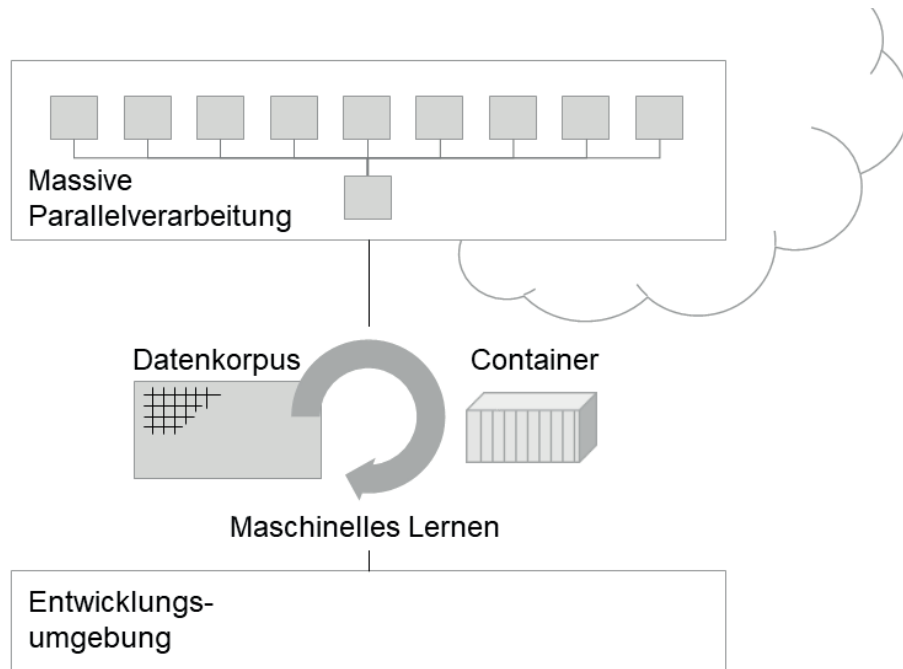


Abbildung 27: KI-Modell-Entwicklung und -Bereitstellung (Quelle: TI.KI)

Die Entwicklung von KI-Modellen mittels überwachtem oder unüberwachtem maschinellem Lernen erfordert den Aufbau eines Datenkorpus, in vielen Fällen aus verschiedenen Quellen. Ein solcher Datenkorpus ist in der Regel eine sehr große flache Datentabelle, oft mit Zehntausenden Spalten – den Merkmalen – und Millionen von Zeilen, den Merkmalsvektoren der einzelnen Ereignisse. Einen derartigen Korpus aufzubauen und effektiv für das maschinelle Lernen vorzubereiten, etwa zu reinigen, und später für das maschinelle Lernen zu verarbeiten, erfordert die Datenspeicherung in einem verteilten Dateisystem und eine skalierbare massive Parallelverarbeitung (Abbildung 27). In dem Rahmen wurde geprüft, ob Vergangenheitsdaten der Rohmilch einer Molkerei und auch Daten aus der Urproduktion von Rohmilch für eine Prognose geeignet wären. Dies erwies sich, im Gegensatz zu Produktionswerten, auf Grund von Verfügbarkeit und Beschaffenheit der Daten zum Zeitpunkt der Erhebung als nicht praktikabel. Erfüllt ein KI-Modell die Anforderungen, wird es (in Form eines Software-Containers) als voll lauffähige Instanz für die Inbetriebnahme bereitgestellt.

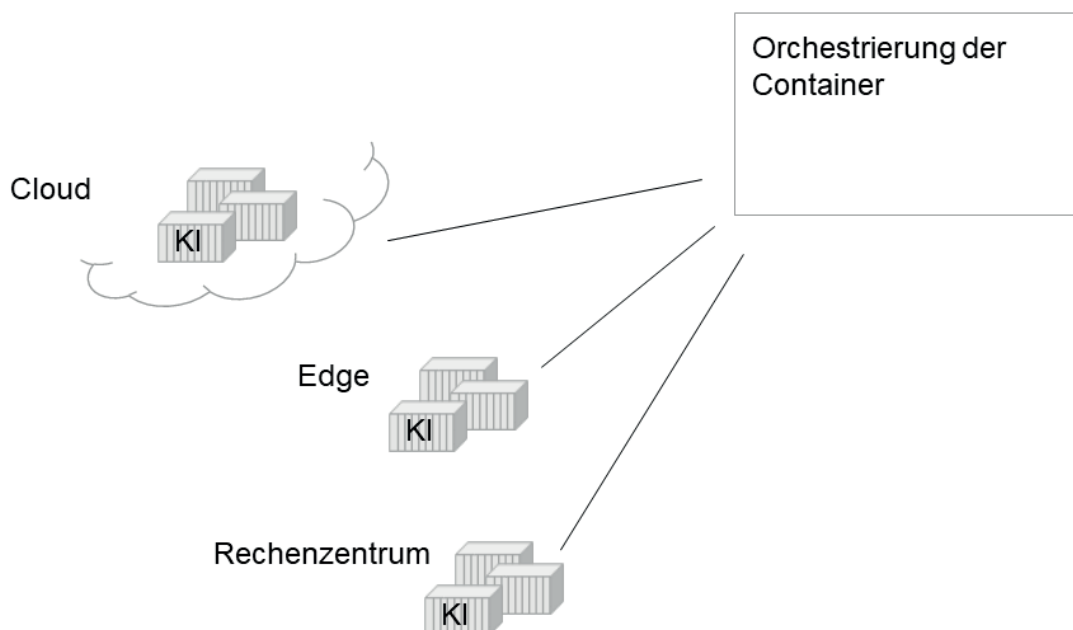


Abbildung 28: KI-Modell-Betrieb (Quelle: TI.KI)

Ein Nutzender von KI entlang der Wertschöpfungskette wird im Normalfall viele, vielleicht Hunderte, Container mit KI-Anwendungen betreiben müssen, weil der Umfang jeder einzelnen KI-Anwendung sehr begrenzt ist. Abbildung 28 zeigt sowohl schematisch diese Vielfalt in Bezug auf das Management der jeweils erforderlichen Ressourcen als auch die Anforderungen an die fortlaufende Auslieferung. Dafür wird eine Komponente für die Orchestrierung wie z. B. Kubernetes eingesetzt. Grundsätzlich kann der Datenverwendende die KIs selbst betreiben oder ‚as-a-Service‘ beziehen.

Zur ökonomischen Bewertung der Handlungsalternativen der KI-Services wurden unterschiedliche Grundlagen herangezogen und auf Relevanz geprüft:

Die Bewertungslogik des Europäischen JRC Technical Reports „Assessment of food waste prevention actions“, um auf etablierten Prozessen aufbauen zu können. Doch nach externer Ausschreibung und Abstimmungen mit den möglichen Auftragnehmern (u. a. dem Thünen-Institut) musste festgestellt werden, dass die Bewertungslogik aus der spezifischen Projektarbeit zu Lebensmittelabfällen und die Anforderungen an generalisierbare Rechenformeln für die Nutzung durch das KI-System in REIF nicht kompatibel sind. Weil die Ergebnisse nicht die benötigte Relevanz mitgebracht hätten, wurde diese erste Grundlage depriorisiert.

Der in Frankreich entwickelten Eco-Score wurde als zweite Grundlage analysiert und untersucht. Hierfür haben u. a. Vernetzung und Gespräche mit den Erfindern des Eco-Scores stattgefunden.

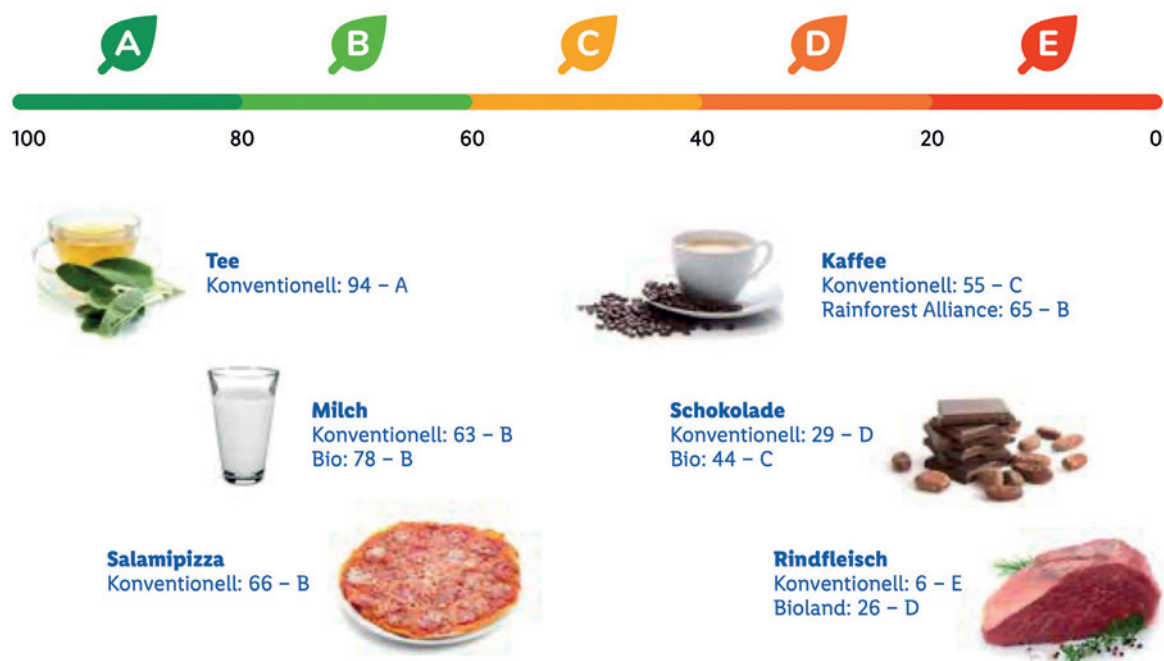


Abbildung 29: Eco-Score Beispiele aus diversen Branchen (Quelle: Lidl 2022)

Der Eco-Score (Abbildung 29) bewertet die Auswirkung von Lebensmitteln auf die Umwelt und verbindet in einer einzigartigen Bewertungslogik sowohl qualitative als auch quantitative Nachhaltigkeitsinformationen. Datenbasis liefert die Agribalyse Datenbank der französischen Agentur für Umweltschutz und Energie (ADEME). Der Score wird aus zwei Hauptkomponenten berechnet:

- **Umweltwirkungen des Produkts, basierend auf dem „Product Environmental Footprint“ (PEF):** Die „Product Environmental Footprint“-Methode berücksichtigt 16 Wirkungskategorien (z. B. Klimawandel, Wasserverbrauch, Landverbrauch, Feinstaub oder Versauerung), die die Umweltwirkung eines Produkts von der Erzeugung bis zur Entsorgung ganzheitlich abbilden.
- **Zusätzliche Nachhaltigkeitskriterien, für die Plus- oder Minuspunkte vergeben werden** (z. B. für Biodiversität, Transport, Wiederverwertbarkeit der Verpackungen und Zertifizierungen der Inhaltsstoffe).

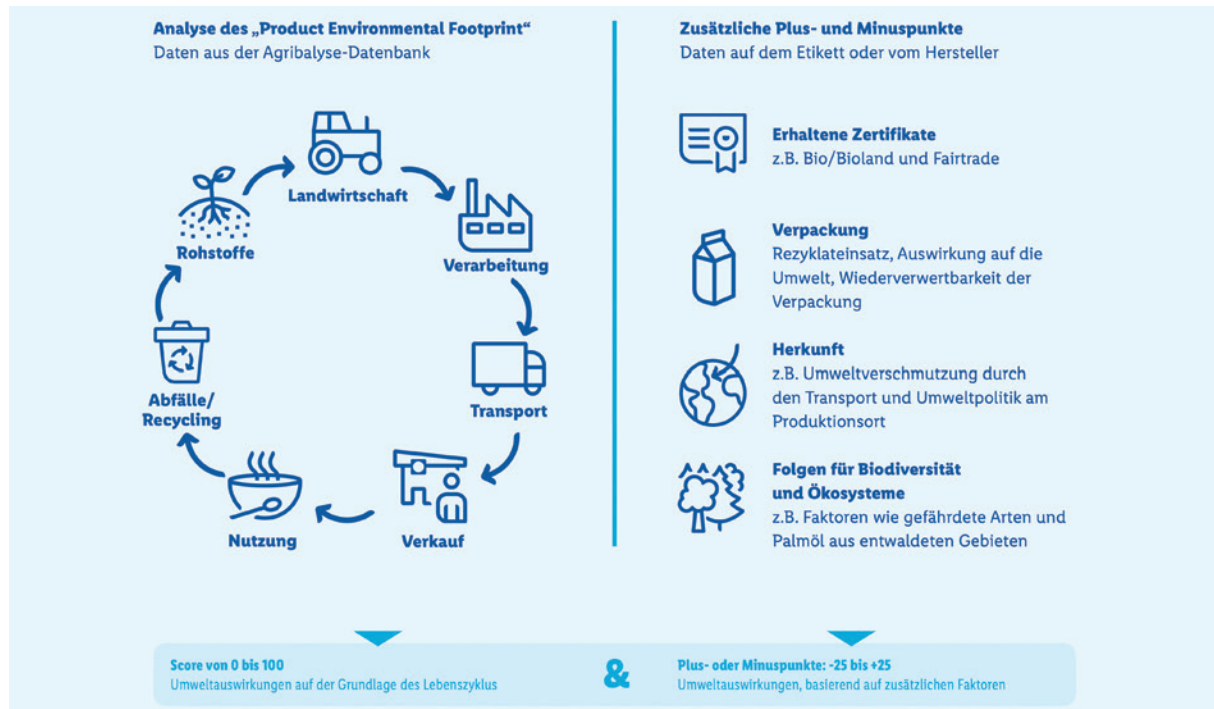


Abbildung 30: Übersicht Eco-Score (Quelle: Lidl 2022)

Zur weiteren Relevanz-Prüfung wurde der Eco-Score für neun ausgewählte Hochland-Produkte beispielhaft berechnet, um die Bandbreite der Scores je nach Produktart bzw. Käse-Technologie in Erfahrung zu bringen:

Marke	Produkt	Gesamtnote	Eco-Score	Herstellung
Hochland	Sandwich-Scheiben Gouda	58	C	Schmelzkäse, 45 % Fett i. Tr
Hochland	Hofkäse Vollmundig-Nussig	56	C	Schnittkäse, 45 % Fett i. Tr.
Grünländer	Mild & Nussig	56	C	Schnittkäse, 48 % Fett i. Tr.
Grünländer	Leicht	56	C	Schnittkäse, Dreiviertelfettstufe
Grünländer	Der Rustikale Kräftig-Würzig	56	C	Schnittkäse, 50 % Fett i. Tr.
Patros	Natur	61	B	Weichkäse
Patros	Leicht	61	B	Weichkäse
Almette	Natur	77	B	Friskäse wärmebehandelt, Doppelrahmstufe
Almette	Kräuter	77	B	Friskäse

Tabelle 4: Beispielhafte Berechnung des Eco-Scores für Hochland Eckartikel (eigene Darstellung)

#### Erkenntnisse für die Bewertung:

- Relativ schwache Differenzierung der Eco-Scores zwischen den Käse-Technologien und vor allem unter den Produkten einer gleichen Range
- PEF-Wert macht ca. 90 Prozent der Eco-Scores aus.

Abschließend wurde ein Austausch mit den CSR-Verantwortlichen eines Lebensmitteleinzelhandels organisiert, die den Eco-Score in Deutschland auf ausgewählten Produkten hinsichtlich Verständnis und Akzeptanz im Markt getestet haben.

Zusammenfassend ist der Eco-Score für die Bewertung der Umweltwirkung verschiedener Handlungsoptionen (als Zusatzkriterium zur reinen Kostenbewertung) geeignet. Denn er berücksichtigt die wichtigsten Wirkungskategorien, die die Umweltwirkung eines Produkts von der Erzeugung bis zur Entsorgung ganzheitlich abbilden, sowie zusätzliche Nachhaltigkeitskriterien. Außerdem kann er als Ergebnis einer Open-Source-Berechnungs-Methode in KI-Berechnungen integriert werden.

Einige Einschränkungen konnten jedoch ermittelt werden:

- Der Eco-Score dient hauptsächlich der Kommunikation zum Endkonsumenten und nicht vorrangig der Produktionssteuerung (z. B. fanden wir sehr überschaubare Score-Unterschiede zwischen den berechneten Hochland-Produkten und den Technologien).
- Da der Eco-Score nur für Endprodukte berechnet werden kann, kann er nur als Orientierung verwendet werden, wenn die Handlungsoptionen zu unterschiedlichen Endprodukten führen.
- Die Relevanz des Eco-Scores für die Bewertung der Handlungsalternativen hängt voraussichtlich davon ab, ob mehrere Technologien an einem Produktionsstandort vorhanden sind.
- Der Eco-Score basiert auf Daten der „Product Environmental Footprint“-Methode, die in der in Frankreich öffentlich verfügbaren Agribalyse Datenbank zusammengefasst wurden. Weil vergleichbare Daten für Deutschland aktuell nicht existieren, müssten die französischen Werte übernommen werden.

### 2.1.3.3 AP III.3 Validiertes Gesamtsystem

Das zuvor konzipierte Gesamtsystem wurde zur Validierung durch die Zusammenführung aller Systembestandteile aufgebaut. Weiterhin wurden verschiedene Szenarien in einer Materialflusssimulation vergleichend bewertet und das Gesamtsystem unter Laborbedingungen eines Demonstrators zur branchenspezifischen Validierung des Gesamtsystems validiert.

Das Gesamtsystem besteht aus den Systembestandteilen Multi-Agenten-System (MAS), den Prognoseservices und einer Datenbank, welche entsprechend der Systemarchitektur vernetzt wurden. Zudem wurden die Anwendungssysteme Materialflusssimulation und Demonstrator in Unterarbeitspaketen entwickelt und für die Integration ins Gesamtsystem erforderliche Schnittstellen eingeplant. Zentraler Bestandteil des Gesamtsystems ist der durch die TUM entwickelte MAS-Service mit dem Ziel der globalen Optimierung durch verschwendungsreduzierte Allokation der Angebote und Bedarfe im Wertschöpfungsnetzwerk. Der MAS-Service wird auf dem IGCV-Rechencluster betrieben und erhält über eine Schnittstelle Absatzprognosedaten des Lebensmittelgroß- und Einzelhandels (z. B. repräsentiert durch Partner tegut...) sowie aktuelle Produktions- und Lagerbestandsdaten der Wertschöpfungsnetzwerk-Teilnehmenden der Stufe Produktion (z. B. Hochland). Alle relevanten Daten werden bis zu ihrer Verarbeitung in der Datenbank auf dem IGCV-Rechencluster gespeichert, welche gemeinsam mit dem MAS-Service an eine Schnittstelle angebunden wurde. Alle für die globale Optimierung benötigten Datenbedarfe wurden in Form eines Datenmodells definiert und entsprechend in der Datenbank implementiert. Die Datenbank dient außerdem zum Datenaustausch zwischen Materialflusssimulation und MAS-Service. Zum Test und der Validierung des Gesamtsystems wurden Realdaten des Anwendungspartners Hochland sowie reale Absatzdaten aus Prognosedatensätzen für den Partner tegut... extrahiert, angereichert und in einem Testdatensatz zusammengefasst.

Für die Validierung des MAS-Service wurde ein genetischer Algorithmus implementiert, der ebenfalls die Allokation von Angeboten und Bedarfen durch die Anpassung von Bestellmengenverteilungen verbessern und so Lebensmittelverschwendung auf Wertschöpfungsnetzwerk-Ebene verringern soll. Zur Zusammenführung der globalen Optimierung im Rahmen von TP III und der lokalen Optimierung in TP IV wurde ein System zum Datenaustausch implementiert. Ergebnisse der globalen Optimierung können dem System zur lokalen Optimierung so als Eingangsgrößen in Form von Produktionsaufträgen bereitgestellt werden.

Neben dem Aufbau des Gesamtsystems wurden außerdem ein Testdatensatz für die Befüllung der Datenbank und die Parametrierung des Materialflusssimulationsmodells sowie ein Referenzszenario als Vergleichsbasis für die Ergebnisse der globalen Optimierung erarbeitet. Für die Definition des Datensatzes wurden Daten der Anwendungspartner aufbereitet, sodass er die Anforderungen der globalen Optimierung erfüllt und die Datenbedarfe im Gesamtsystem deckt. In Abstimmung mit dem Partner Hochland wurden die für das Referenzszenario initial definierten Produktionsstammdaten validiert, korrigiert und ergänzt. Abbildung 31 zeigt den Ablauf der Koordination im Wertschöpfungsnetzwerk als Sequenz von Ereignissen.

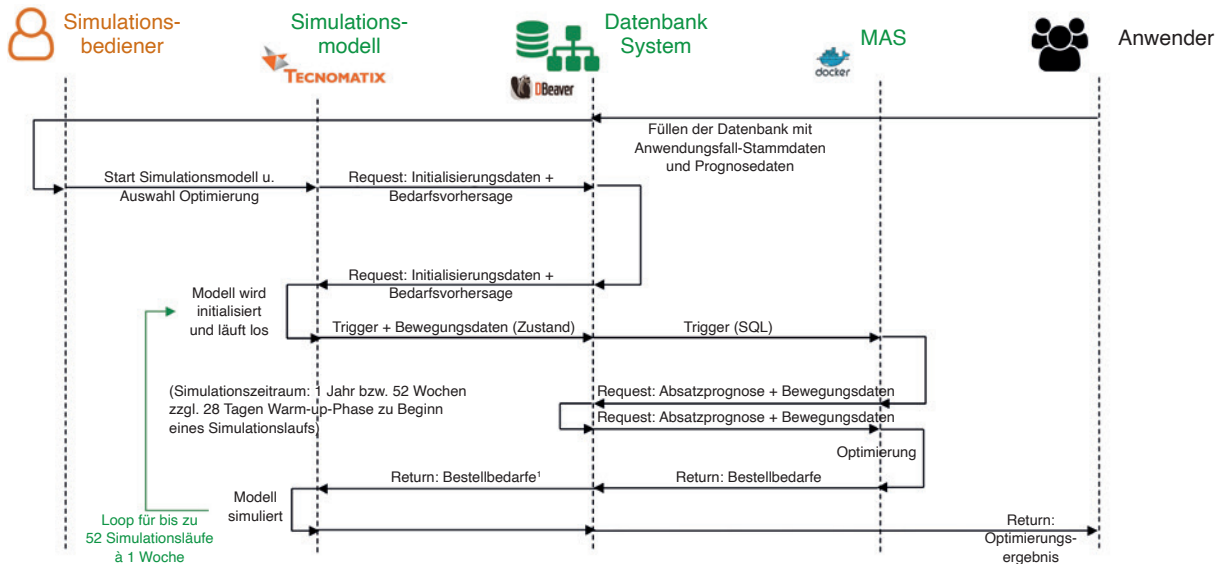


Abbildung 31: Ablauf der Koordination (eigene Darstellung)

Anschließend wurde das im Gesamtsystem vorgesehene Materialfluss-Simulationsmodell aufgebaut. Ziel war hier die Schaffung einer validierten Umgebung für Benchmark- und Referenzstudien zum Nutzen des REIF-Ökosystems aus Absatzprognosen, Multi-Agenten-System und lokaler Optimierung. Dafür wurde nach Definition des abzubildenden Wertschöpfungsnetzwerks der Lebensmittelbranche ein Materialflussmodell in Tecnomatix Plant Simulation aufgebaut. Das Modell wurde als skalierbares System von Unternetzwerken für die Wertschöpfungsstufen Landwirtschaft, Produktion, Großhandel und Point of Sale konzipiert (Abbildung 32).

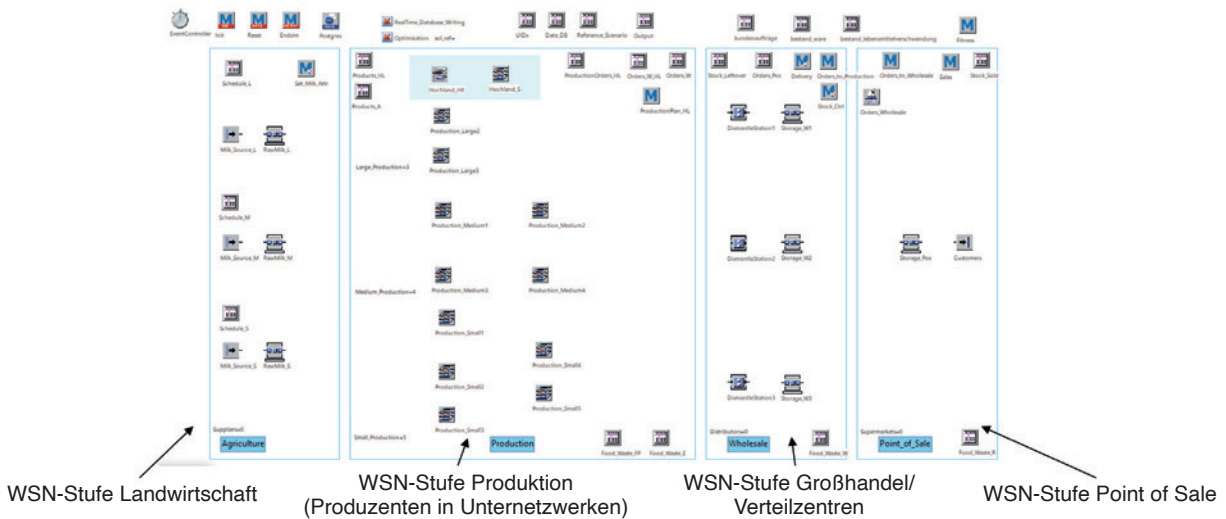


Abbildung 32: Materialflusssimulationsmodell (eigene Darstellung)

Die Funktion des Simulationsmodells wurde durch Implementierung des generierten Demonstrationsdatensatzes und nach der Spezifikation und Durchführung von geeigneten Simulationsszenarien getestet.

Zur Validierung des Gesamtsystems unter Laborbedingungen sowie zur Visualisierung der Forschungsergebnisse aus TP III wurde der Demonstrator am Fraunhofer IGCV erweitert. Der Demonstrator besteht aus verschiedenen Stationen (Einzelbearbeitungsstationen, SCARA-Roboter, Transportbänder, Montagestationen), diversen Visualisierungstechnologien (z. B. LCD-Displays an den Bearbeitungsstationen) und wurde um Komponenten wie z. B. Linearachsen und Ausschussbehälter erweitert, um den Materialfluss der Waren im REIF-Wertschöpfungsnetzwerk abzubilden. Das erarbeitete Referenzszenario der Molkereibranche wurde auf die Stationen des Demonstrators übertragen und angepasst. Dabei repräsentiert das Würfelmagazin die Rohstoffherzeugung der Landwirtschaft, die 12

Einzelstationen, die 12 Produktionsstandorte und die vier Montagestationen des Lebensmittelgroß- und Einzelhandels. Die Parameter der Materialflusssimulation wie z. B. Produktionsdauern wurden skaliert, zur Visualisierung Simulationsvideos angefertigt und als Stammdaten in der Demonstrator-Datenbank hinterlegt. Abbildung 33 zeigt den Demonstrator im Betrieb:




Abbildung 33: Visualisierung am Demonstrator (eigene Darstellung)

Zu dieser Steuerung der Waren am Demonstrator werden Informationen des MAS-Service von der Datenbank abgerufen, verarbeitet und in geeigneter Form in der Demonstrator-Datenbank abgelegt. Die SPS-Steuerung verwendet zur Steuerung der Warenströme die aktuellen Steuerungsanweisungen aus der Demonstrator-Datenbank. Zur Erfassung des Informationsflusses werden die erzeugten Daten von der SPS über OPC UA in der Demonstrator-Datenbank gespeichert. Diese Daten dienen zur Berechnung von Kennzahlen, z. B. der Menge der verschwendeten Lebensmittel, und zur Visualisierung der Ausschussreduzierung über eine entwickelte GUI. Mithilfe des Demonstrators werden die Vorteile der KI-basierten Services zur Reduktion von Lebensmittelverschwendung physisch und anhand von Kennzahlen verdeutlicht.

### 2.1.3.4 AP III.4 Validierung anhand von Use Cases

Zur Evaluierung des Gesamtsystems sollten die Anwendungsfälle der Partner in die entwickelte Systemarchitektur integriert werden. Die in den Modellfällen enthaltenen Informationen umfassen Rohstoff-, Produkt-, Distributions- und Produktionsstammdaten sowie das jeweilige Gerüst an Bewegungsdaten und Metainformationen der Branche entsprechend dem entwickelten Datenmodell. Die geforderten Inhalte wurden bereits in der Entwicklungsphase des Gesamtsystems durch Verwendung des Referenzszenarios für die Molkereibranche als Entwicklungsdatensatz vorbereitet. Zur Einholung der erforderlichen Daten und Informationen wurde in mehreren Workshops ein gemeinsames Verständnis von den Anforderungen und Datenbedarfen geschaffen und ein auf dem Datenmodell basierender Fragebogen erstellt. Die so eingeholten Informationen wurden abschließend, zusammen mit den dokumentierten Entscheidungen der Systementwicklung, per Expertenfragebogen validiert.

## Literatur

- Kochenderfer, Mykel J.; Wheeler, Tim A.; and Wray, Kyle H.: Algorithms for Decision Making. MIT Press, 2022. <https://mitpress.mit.edu/9780262047012/algorithms-for-decision-making/>.
- LIDL, Eco-Score Beispiele aus diversen Branchen, 2022 (Abbildung 29)
- LIDL, Übersicht Eco-Score, 2022 (Abbildung 30)



## 2.1.4 Teilprojekt IV – Verschwendungsminimierende Produktionssysteme

Theumer, Philipp (Fraunhofer IGCV); Braun, Hans-Martin und Braunreuther, Stefan (Technische Hochschule Augsburg); Gaßner, Günther (Technische Universität München); Achhammer, Thomas (TI.KI GmbH); Heim, Albert (Hochland SE)

Aktive Partner: **Technische Hochschule Augsburg**, Hochland Deutschland GmbH, Fraunhofer IGCV, TI.KI GmbH, Technische Hochschule München

Assoziierte Partner: GEA Germany, Krones AG

Im Rahmen von TP IV wurden unterschiedliche Problemstellungen in unterschiedlichen Ebenen der Automatisierungspyramide adressiert. Der Einsatz von Softsensoren ermöglicht die Prognose nicht direkt messbarer Qualitätsmerkmale divergierender Produkte. Die Erfassung dieser Qualitätsmerkmale auf Prozessebene ermöglichte es, den Mitarbeitenden im Bedarfsfall eine Anpassung der Maschinenparameter vorzuschlagen mit dem Ziel, Lebensmittelverschwendung zu vermeiden, bevor diese auftritt.

### 2.1.4.1 AP IV.1 Softsensoren

Vier Anwendungsfälle für Softsensoren sind mit Hochland identifiziert und bewertet worden. Für jeden der zwei Hochland-Standorte wurde jeweils ein Anwendungsfall ausgewählt, nämlich die Vorhersage der Pumpfähigkeit der Käsemasse zum Schmelzofen einerseits sowie die Vorhersage der Trockenmasse für Weißkäse andererseits. Damit sind zwei weitere inhaltliche Dimensionen abgedeckt, nämlich der Einsatz von KI, um den Produktionsprozess zu verbessern und um die Produktqualität zuverlässig zu erreichen.

Zunächst wurde der Anwendungsfall „Vorhersage der Pumpfähigkeit der Käsemasse“ fokussiert betrachtet. Neben der inhaltlichen Arbeit wurden dabei auch schon viele technische Voraussetzungen für den zweiten Anwendungsfall „Vorhersage der Trockenmasse für Weichkäse“ umgesetzt.

Die Rohdaten von Maschinen und chemischen Untersuchungen der eingesetzten Rohmaterialien sind aus den Hochland Systemen extrahiert worden. Auf Seite des Technologischen Instituts für angewandte Künstliche Intelligenz (TI.KI) wurde eine ‚Landing‘-Zone für die Daten eingerichtet, in die Hochland die Daten bequem mit einem FTP-Service laden kann.

Die Daten wurden von der ‚Landing‘-Zone in TI.KIs managed Data Science Plattform überführt und mit den dort verfügbaren Werkzeugen zu einem einheitlichen Datenkorpus integriert. In wöchentlichen ‚Stand-up‘-Meetings mit Vertretern aller beteiligten Organisationen wurde dabei sichergestellt, dass die Data Scientists die Daten inhaltlich richtig verstehen. In einem iterativen Vorgehen – auch mit der Beschaffung zusätzlicher Daten – ist der Datenkorpus sukzessive erweitert worden.

Der Softsensor soll möglicherweise auftretende Pumpprobleme erkennen, um zu verhindern, dass die Käsemasse steckenbleibt und entsorgt werden muss. Zunächst wurde dazu in intensiven Diskussionen mit Hochlands Fachleuten definiert, wie sich ein Pumpproblem anhand der gemessenen Drücke im Pumpsystem kennzeichnen lässt. Aus diesen Signaturen wurden Labels für den Einsatz eines überwachten Lernalgorithmus erzeugt. Ein Entscheidungsbaum und ein neuronales Netz sind daraufhin mit den Daten trainiert worden und lieferten vergleichbar gute Vorhersageergebnisse für ein Pumpproblem. Aus dem Entscheidungsbaum konnten darüber hinaus Hinweise für die möglichen Ursachen für ein Pumpproblem erkannt werden, sodass mit den Produktionsexperten ein Vorgehen abgestimmt werden konnte, an welcher genauen Stelle im Produktionsprozess die Vorhersage helfen kann.

Während der Softsensor ‚Pumpfähigkeit‘ eine Vorhersage bezogen auf den Prozess selbst macht, soll der Softsensor ‚Trockenmasse‘ eine Vorhersage bezogen auf die Qualität des Käseprodukts – die Trockenmasse – machen. Die Vorhersage soll auch hier so frühzeitig erfolgen, dass noch korrigierend in den Produktionsprozess eingegriffen werden kann. Da der Trockenmasse-Prozess an einem anderen Hochland-Standort und auf anderen IT-Systemen angesiedelt ist, mussten die gleichen Schritte zu Datenextraktion und -übermittlung wie bei der ‚Pumpfähigkeit‘ umgesetzt werden. Dabei zeigte sich

bereits ein deutlicher Lerneffekt, sodass die Ergebnisse schneller und mit weniger Aufwand umgesetzt werden konnten. Das Vorhersagemodell konnte mit Methoden des überwachten maschinellen Lernens trainiert werden, wobei die Vorhersagequalität durch die große Streubreite der als Label verwendeten Messwerte der Trockenmasse begrenzt ist.

Den Abschluss des Arbeitspakets IV.1 „Softsensoren“ markierte die Erreichung des Meilensteins IV.3. Die Vorhersage der Pumpfähigkeit einer Käsemasse erfolgt durch ein KI-Modell, welches basierend auf den Eingangsdaten die Prognose des nicht direkt messbaren Qualitätsmerkmals „Pumpfähigkeit“ ermöglicht. Hierzu erfolgt die Bereitstellung der benötigten Daten im CVS-Format durch Hochland. Neben den Maschinen- und Anlagendaten (PLSR-Daten) vom Produktionsserver werden die PLSP-Daten sowie die chemischen Daten der Eingangsprodukte bereitgestellt (Abbildung 34).

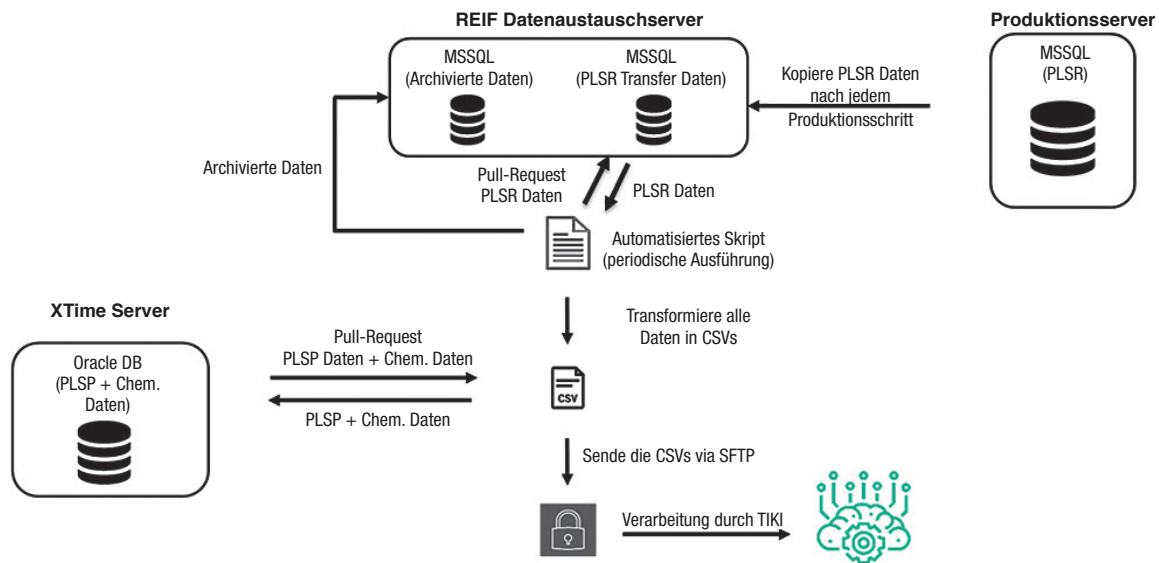


Abbildung 34: Schematische Darstellung des Datenflusses zur Nutzung des KI-Modells zur Prognose der Pumpfähigkeit (eigene Darstellung)

Die Realisierung des Softsensors zur Vorhersage der Pumpfähigkeit erfolgt durch den Einsatz eines Machine Learning Modells, welches basierend auf den Eingangsparametern der Anlage und von direkten Sensoren eine Prognose relevanter und nicht direkt messbarer Qualitätsmerkmale („Pumpfähigkeit“) bezogen auf die Milchqualität im Produktionsprozess ermöglicht.

### 2.1.4.2 AP IV.2 Selbstoptimierende Anlage

Die Grundlage für die Entwicklung der selbstoptimierenden Anlage stellt das im Arbeitspaket IV.1 KI-Modell zur Vorhersage der Pumpfähigkeit einer Käsemasse dar. Abbildung 35 zeigt, wie das in Arbeitspaket AP IV.1 entwickelte Vorhersagemodell des Softsensors eingebunden ist, um die Anlage selbst optimierend zu machen. Im Mischprozess erzeugte Daten, etwa zu Zeitpunkten und Mengen der zugefügten Materialien, werden um die vorher festgestellten chemischen Daten der verwendeten Lebensmittelchargen erweitert und dem Prognoseprozess zugeführt. Diese Daten werden durch eine Vorverarbeitung und Transformation in das Format gebracht, das auch ursprünglich für das Modelltraining verwendet wurde. Mit den aktuellen Daten aus dem Prozess erstellt das Prognosemodell eine Vorhersage bezogen auf die Pumpfähigkeit der Rohmasse im Mischer.

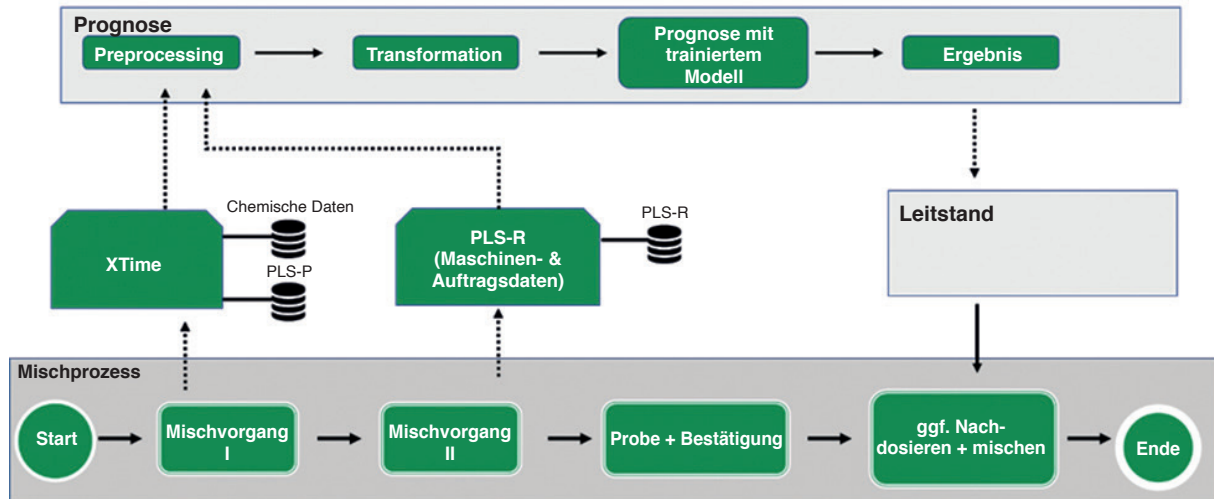


Abbildung 35: Systemarchitektur für die intelligente Anlagensteuerung (eigene Darstellung)

In einem ersten Schritt wurde, falls eine eingeschränkte Pumpfähigkeit vorhergesagt wird, automatisch eine entsprechende Warnung an den Leitstand übermittelt, um optimierend in den Prozess eingreifen zu können. Im Zuge der Vollautomatisierung wurde die datenverarbeitende Pipeline weiter optimiert und derart angepasst, dass manuelle Schritte weitestgehend nicht mehr ausgeführt werden müssen.

Es wurde versucht das Machine Learning Modell weiter zu optimieren, um die Vorhersagen zu verbessern und so das Vertrauen der Mitarbeiter in die KI-gestützte Anlagensteuerung zu verbessern. Dabei wurden zum einen die historischen Daten weiter auf vielversprechende Features analysiert. Zum anderen wurden verschiedene Modelle auf die Daten getestet. Eine signifikante Verbesserung der Modellqualität konnte jedoch nicht erreicht werden. Um in Zukunft den Prozess weiter zu automatisieren und die Mitarbeitenden, die durch den aktuell verwendeten „human-in-the-middle“-Ansatz eingebunden sind, zu entlasten, wurden erste Tests mit einem Model Predictive Control Regler (MPC-Regler) gemacht. Belastbare Aussagen zu den Ergebnissen dieser Tests konnten in der Projektlaufzeit nicht mehr getroffen werden.

### 2.1.4.3 AP IV.3 Intelligenter Mixer

AP IV.3 befasst sich mit einem KI-basierten Konzept zur Unterstützung der Anlagensteuerung unter Berücksichtigung unterschiedlicher Einflussparameter (z. B. Maschinenkennzahlen, Rohstoffzusammensetzung etc.). Zentral geht es um den Entwurf eines Systems, welches den Mitarbeitenden im Produktionsalltag zur Zielwerterreichung dienen kann. Aufbauend auf dem aktuellen Zustand einer Anlage werden Vorhersagen über den Zustand des Endprodukts getätigt und diese, unter Berücksichtigung der Prozessziele, dem Mitarbeitenden zur Verfügung gestellt. Hier wurden zunächst konzeptionierte Einsatzmöglichkeiten bewertet und ein Use Case in der Weißkäseherstellung identifiziert. Anschließend wurden relevante Prozessparameter für die Beeinflussung aufgenommen, diese umfassten diverse Koagulatorstellgrößen wie z. B. Bandgeschwindigkeit, Höheneinstellungen diverser Aggregate, Rührgeschwindigkeiten etc.

Auf AP IV.1 aufbauend befasst sich der intelligente Mixer mit gewonnenen Erkenntnissen des Softsensors „Trockenmasse“. Als Prozessziel im Use Case wird die präventive Vermeidung von Lebensmittelabfällen durch Sicherung der Spezifikationsnähe der Produkte angesehen. Hiermit soll bei Abweichungen gezielt in den Herstellungsprozess eingegriffen werden, um im Falle von prognostizierten Schwankungen schneller reagieren zu können. Hauptaspekt ist es, durch die zeitnahe Anpassung der Mischparameter den notwendigen Ressourcenverbrauch zu verringern und damit präventiv Lebensmittelverschwendung zu reduzieren.

Für die Entwicklung der KI-unterstützten Anlagensteuerung ist eine Umgebung zu gestalten, die Daten der Verarbeitungsprozesse und Abläufe der zu betrachtenden Prozesse sammelt, bündelt und entspre-

chend für KI-Verarbeitung zugänglich macht. Darüber hinaus sollen Resultate auf den Shop Floor zurückgespielt werden können, was durch Nutzung interner Kommunikationskanäle erfolgen soll. Die dafür benötigten Schnittstellen können durch Erweiterung der vorhandenen Infrastruktur entsprechend umgesetzt werden. Hier konnte ein automatisierter Nachrichtendienst eingerichtet werden, welcher den KI-Server mit dem Personal auf dem Shop-Floor zur Unterstützung bei Entscheidungssituationen verbindet.

### Datenbereitstellung und Vorverarbeitung

Die Konzeptionierung der KI-Entwicklungsumgebung geschieht unter Mitnutzung der bereits implementierten Schnittstelle zur Datenextraktion und Rückkommunikation. Zunächst erfolgt die informationstechnische Anbindung des betrachteten Produktionsabschnitts, und ein Datensatz für die Analyse und das Training wird übertragen. Dieser Datensatz enthält diverse Parameter der Maschine, Laboranalysen der Rohstoffe und des Produkts am Ende des Prozesses. Auf Basis dieses Datensatzes erfolgte die Konzeptionierung der KI-Entwicklungsumgebung zur Analyse, Transformation und Aufbereitung der Daten.

Der resultierende Datenkorpus wurde im Anschluss einer explorativen Analyse und Filterung unterzogen, welche sich mit der Struktur und den Zusammenhängen der Datenpunkte beschäftigt. Der Korpus dient dem Training und der Erprobung von verschiedenen KI-Algorithmen. Grundlegend waren hier Analysen mittels verschiedener Techniken (z. B. Regressionsanalyse, Kausale Inferenz, Random Forest etc.), denn das Problem eignet sich aufgrund des diskreten Charakters der Produktion nicht für die Verwendung von Reinforcement Learning.

### KI-Entwicklung und Lösungsansätze

TensorFlow ist ein Open-Source-Framework für maschinelles Lernen, Deep Learning und andere statistische und prädiktive Analyseaufgaben. Mittels Datenflussgraphen lässt sich beschreiben, wie Daten durch eine Reihe von Verarbeitungsknoten bewegt werden. Jeder Knoten im Graphen stellt eine mathematische Operation dar und jede Verbindung zwischen den Knoten ist ein mehrdimensionales Datenfeld (Tensor).

Mit Hilfe von Experten wurden beeinflussbare Parameter mit Bedeutung, sog. Features, identifiziert, welche für die Berechnung eines Gewichtungsfaktors, sog. Importance, herangezogen werden. Die Berechnung erfolge mittels State-of-the-art-Techniken und dient als Grundlage für Extrapolation und selektiver Auswahl von Datenpunkten für das Trainieren eines neuronalen Netzes. Dieses entnimmt einen Teil der aufbereiteten Daten, die im Prozess auftreten, und erlernt die Zusammenhänge durch Trainingseinheiten. Dieses Training erfolgt mittels Definition eines Berechnungsgraphen, der die mathematischen Operationen in einem maschinellen Lernmodell darstellt. Nach ausreichend Epochen (vollständiger Trainingszyklus) entsteht ein nutzbares TensorFlow-Modell des Prozesses. Dieses Modell dient der Bewertung des Maschinenzustands und der Vorschlaggenerierung für den im Training erlernten Prozess.

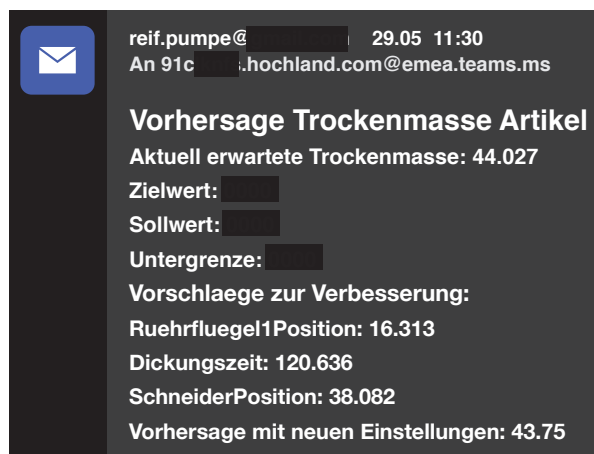


Abbildung 36: Beispiel einer Empfehlung für Maschinenparameter (eigene Darstellung)

Anschließend wurde im Rahmen einer prototypischen Umsetzung exemplarisch ein System in Betrieb genommen. Dieses verarbeitet die aufgenommenen Werte und liefert eine Empfehlung zur Parameter-einstellung an die Schaltwarte in der Produktion (Abbildung 36).

Interventionen sollen mit Hilfe der sogenannten Kausale Inferenz Methoden untersucht werden, um automatisch die optimale Einflussnahme auf den Prozess durch Stellgrößenmanipulation zu bestimmen. Für die Analyse werden identifizierte kausale Beziehungen in einem gerichteten azyklischen Graphen dargestellt. Um das Diagramm zu einem vollständigen strukturellen Kausalmodell (SCM) zu entwickeln, müssen die funktionalen Abhängigkeiten für die Variable weiter definiert werden.

Die Einrichtung des Pilotbetriebs beim Anwendungspartner Hochland ist insofern abgeschlossen, dass ein Datenaustausch ermöglicht ist und dieser auch funktionsfähig vorliegt. Datensätze beim Anwender werden über die verknüpfte Datenschnittstelle zum KI-Dienst übertragen und entsprechend verarbeitet.

Entscheidend für die Qualität der Vorhersage (Abbildung 37) ist die Menge der Daten und das Maß an Streubreite der Trockenmasse-Messungen, die als Labels für das Training verwendet werden. Durch einen wachsenden Datensatz und Experteninput werden hier noch Potentiale vermutet. Nach Befragungen wird der Einsatz von Vorhersage in der Produktion von Experten grundsätzlich als prüfenswert befunden.

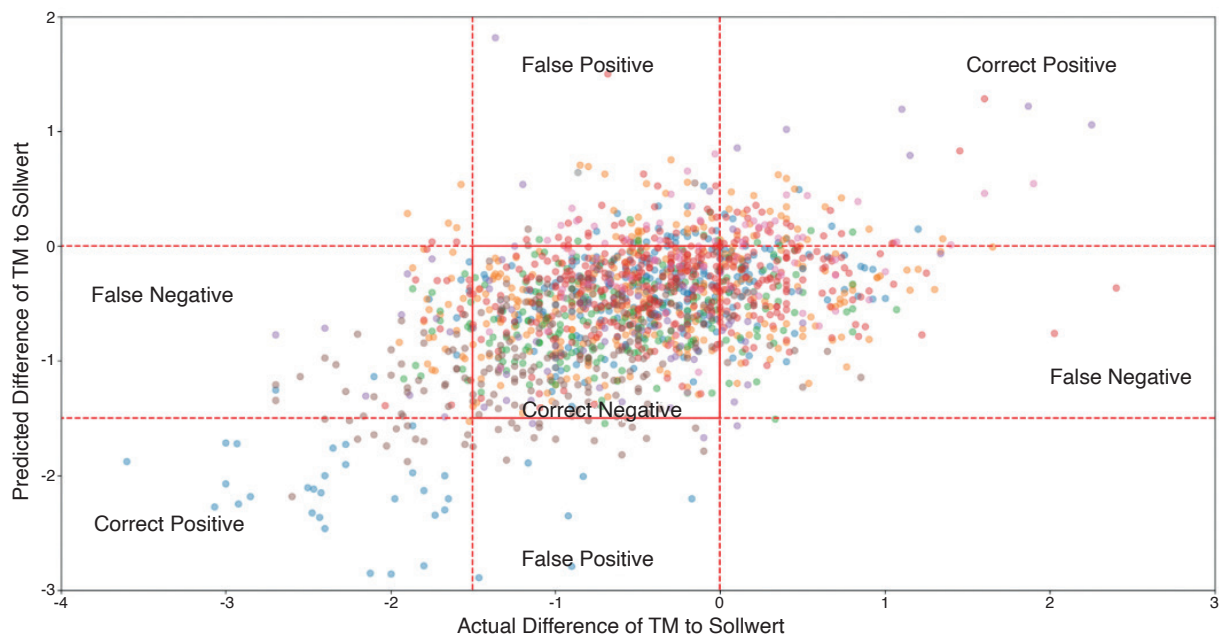


Abbildung 37: Vergleich zwischen Vorhersage der Trockenmassedifferenz und dem tatsächlichen Differenzwert im Produkt (eigene Darstellung)

Abschließend wurde an einem Konzept für die technisch realisierbaren Anpassungen der Einflussgrößen gearbeitet, welches in Zukunft genutzt werden soll, um bei einer prognostizierten Abweichung im Prozess einen korrigierenden Einfluss zu nehmen. Hierdurch sollen die Abweichungen a priori vermieden werden, um somit die sich ansonsten einstellenden Grenzwertverletzungen zu eliminieren.

#### 2.1.4.4 AP IV.4 Optimierte Produktionssteuerung

##### Ausgangssituation

Im Rahmen von AP IV.4 wurde ein KI-basiertes System zur Unterstützung in Entscheidungssituationen unter Berücksichtigung unterschiedlicher Einflussfaktoren (z. B. vorhandener Rework, notwendige Reinigungen) entwickelt. Der Fokus liegt dabei auf der Entwicklung eines reaktiven Systems zur Entscheidungsunterstützung der Mitarbeitenden. Ziel der reaktiven Steuerung ist es, basierend auf dem aktuellen Zustand des Gesamtsystems, dem Mitarbeitenden die aus Unternehmenssicht bestmögliche

Aktion unter Berücksichtigung der Reduzierung von Lebensmittelverschwendung vorzuschlagen.

Abgeleitet von den bei Hochland am Produktionsprozess beteiligten Personen wurde hierfür ein Multiagentensystem mit Deep Reinforcement Learning erstellt. Dieses beinhaltet verschiedene Arten von Agenten. Einzelne Agenten entsprechenen dabei im realen Produktionssystem vertretenen Benutzerrollen. Die Aktionen, welche die Agenten in Abhängigkeit des Zustands des Produktionssystems vorschlagen können, entsprechen unterschiedlichen Maßnahmen der Produktionssteuerung (z. B. Anpassung der Ist-Kapazität, Veränderung der Ist-Reihenfolge), welche die Mitarbeitenden veranlassen können.

**Modellierung des Produktionsprozesses und des Planungsprozesses**

Die in Abbildung 38 dargestellten Schritte sind die Produktionsbereiche, in denen Produktverluste auftreten können. Speziell die Schritte Schmelzen und Verpackung bieten für das Projekt REIF ein hohes Potenzial, durch Optimierungen des Produktionsprozesses die Entstehung von unerwünschten Nebenprodukten wie z. B. Rework, Ausschuss oder K3-Ware zu reduzieren.

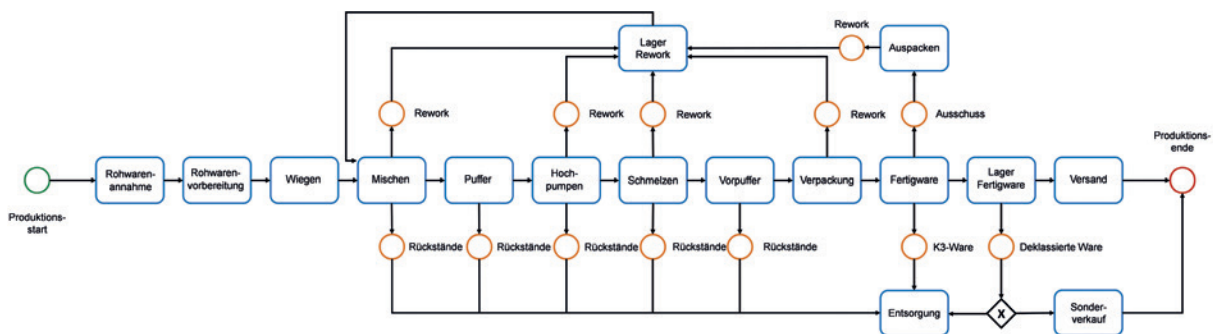


Abbildung 38: BPMN-Modell des Produktionsprozesses bei Hochland für das Produktsegment Schmelzkäse (eigene Darstellung)

**Definition Rework**

Rework entsteht in der Produktion während Umstellprozessen, Grundreinigungen, Zwischenreinigungen und Störungen. Das so entstehende Nebenprodukt kann unter bestimmten Voraussetzungen wieder in den Produktionsprozess zurückgeführt und weiterverarbeitet werden.

**Modell des Planungsprozesses**

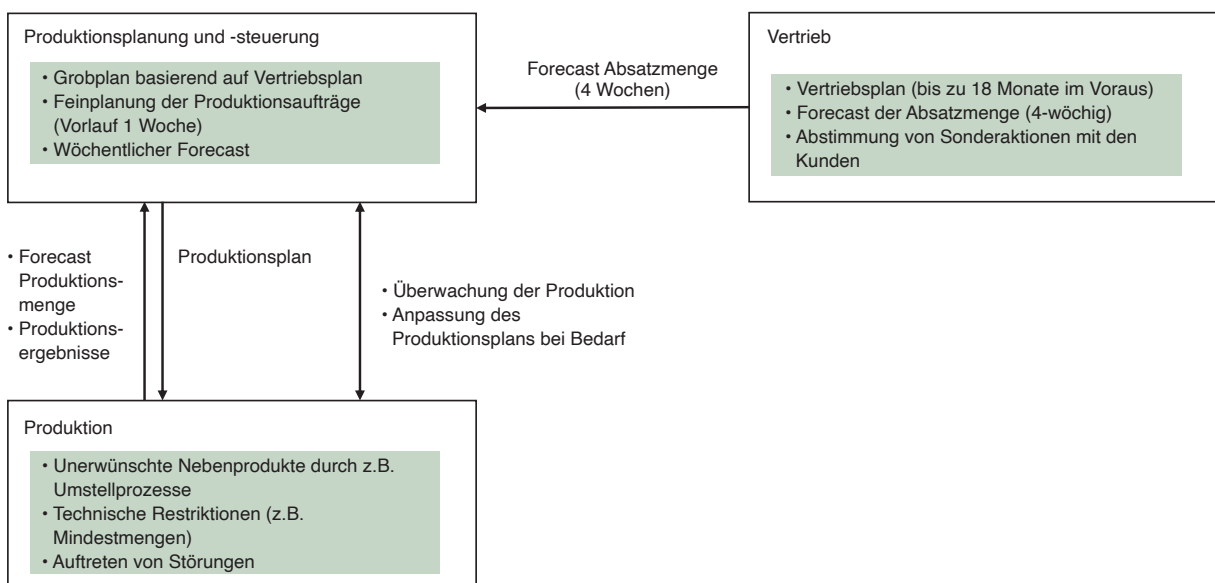


Abbildung 39: Ablauf der Produktionsplanung und -steuerung (eigene Darstellung)

Zur Erfassung der Ist-Situation wurde gemeinsam mit den Experten von Hochland im Rahmen von mehreren Workshops der Ablauf der Produktionsplanung und -steuerung erfasst (Abbildung 39). Der Fokus lag hierbei insbesondere auf der Erfassung der steuerungsrelevanten Daten. Dies ermöglicht es, Entscheidungen bez. des optimalen Produktionsablaufs zu treffen. Bei den steuerungsrelevanten Daten handelt es sich im vorliegenden Use Case um:

- Artikel und Rezepturen,
- Produktionszeiten,
- Bearbeitungszeiten,
- Anlagenfähigkeitsmatrix und
- Rüst- und Reinigungszeiten.

Diese Daten ermöglichen es, auf unvorhergesehene Störungen in der Produktion zielgerichtet zu reagieren. Die Reaktion auf Störungen kann durch unterschiedliche Benutzergruppen (z. B. Produktionssteuerer, Anlagenbediener) bzw. Benutzer erfolgen. Unvorhergesehene Störungen können im vorliegenden Fall in zwei unterschiedliche Störungsklassen – *Störungen des Produktionsprozesses* und *Störungen des Produktionsprozessergebnisses* – eingeteilt werden. Beide Störungsklassen können die Produktion sowohl kurzfristig (z. B. kurzfristiger Anlagenausfall) als auch langfristig (z. B. langfristiger Personalausfall) beeinträchtigen (Abbildung 40).

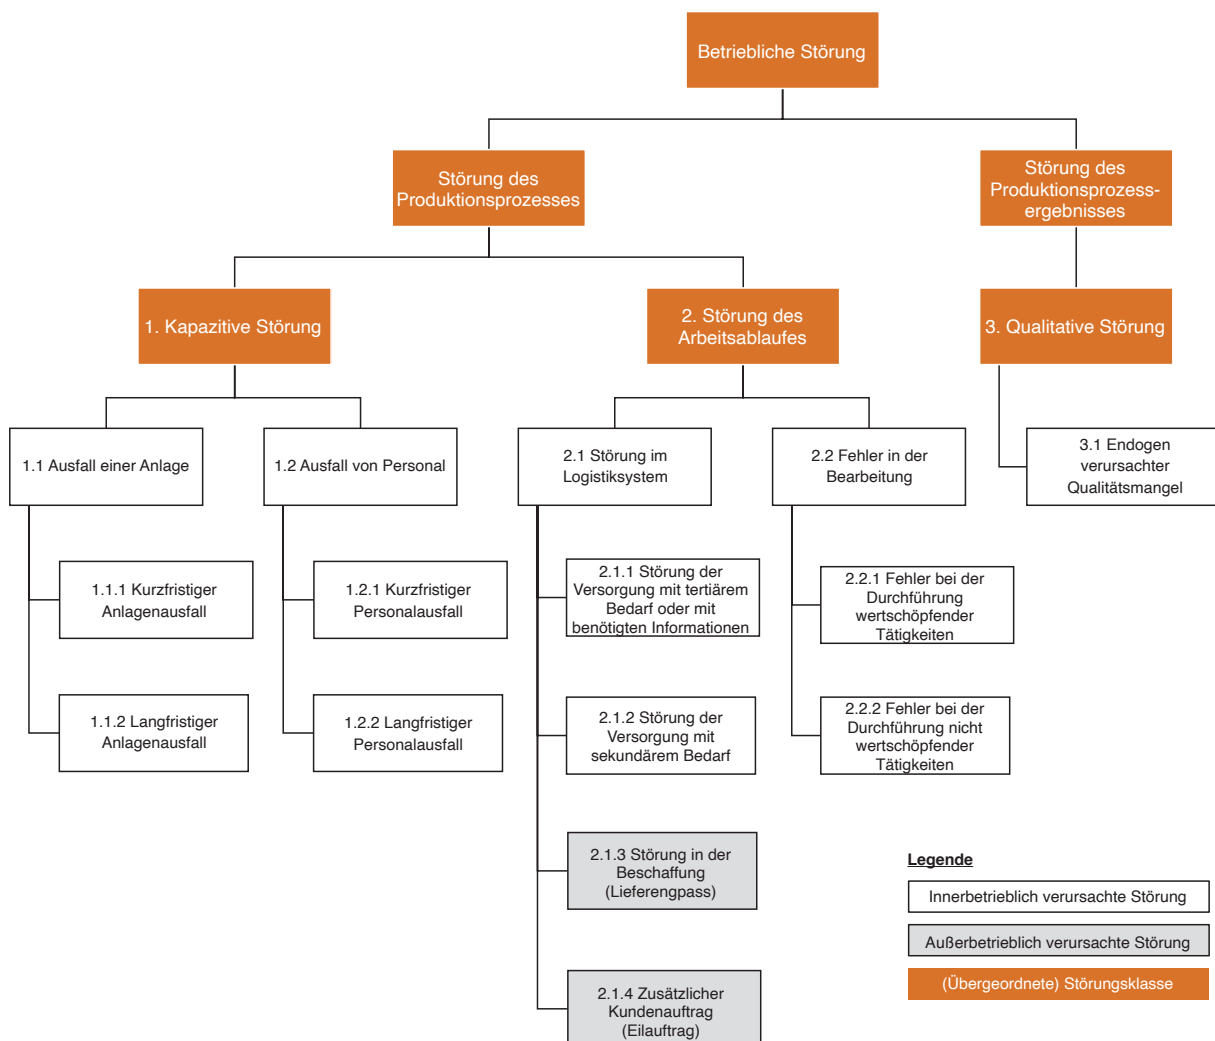


Abbildung 40: Identifizierte Ereignisse, welche ein Eingreifen durch den Mitarbeitenden erfordern (eigene Darstellung)

Zur Reduzierung der Auswirkungen der Ereignisse auf die Wirtschaftlichkeit der Produktion können unterschiedliche Maßnahmen durch die Produktionssteuerung ergriffen werden. Dies beinhaltet einer-

seits die Anpassung der Ist-Reihenfolge und andererseits die Anpassung der Ist-Kapazität. Die Ist-Reihenfolge beeinflusst direkt die erforderlichen Reinigungs- und Rüstzeiten. Durch die Anpassung der Ist-Kapazität wird die Anzahl der an einer Anlage produzierten Aufträge gesteigert oder vermindert. Bei der Initiierung unterschiedlicher Maßnahmen gilt es stets unterschiedliche Anforderungen zu erfüllen. Eine zusätzliche Herausforderung bilden Eilaufträge, welche innerhalb einer Woche mit einem Fertigstellungsdatum in derselben Woche auftreten können. Dementsprechend muss eine Abwägung zwischen Lieferverzug und langen Reinigungszeiten getroffen werden.

Der entstandene Rework (z. B. durch eine Anlagenstörung) muss innerhalb einer definierten Zeitspanne erneut verwendet werden, da er aufgrund der Haltbarkeit ansonsten als K3-Ware deklariert werden muss. Dies kann durch eine Anpassung der Ist-Reihenfolge der freigegebenen Aufträge erfolgen. Sowohl die Anpassungen der Ist-Reihenfolge als auch der Ist-Kapazität gilt es unter Berücksichtigung der logistischen Zielgrößen sowie der resultierenden Lebensmittelverschwendung zu treffen.

Die erarbeiteten Ziele sind:

- Sicherstellung der Lieferfähigkeit bzw. Erreichung der Termintreue,
- Sicherstellung der geforderten Liefermengen,
- Sicherstellung der Mindestlaufzeit des MHD,
- Erhöhung der Auslastung,
- Reduzierung der reworkbedingten K3-Ware und
- Reduzierung der Entstehung von Rework

### Kennzahlensystem

Um die Leistungsfähigkeit des Produktionssystems ganzheitlich bewerten zu können, wurde im Rahmen von REIF ein umfassendes Kennzahlensystem (Abbildung 41) entwickelt. Die Spitzenkennzahl des Kennzahlensystems stellt die sog. operative Produktionsperformance dar (Zipfel et al. 2021).

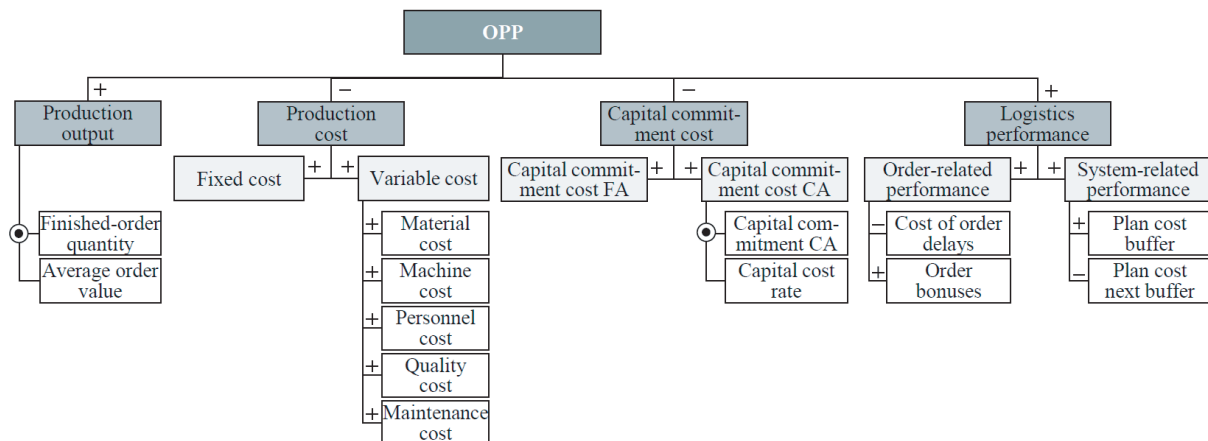


Abbildung 41: Kennzahlensystem zur operativen Produktionsperformance (Quelle: Zipfel et al. 2021)

Im Rahmen von REIF wird der Input für das Kennzahlensystem mit Hilfe eines Simulationsmodells erzeugt. Das Simulationsmodell bildet den Materialfluss im Produktionssystem bei Hochland ab. Da ein Modell allerdings stets eine vereinfachte, abstrahierte Abbildung eines realen Objekts ist, werden im Simulationsmodell nur die für den Zweck der Produktionssteuerung und der Ermittlung der operativen Produktionsperformance relevanten Charakteristika fokussiert. Insbesondere sind dies der Produktionsplan mit den Produktvarianten (Artikel-/Rezepturkombinationen), die Fertigungslinien, die Herstellkosten und die Bearbeitungszeiten inkl. Rüst- und Reinigungszeiten.

### Aufbau des Agentensystems

Zur Realisierung einer nutzerzentrierten Produktionssteuerung ist es wichtig, dem richtigen Benutzer die richtigen Informationen zur richtigen Zeit am richtigen Ort bereitzustellen. Hierfür wurden im



Rahmen von Expertenworkshops unterschiedliche Benutzerrollen identifiziert, welche anschließend als Grundlage für die Realisierung der Agenten verwendet wurden. Durch die Ableitung von Agenten von Benutzerrollen bzw. Benutzern können nutzerzentrierte Informationsräume realisiert werden. Der Aktionsraum der Agenten leitet sich direkt von den Maßnahmen ab, welche Benutzer initiieren können. Der strukturelle Aufbau des Agentensystems wird ebenfalls in Anlehnung an die Organisationsstruktur gewählt (Abbildung 42).

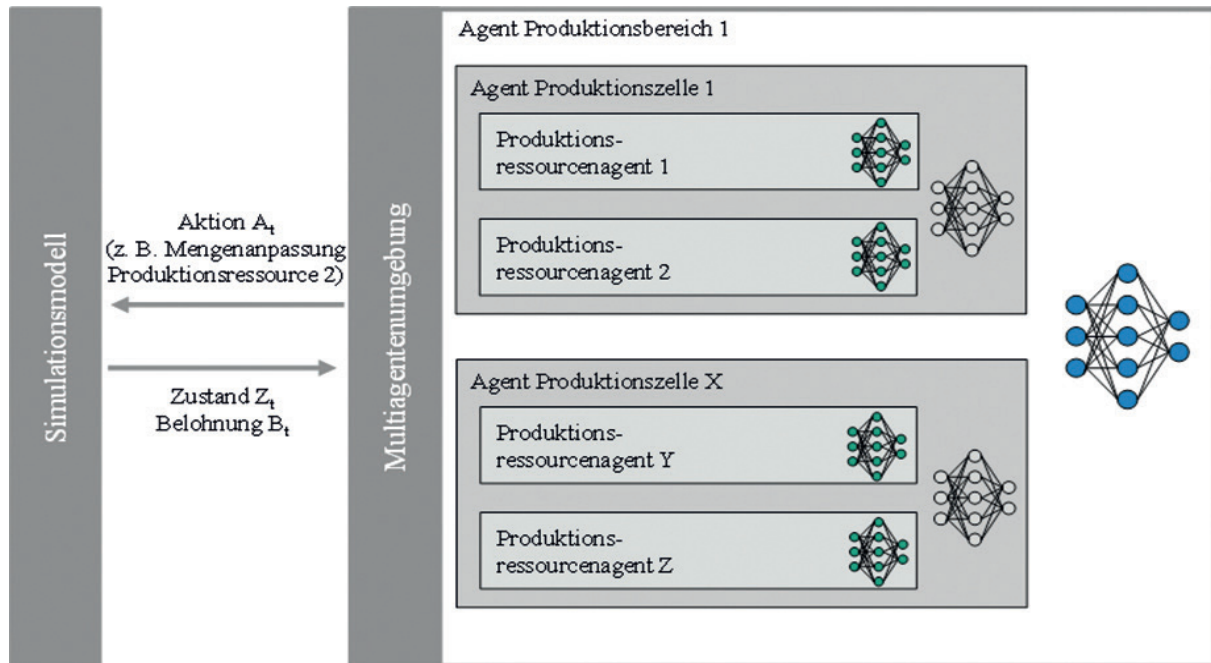


Abbildung 42: Schematischer Aufbau des Multiagentensystems (Quelle: Theumer et al. 2022)

### Deep Reinforcement Learning

Ziel des entwickelten Multiagentensystems ist es, innerhalb von kürzester Zeit die bestmögliche Entscheidung zu treffen und damit den Mitarbeitenden bei seiner Entscheidung zu unterstützen. Damit die Agenten das Mapping zwischen dem aktuellen Zustand der Produktion und der bestmöglichen verfügbaren Aktion lernen, wird Deep Reinforcement Learning (DRL) eingesetzt. DRL nutzt KNNs zum Lernen der Zusammenhänge. Der Lernprozess findet dabei mit Hilfe von Interaktion zwischen dem Simulationsmodell (der Produktion) und dem Multiagentensystem statt (Abbildung 42). Das Multiagentensystem wählt basierend auf dem aktuellen Zustand des Simulationsmodells  $Z_t$  eine Aktionen  $A_t$  aus. Durch die Ausführung der Aktion ergeben sich der neue Zustand  $Z_{t+1}$  s und eine Belohnung für die ausgewählte Aktion. Der Lernvorgang mit DRL erfordert die Möglichkeit einer Vielzahl von Interaktionen zwischen den Agenten und dem Produktionssystem. Damit die Agenten ohne Eingriffe in das Realsystem lernen und gleichzeitig viele Interaktionen in kurzer Zeit stattfinden können, wurde eine eigene Materialflusssimulation des Produktionssystems in Python entwickelt. Der Agent hat das Ziel, sein Verhalten – repräsentiert durch die Gewichte des KNN – so anzupassen, dass die Belohnung maximiert wird. Im Rahmen dieses Teilprojekts wird der Algorithmus Proximal Policy Optimization (PPO) als Actor-Critic-Ansatz verwendet. Durch den Einsatz von DRL ist es möglich, innerhalb von wenigen Sekunden Entscheidungsvorschläge zu generieren. Allerdings handelt es sich bei dem eingesetzten Verfahren um ein Black-Box-Modell. Bei den entwickelten Ansätzen handelt es sich allerdings um sog. Black-Box-Ansätze, welche nicht nachvollziehbar sind und sich deshalb negativ auf die Akzeptanz bei den Mitarbeitenden auswirken können.

### Einsatz von Explainable AI zur Akzeptanzsteigerung

Dieses Problem kann durch den Einsatz von Methoden der Explainable AI (XAI) adressiert werden. Prinzipiell kann hierbei zwischen ante-hoc und post-hoc Methoden unterschieden werden. Bei ante-hoc Verfahren sind die Entscheidungsregeln der eingesetzten Algorithmen (z. B. ein Entscheidungsbaum)

direkt ablesbar. Post-hoc Methoden hingegen verändern das Verfahren zur Entscheidungsfindung nicht, sondern generieren nachgelagert Erklärungen des eingesetzten Black-Box-Modells. Im Rahmen dieses Forschungsprojekts wurden post-hoc Methoden verwendet, da die vorhandene Komplexität mit Hilfe von transparenten Algorithmen nicht beherrscht werden kann.

Weiterhin kann bei den generierten Erklärungen zwischen lokalen und globalen Erklärungen unterschieden werden. Lokale Erklärungen zeigen den Einfluss auf eine einzelne Entscheidung, wohingegen die globalen Erklärungen das prinzipielle Verhalten des trainierten Modells erklären.

### Ergebnisse

Zur Bewertung des entwickelten Multiagentensystems mit DRL (DRL 1) zur Produktionssteuerung werden unterschiedliche Vergleichsszenarien definiert. Bei zwei der Szenarien handelt es sich um Heuristiken (Shortest Setup Time Next (SSTN) und First in – First out (FIFO)). Diese definieren einfache Regeln für die Reihenfolgebildung. Bei R 1 handelt es sich um einen manuell erstellten Produktionsplan.

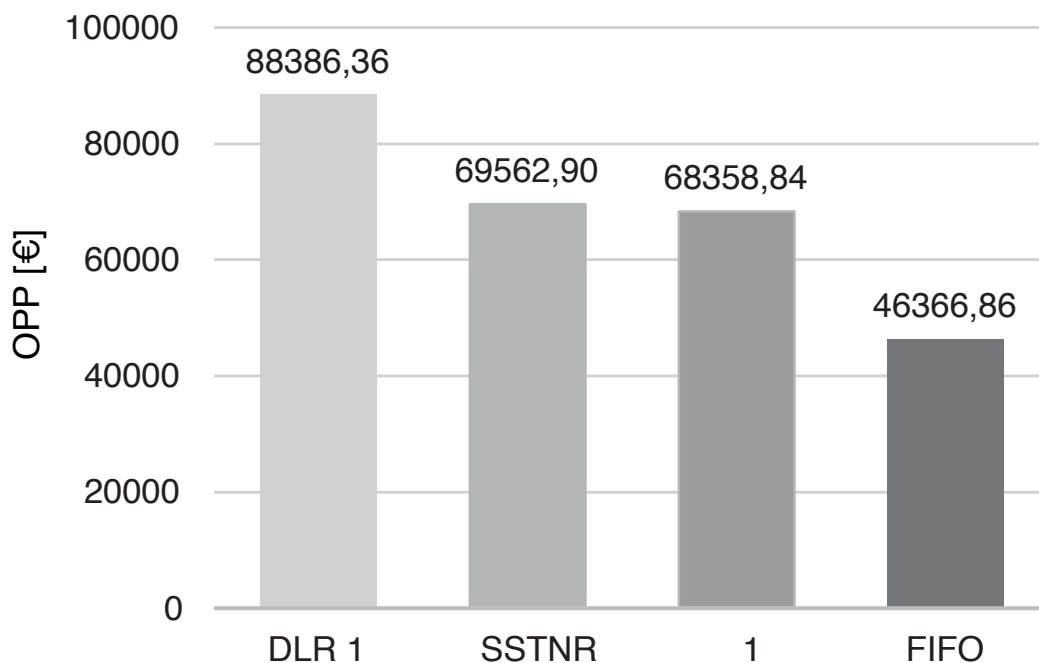


Abbildung 43: Durchschnittliche OPP in Abhängigkeit des untersuchten Simulationsszenarios (eigene Darstellung)

Abbildung 43 zeigt die mittlere OPP für die definierten Simulationsszenarien. Es zeigt sich, dass der entwickelte agentenbasierte Ansatz zur Produktionssteuerung die höchste OPP erzielt.

Abbildung 44 zeigt anhand eines Force-Plots den Einfluss unterschiedlicher Größen auf die Entscheidung, die Rezeptur R 1 zu wählen. Die Merkmalsrelevanz wird hierbei anhand der SHAP-Werte berechnet. Der zugrunde liegende Agent ist der eines Anlagenbedienenden, welcher die Aufgabe hat, aus einem Pool von Aufträgen den nächsten Auftrag auszuwählen.



Abbildung 44: Umsetzung einer lokalen Erklärung durch die Bestimmung der Merkmalsrelevanz (eigene Darstellung)

## Literatur

- Breyer, Michel; Furrer, Fadri; Novkovic, Tonci; Siegart, Roland; Nieto, Juan (2018): Flexible Robotic Grasping with Sim-to-Real Transfer based Reinforcement Learning. Online verfügbar unter <http://arxiv.org/pdf/1803.04996v2>.
- Friedli, Thomas; Mundt, Andreas; Thomas, Stefan (2014): Strategic Management of Global Manufacturing Networks. Aligning Strategy, Configuration, and Coordination. Aufl. 2014. Cham: Springer International Publishing.
- Friedli, Thomas; Schuh, Günther (2012): Wettbewerbsfähigkeit der Produktion an Hochlohnstandorten. Berlin, Heidelberg: Springer Berlin Heidelberg.
- Gaafar, Lotfi K.; Choueiki, M. Hisham (2000): A neural network model for solving the lot-sizing problem. In: *Omega* 28 (2), S. 175–184. DOI: 10.1016/S0305-0483(99)00035-3.
- Gatteschi, Valentina; Lamberti, Fabrizio; Demartini, Claudio; Pranteda, Chiara; Santamaria, Victor (2018): To Blockchain or Not to Blockchain: That Is the Question. In: *IT Prof.* 20 (2), S. 62–74. DOI: 10.1109/MITP.2018.021921652.
- Geffner, Hector (2018): Model-free, Model-based, and General Intelligence. Online verfügbar unter <http://arxiv.org/pdf/1806.02308v1>.
- IBM (2019): IBM Food Trust. Online verfügbar unter <https://www.ibm.com/de-de/marketplace/food-trust>, zuletzt geprüft am 26.02.2019.
- Jacob, Frank (2006): Quantitative Optimierung dynamischer Produktionsnetzwerke. Aachen: Shaker (Darmstädter Forschungsberichte für Konstruktion und Fertigung).
- Jacob, Frank; Strube, Gernot (2008): Why Go Global? The Multinational Imperative. In: Eberhard Abele, Tobias Meyer, Ulrich Näher, Gernot Strube und Richard Sykes (Hg.): *Global Production*. Berlin, Heidelberg: Springer Berlin Heidelberg, S. 2–33.
- Laptev, Nikolay; Yosinski, Jason; Erran Li, Li; Smyl, Slawek (2017): Time-series Extreme Event Forecasting with Neural Networks at Uber: CML Time Series Workshop.
- Mnih, Volodymyr; Kavukcuoglu, Koray; Silver, David; Rusu, Andrei A.; Veness, Joel; Bellemare, Marc G. et al. (2015): Human-level control through deep reinforcement learning. In: *Nature* 518 (7540), S. 529–533. DOI: 10.1038/nature14236.
- Möller, Klaus; Klatt, Tobias; Drees, Alexander (2011): Heutige und zukünftige Paradigmen des Produktionsstandorts Deutschland. In: Jürgen Gausemeier und Hans-Peter Wiendahl (Hg.): *Wertschöpfung und Beschäftigung in Deutschland*. Berlin, Heidelberg: Springer Berlin Heidelberg, S. 19–33.
- Roland Berger: The Supply Chain Excellence Study. Online verfügbar unter <https://www.rolandberger.com/de/Publications/Supply-Chain-Excellence-Study.html>, zuletzt geprüft am 23.02.2023.
- Rudberg, Martin; Martin West, B. (2008): Global operations strategy: Coordinating manufacturing networks. In: *Omega* 36 (1), S. 91–106. DOI: 10.1016/j.omega.2005.10.008.
- Sager, Benedikt (2019): Konfiguration globaler Produktionsnetzwerke. München: utzverlag (Forschungsberichte IWB, Band 344).
- Schmid, Martin (2018): Kognitive Prozesssteuerung zur Steigerung der Ressourceneffizienz in der Druckindustrie. München: Herbert Utz Verlag (Forschungsberichte IWB, Band 335).
- Susto, Gian Antonio; Schirru, Andrea; Pampuri, Simone; Pagano, Daniele; McLoone, Sean; Beghi, Alessandro (2013): A predictive maintenance system for integral type faults based on support vector machines: An application to ion implantation. In: 2013 IEEE International Conference on Automation Science and Engineering (CASE). 2013 IEEE International Conference on Automation Science and Engineering (CASE 2013). Madison, WI, USA, 17.08.2013 – 20.08.2013: IEEE, S. 195–200.
- Sutton, Richard S.; Barto, Andrew (2018): Reinforcement learning. An introduction. Second edition. Cambridge, Massachusetts, London, England: The MIT Press (Adaptive computation and machine learning).
- Teng, Dan; Dasgupta, Sakyasingha (2018): Continuous Time-series Forecasting with Deep and Shallow Stochastic Processes. In: 32nd Conference on Neural Information.
- Theumer, Philipp; Edenhofner, Florian; Zimmermann, Roland; Zipfel, Alexander (2022): Explainable Deep Reinforcement Learning for Production Control. Unter Mitarbeit von Technische Informationsbi-

- bliothek (TIB), David Herberger und Marco Hübner: Hannover : publish-Ing.
- Theumer et al.: Schematischer Aufbau des Multiagentensystems, 2022 (Abbildung 42)
  - Thomas, Stefan (2013): Produktionsnetzwerksysteme: Ein Weg zu effizienten Produktionsnetzwerken. Dissertation, St. Gallen.
  - Tian, Feng (2016): An agri-food supply chain traceability system for China based on RFID & blockchain technology. In: 2016 13th International Conference on Service Systems and Service Management (ICSSSM).
  - Waschneck, Bernd; André Reichstaller; Lenz Belzner; Thomas Altenmüller; Thomas Bauernhansl; Alexander Knapp und Andreas Kyek (2018): Optimization of global production scheduling with deep reinforcement learning. *Procedia CIRP* 72: 1264–1269. doi: 10.1016/j.procir.2018.03.212.
  - Zeng, Andy; Song, Shuran; Welker, Stefan; Lee, Johnny; Rodriguez, Alberto; Funkhouser, Thomas (2018): Learning Synergies between Pushing and Grasping with Self-supervised Deep Reinforcement Learning. Online verfügbar unter <http://arxiv.org/pdf/1803.09956v3>.
  - Zipfel, Alexander; Daniel Herdeg und Philipp Theumer (2021): Method for quantifying the value of information for production control in cross-company value-adding networks. *Procedia Manufacturing* 54: 1–6. doi: 10.1016/j.promfg.2021.07.001
  - Zipfel et al.: Kennzahlensystem zur operativen Produktionsperformance, 2021 (Abbildung 41)

## 2.1.5 Teilprojekt V – Bedarfsgerechte Produktionspläne

Schaten, Daniel (Westfleisch SCE mbH), Schallner, Harald (Jade Hochschule), Pargmann, Hergen (CompanyMind GmbH & Co. KG)

Aktive Partner: **Westfleisch SCE mbH**, Fraunhofer IGCV, Jade Hochschule

Assoziierte Partner: CompanyMind GmbH & Co. KG

### 2.1.5.1 Gesamtziel des Teilprojekts

Das Ziel des Teilprojekts ist es, durch den Einsatz von Künstlicher Intelligenz (KI) die Verschwendung von Lebensmitteln drastisch zu reduzieren. Ein besonderes Augenmerk des Projekts liegt auf einer ganzheitlichen Optimierungsstrategie über mehrere Wertschöpfungspartner hinweg.

Um eine Reduzierung der Lebensmittelverschwendung zu ermöglichen, ist das Gesamtziel dieses Teilvorhabens eine anforderungsgerechte Konzeption, prototypische Entwicklung und wissenschaftliche Validierung von maschinellen Lernalgorithmen, welche einen ressourcenschonenden Produktionsplanungsprozess in der deutschen Lebensmittelbranche unterstützen.

Auf der Basis von Reinforcement Learning Algorithmen und einer verbesserten Prognosegüte des Fleischkonsums wurden folgende Verbesserungspotenziale fokussiert:

- Vermeidung unnötiger Überproduktionen,
- Einhaltung der geforderten Restdauer für die Mindesthaltbarkeit,
- Reduzierung von Kühllagerbeständen und des Energiebedarfs zur Kühlung und
- passgenaue Planung der Tieranlieferung.

Die Validierung und Qualitätssicherung des KI-Prototyps erfolgte durch die Jade Hochschule für den prototypischen Einsatz in einem Produktionswerk des Anwenderunternehmens Westfleisch SCE mbH. Die anforderungsgerechte Implementierung des KI-Prototyps wurde von dem KI-Start-up CompanyMind GmbH & Co. KG übernommen. Bei der Konzeption und Entwicklung des KI-Prototyps wurde auf die Übertragbarkeit auf weitere Unternehmen der Lebensmittelbranche geachtet und durch eine Integration des KI-Prototypen in die REIF-Plattform sichergestellt. Folglich kann die REIF-Plattform nach dem Projektende jedem interessierten Unternehmen einen KI-basierten Dienst für eine ressourcenschonende und intelligente Produktionsplanung anbieten.

### Ansätze für die Anwendung Künstlicher Intelligenz

Prozessbedingte Abhängigkeiten innerhalb lebensmittelverarbeitender Unternehmen und vielfältige Lieferrelationen zwischen interagierenden Unternehmen führen zu einer enormen Komplexität in den Wertschöpfungsketten der Lebensmittelindustrie. Konventionelle Planungs- und Steuerungsalgorithmen sind nicht in der Lage, diese Komplexität zu beherrschen und zu einer signifikanten Reduzierung der Lebensmittelverschwendung beizutragen. Ansätze der KI bieten hier jedoch Abhilfe, um Überproduktion und Ausschuss zu verringern. Insbesondere durch die über den gesamten Wertschöpfungsprozess verteilte Generierung enormer Datenmengen – z. B. zur Realisierung der vom Gesetzgeber geforderten lückenlosen Rückverfolgbarkeit – ist die Lebensmittelindustrie prädestiniert für die Anwendung von KI-Methoden.

Mit ihrem vielfältigen Produktportfolio bildet die Lebensmittelindustrie darüber hinaus eine Vielzahl von industriellen Fertigungs- und Vertriebssystemen ab. Auf KI spezialisierte Unternehmen erhielten dadurch im Rahmen von REIF die Möglichkeit, eine große Anzahl unterschiedlicher, potenziell durch KI zu optimierender Prozesse kennenzulernen und dadurch Erfahrungen im Bereich des gezielten und effektiven Einsatzes unterschiedlicher KI-Technologien zu sammeln. Gleichzeitig wurden im Rahmen des Forschungsprojektes die oft mittelständisch geprägten Unternehmen der Lebensmittelbranche an das Zukunftsthema KI herangeführt.

### 2.1.5.2 Wissenschaftliche und/oder technische Arbeitsziele

Dieses Teilvorhaben gliedert sich in das Gesamtvorhaben über das Teilprojekt V „Ableitung bedarfsgerechter Produktionspläne basierend auf den prognostizierten Bedarfen“ ein. In diesem Teilprojekt wurden die Verschwendungstreiber Überproduktion und Ausschuss exemplarisch in der Fleischbranche adressiert. In dem Anwendungsfeld wurden konkrete KI-basierte Lösungen zur Verschwendungsreduktion entwickelt, erprobt und anschließend in die REIF-Plattform eingebunden. Eine Systematisierung der dabei entwickelten Herangehensweise stellte sicher, dass die Ergebnisse anschließend auf weitere Anwendungsfelder übertragbar sind. In dem Teilprojekt V wurden innovative Verbesserungspotenziale in den Produktionsprozessen der Fleischbranche realisiert, um folgende besondere Herausforderungen an eine nachhaltige und bedarfsgerechte Planung der Erzeugung zu adressieren:

1. Die Nahrungsmittelbranche zeichnet sich durch eine hohe Varianz der Qualitätseigenschaften von Rohstoffen aus, die wiederum zu Endprodukten mit gleichbleibenden Eigenschaften weiterverarbeitet werden müssen.
2. Von der Rohstoffherzeugung – beispielsweise Ferkelaufzucht, Kälber – bis zum Start des Produktionsprozesses sind unterschiedliche Zeiträume zu koordinieren. Die Aufzucht kann mehrere Jahre dauern, Lieferbedarfe können sich jedoch täglich und saisonal ändern. Hinzu kommen globale Nachfrageschwankungen.
3. Innerhalb der Supply Chain müssen Kühlketten, begrenzte Lagerortkapazitäten mit geeigneten Umwelteigenschaften (Temperatur, Luftfeuchtigkeit, Luftreinheit, Keimfreiheit) als auch Transportkapazitäten im kurzfristigen Horizont geplant werden.
4. Der Einhaltung von Mindesthaltbarkeitsanforderungen (MHD) steht eine hohe Produktvielfalt mit Variantenfertigung gegenüber (halal, kosher, vegetarisch, vegan).

Durch den Einsatz von Methoden der KI, insbesondere des maschinellen Lernens, wurden die Produktionsprozesse im Gesamtkontext unternehmensübergreifend optimiert. Hierzu wurden nicht nur komplex funktionale Abhängigkeiten wie beispielsweise jahreszeitliche Sortimentsschwankungen der Produktnachfrage berücksichtigt, sondern es fanden auch Faktoren wie Wetterdaten, Konsumtrends der Endverbraucher Eingang in die Berechnung einer optimalen, absatzgerechten Produktionsplanung, damit keine Produkte verschwendet bzw. zu nicht wirtschaftlichen Preisen angeboten werden müssen. Dabei wurde eine „datenarme“ KI über die Methode des sogenannten Reinforcement Learning (bestärkendes Lernen) realisiert. Im Gegensatz zu den Methoden des Supervised Learning (überwachtes Lernen) und Unsupervised Learning (unüberwachtes Lernen) werden keine großen Datenbestände benötigt. Stattdessen wurde innerhalb einer Lernumgebung ein Agent implementiert, der bezogen auf eine frei definierbare Zielfunktion eine Lösung erlernt, indem diese sich einem Maximalwert in jeder Lernperiode schrittweise nähert, siehe folgende Abbildung 45:

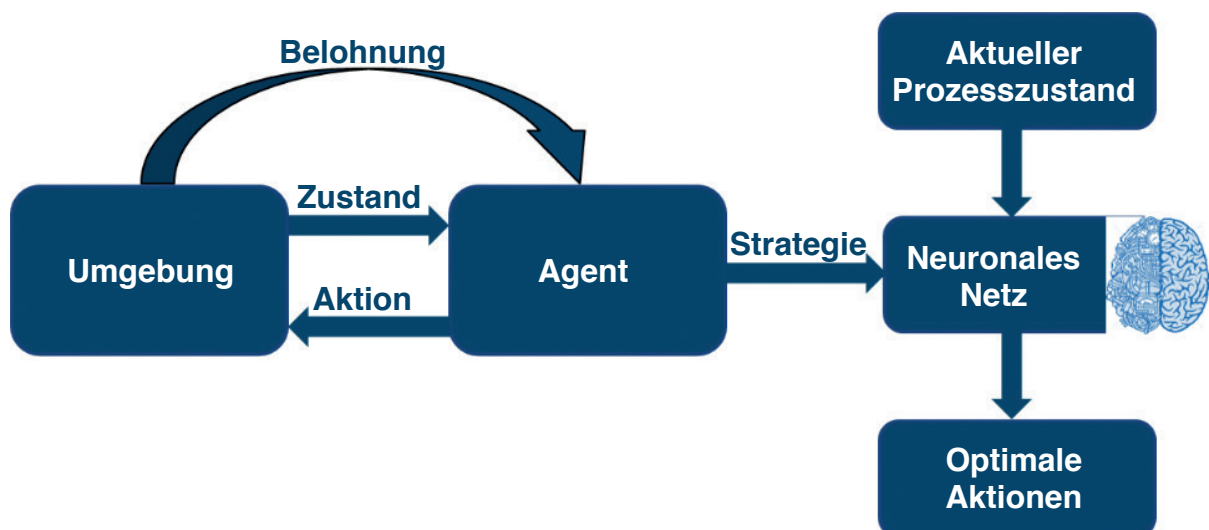


Abbildung 45: Reinforcement Learning (eigene Darstellung)

Des Weiteren wurde die Qualitätssicherung des KI-Prototypen über das „Expertenforum Künstliche Intelligenz“ (Teilprojekt I) umgesetzt, indem innerhalb des REIF-Ökosystems ein wissenschaftlicher Austausch über die Möglichkeiten und Grenzen des Einsatzes von maschinellen Lernmethoden etabliert wurde. Zur Evaluierung des Einsatzes von Machine Learning Algorithmen wurden die Kriterien Stabilität, Erklärbarkeit, Reproduzierbarkeit und Optimalität herangezogen. Die Strukturierung des Expertenforums nach den drei Arten des Machine Learning ermöglichte es, zielgerichtet spezifische Herausforderungen der Teilprojekte zu thematisieren und gemeinsam nach spezifischen Lösungen zu suchen.

Die Fleischwarenindustrie ist durch sehr geringe Margen innerhalb ihrer Produktionsketten gekennzeichnet. Umso stärker macht sich eine Vergeudung oder Verschwendung von Ressourcen an Tieren, menschlicher Arbeitskraft und Energie bemerkbar. Gerade in der heutigen Zeit wird eine optimale, vollständige und nachhaltige Nutzung aller eingesetzten Betriebsmittel von der Gesellschaft eingefordert.

Eine bedarfsgerechte, zeitnahe und zuverlässige Produktion von vom Endkunden gewünschten Produkten ist eine wesentliche Prämisse innerhalb der Lebensmittel- bzw. Fleischwarenindustrie. Um dies zu realisieren, müssen primär kostenintensive Kühllagerbestände reduziert, Ausschussmengen und Ausschusschragen reduziert sowie eine Abstufung von Produktqualitäten verhindert werden.

Mit herkömmlichen Planungsszenarien ist dieser hohe Anspruch nicht zu gewährleisten, da zu viele direkte und indirekte Einflussfaktoren zum Tragen kommen. Beispielhaft sind hier das Wetter, das Konsumverhalten des Endkunden und die sehr starke Schwankung der für die Verarbeitung zur Verfügung stehenden Tiere. Es ist derzeit planerisch kaum möglich, die funktionalen und nicht funktionalen Einflussfaktoren hinreichend gut zu quantifizieren. Hier wurden durch angewandte Methoden der KI aus dem Bereich der neuronalen Netze bisher unmöglich erscheinende Qualitäten zum Vorschein gebracht.

Um dieses Ziel – optimale, bedarfsgerechte Produktionspläne – zu erreichen, mussten die im Folgenden beschriebenen Teilschritte bearbeitet werden. Zuerst galt es, die aktuellen Produktionsplanungsprozesse durch die Anwendung formaler Methoden zu analysieren. Dadurch konnten erstmalig alle Teilprozesse einer homogenen Analyse zugeführt werden. Die folgende Schwachstellenanalyse identifizierte erstmalig quantitative und qualitative Ressourcenverschwendungen in Bezug auf eingesetzte Edukte (Tiere) und Kühlenergie. Aufbauend auf der Schwachstellenanalyse galt es, die Potenzialanalyse für eine ressourcenschonende Produktion durchzuführen. Dadurch wurden quantitative und qualitative Bewertungen der Verbesserungspotenziale für jede identifizierte Schwachstelle realisierbar. Als nächster Schritt wurde eine Anforderungsanalyse an dem ressourcenschonenden Produktionsplanungsprozess durchgeführt. Ziel hierbei war die erstmalige Erstellung valider Prognosen basierend auf den detaillierten Beschreibungen der Anforderungen.

Für eine optimierte Produktionsplanung und für neue Geschäftsprozessdesigns wurden maschinelle Lernalgorithmen entwickelt. Hier wurde besonderer Augenmerk auf das Veränderungsmanagement gelegt. Unter Berücksichtigung der Anforderungen wurde das Ziel erreicht, einen Softwareentwurf eines KI-Prototypen für eine Unterstützung des ressourcenschonenden Produktionsplanungsprozesses zu erstellen. Hierzu wurden folgende Maßnahmen durchgeführt:

1. Entwurf einer Softwarearchitektur und Systemlandschaft, die einen optimalen Informationsfluss gewährleisten.
2. Darauf aufbauend das Deep Learning Framework Tensor Flow Agents anforderungsgerecht ausgewählt und eine zielgruppenadäquate Benutzungsoberfläche bestimmt. Des Weiteren wurden Lern-, Test- und Validierungsdaten identifiziert, aufbereitet und bereitgestellt.
3. Der Softwareentwurf des anforderungsgerechten KI-Prototypen wurde im nächsten Schritt implementiert. Zu diesem Teilschritt gehörten die Programmierung und der Test der KI-Software sowie Ausprägung aller notwendigen Interfaces zu den ERP-Systemen.
4. Zur Validierung und Qualitätssicherung des KI-Prototypen wurde ein Vergleich einer simulativen Produktionsplanung (Schattenplanung) in einem Produktionswerk von Westfleisch mit der operativen Produktionsplanung durchgeführt.
5. Darüber hinaus konnten weitere Verbesserungspotenziale ausgemacht werden. Der validierte KI-Prototypen wurde kontinuierlich weiterentwickelt. Zur Qualitätssicherung des KI-Prototypen fand eine wissenschaftliche Analyse und Prüfung der KI-Prototypen hinsichtlich der Kriterien Stabilität,

Erklärbarkeit, Reproduzierbarkeit und Optimalität statt.

6. Abschließend wurde die Integration in die REIF-Plattform durchgeführt. Dazu wurde eine Umsetzung der Datenfreigabestrategien vorgenommen sowie eine Schnittstellenprogrammierung zur REIF-Plattform implementiert, welche mit einem Integrationstest abschloss.

### 2.1.5.3 Verwendung der Zuwendung und erzielte Ergebnisse

Der Einsatz von Ressourcen und die mit ihnen erzielten Ergebnisse können anhand der definierten Arbeitspakete (AP) des Teilprojekts V abgeleitet werden, in denen die oben aufgeführten Maßnahmen gebündelt dargestellt sind. Hierbei werden die jeweiligen Zuwendungsempfänger bzw. verantwortlichen Institutionen (Jade Hochschule/ JH und Westfleisch SCE mbH /WF) genannt – und inwieweit die gesteckten Ziele erreicht wurden.

#### 2.1.5.3.1 AP V.1 Analyse des aktuellen Produktionsplanungsprozesses (WF)

Um den Produktionsplanungsprozess zu optimieren, war eine formale Darstellungsweise aller Abläufe zwingend notwendig, um dann eine Optimierung korrekt anwenden zu können. Hierbei war das Ziel, ein quantitativ und qualitativ bewertetes Verbesserungspotential für den Produktionsplanungsprozess zu erarbeiten. Hieraus folgen die drei weiteren Teilaufgaben:

##### **AP V1.1: Aufbereitung des IST-Geschäftsprozesses (WF)**

Als Ergebnisdokument wurden alle IST-Geschäftsprozesse der Produktionsplanung von WF auf Basis von diversen Analyseschritten modelliert, entwickelt und final validiert. Hierzu sind speziell adaptierte Modellierungskonventionen festgelegt worden, um mit ihnen die Vielzahl der IST-Prozesse zu modellieren und zu validieren. Als Ergebnis wurde eine formale Modellierung als Dokumentation aller relevanten Geschäftsprozesse von WF erstellt.

Alle gesteckten Ziele wurden erreicht und der geplante Personalaufwand von zwei Personenmonaten (PM) konnte eingehalten werden.

##### **AP V1.2: Identifikation von Ressourcenverschwendung (WF)**

Ziel war es, Ressourcenverschwendung bez. Energieverbrauch und Tieren (Rind und Schwein) zu identifizieren. Hierzu wurden die unter V1.1 Geschäftsprozesse aufgenommenen formalen Geschäftsprozesse auf unterschiedliche Schwachstellentypen hinsichtlich Ressourcenverschwendung analysiert und eine Vielzahl von Schwachstellen konnte im Produktionsplanungsprozess identifiziert und dokumentiert werden.

Alle gesteckten Ziele wurden erreicht und der geplante Personalaufwand von zwei PM konnte eingehalten werden.

##### **AP V1.3: Ableitung von Verbesserungspotenzialen (WF)**

Nach den o. g. Vorarbeiten sollte eine Ableitung von quantitativ und qualitativ bewerteten Verbesserungspotenzialen für jede identifizierte Schwachstelle erzeugt werden. Dies wurde auf Basis von Literaturrecherchen umgesetzt, indem Ansätze identifiziert wurden, wie bereits identifizierte Schwachstellen qualitativ und quantitativ bewertet werden konnten. Als Ergebnis wurde eine Dokumentation erstellt, die alle qualitativen und quantitativen Verbesserungspotenziale aufzeigt.

Alle gesteckten Ziele wurden erreicht und der geplante Personalaufwand von zwei PM konnte eingehalten werden.



### 2.1.5.3.2 AP V.2 Konzeptionierung eines ressourcenschonenden Produktionsplanungsprozesses (JH)

Nachdem diese Vorarbeiten abgeschlossen waren, konnte ein anforderungsbasiertes Geschäftsprozessdesign erstellt werden, welches für den Einsatz von maschinellen Lernalgorithmen für eine optimierte Produktionsplanung geeignet ist.

#### **AP V2.1: Anforderungsanalyse an einen ressourcenschonenden Produktionsplanungsprozess (WF)**

Um das Gesamtziel des AP V.2 zu erreichen, musste eine detaillierte Beschreibung der Anforderungen für einen ressourcenschonenden Produktionsplanungsprozess erstellt werden. Hierzu wurden aus den identifizierten Verbesserungspotenzialen Anforderungen definiert und anschließend aufeinander abgestimmt und priorisiert. Hierzu wurden u. a. Transformationen der Verbesserungspotenziale an den Produktionsplanungsprozess umgesetzt. Als Ergebnisdokument wurde eine abgestimmte und priorisierte Anforderungsliste erzeugt.

Alle gesteckten Ziele wurden erreicht und der geplante Personalaufwand von drei PM konnte eingehalten werden.

#### **AP V2.2: Geschäftsprozessdesign einer optimierten Produktionsplanung (JH)**

Aus der Anforderungsliste musste nun ein Geschäftsprozessdesign für den Einsatz von maschinellen Lernalgorithmen für eine optimierte Produktionsplanung erstellt werden. Hierzu wurden Expertenworkshops durchgeführt, um Geschäftsprozesse derart abzubilden, dass sie formal korrekt modelliert und durch planungsrelevante Soll-Datenflüsse aufbereitet werden konnten. Somit waren abschließend alle Soll-Geschäftsprozesse optimiert und nach Abstimmungen in machbare Soll-Geschäftsprozesse transformiert.

Alle gesteckten Ziele wurden erreicht und der geplante Personalaufwand von drei PM konnte eingehalten werden.

### 2.1.5.3.3 AP V.3 Aufbau eines KI-Prototypen (WF)

Nach diesen Vorarbeiten konnte die Entwicklung eines KI-Prototypen avisiert werden, der nach einer finalen Validierung in die REIF-Plattform integriert werden konnte.

#### **AP V3.1: Entwurf eines anforderungsgerechten KI-Prototypen (WF)**

Um das Ziel des AP zu erreichen, musste ein Softwareentwurf für einen KI-Prototypen entwickelt werden, der für eine Unterstützung des ressourcenschonenden Produktionsplanungsprozesses geeignet war. Basierend auf den bisher identifizierten Anforderungen wurde eine Softwareumgebung definiert und in einer geeigneten Umgebung implementiert, um ihn danach qualitativ und quantitativ zu evaluieren. Um dies zu erreichen, wurden mehrere (public domain) Deep Learning Frameworks analysiert und das am besten geeignete Framework TensorFlow Agents ausgewählt. Parallel hierzu wurde auch eine optimierte Benutzungsoberfläche für den KI-Prototypen entwickelt. Alle Entwicklungen mündeten in einen dokumentierten und abgenommenen Entwurf eines KI-Prototypen.

Alle gesteckten Ziele wurden erreicht und der geplante Personalaufwand von zwei PM konnte eingehalten werden.

#### **AP V3.2: Implementierung des KI-Prototypen (WF)**

Auf den Entwurf des KI-Prototypen konnte nun eine Implementierung des anforderungsgerechten KI-Prototypen erfolgen. Hierzu wurden die entsprechenden KI-Algorithmen implementiert und durch Funktionstests auf ihre Korrektheit hin evaluiert. Bei ersten Tests wurde eine Vielzahl von Verbesserungspotenzialen identifiziert und fanden Eingang in die entsprechenden Implementierungen der Algorithmen. Dies alles führte zu einem validierbaren KI-Prototypen.

Alle gesteckten Ziele wurden erreicht und der geplante Personalaufwand von zwei PM konnte eingehalten werden.

**AP V3.3: Validierung des KI-Prototypen (JH)**

Die neutrale, wissenschaftliche Validierung des erstellten KI-Prototypen wurde von der Jade Hochschule durchgeführt. Hierzu wurden simulative Produktionsplanungen (Schattenplanungen) für ein Produktionswerk von WF durchgeführt. Hieraus konnten Verbesserungspotenziale abgeleitet werden, welche dann Eingang in den KI-Prototypen nahmen. Am Ende dieses AP stand ein validierter und verbesserter KI-Prototyp dem Projekt zur Verfügung.

Alle gesteckten Ziele wurden erreicht und der geplante Personalaufwand von drei PM konnte eingehalten werden.

**AP V3.4: Integration in die REIF-Plattform (WF)**

Nachdem der KI-Prototyp die hinreichende Qualität für eine Veröffentlichung innerhalb der REIF-Plattform hatte, konnte nun seine Integration durchgeführt werden. Hierzu wurden diverse Interfaces implementiert, sodass eine transparente Integration möglich wurde. Die erfolgreiche Integration wurde dabei durch eine Vielzahl von Integrationstests sichergestellt. Zusätzlich wurden verschiedene Datenfreigabe-strategien erprobt und umgesetzt.

Alle gesteckten Ziele wurden erreicht und der geplante Personalaufwand von zwei PM konnte eingehalten werden.

**AP V3.5: Weiterentwicklung des KI-Prototypen (WF)**

Nach der erfolgreichen Integration in die REIF-Plattform bestand das nächste Ziel in der Weiterentwicklung des KI-Prototypen. Durch fortlaufende Tests wurden weitere Verbesserungspotenziale bez. Algorithmik und Benutzungsoberfläche identifiziert und nach weiteren Analysen im KI-Prototypen umgesetzt. Hierzu wurde eine Vielzahl von Anpassungen programmiert und durch automatische Tests validiert, um die Gesamtfunktionalität weiterhin aufrechtzuerhalten.

Alle gesteckten Ziele wurden erreicht und der geplante Personalaufwand von zwei PM konnte eingehalten werden.

**2.1.5.3.4 AP V4 Qualitätssicherung des KI-Prototypen (JH)**

Um wiederum eine neutrale Qualitätsprüfung des KI-Prototypen zu gewährleisten, übernahm die Jade Hochschule die finale Qualitätssicherung und die Veröffentlichung der Ergebnisse aus dem Forschungsprojekt bez. des KI-Prototypen.

**AP V4.1: Analyse und Prüfung des KI-Prototypen (JH)**

Ziel war die Bestätigung eines qualitätsgeprüften KI-Prototypen für das Forschungsprojekt. Hierzu wurde ausgehend von den bisher definierten Anforderungen an eine ressourcenschonende Planung und der Integration in die REIF-Plattform eine intensive Validierung vorgenommen. Dafür wurde das System anhand geeigneter Kriterien wissenschaftlich analysiert und geprüft. Besonders priorisierte Kriterien waren dabei Stabilität des Systems, Erklärbarkeit der KI-basierten Resultate sowie eine stabile Reproduzierbarkeit und Optimalität der Gesamtleistung des integrierten Systems. Hierbei wurden auch erstmals wissenschaftliche Erkenntnisse hinsichtlich Möglichkeiten und Grenzen eines KI-Prototypen gewonnen.

Alle gesteckten Ziele wurden erreicht und der geplante Personalaufwand von zwei PM konnte eingehalten werden.

**AP V4.2: Veröffentlichung und Dokumentation der Analyseergebnisse (JH)**

Die Jade Hochschule übernahm die Dokumentation und Veröffentlichung aller Analyseergebnisse. Hierzu wurden technische Dokumente erstellt als auch wissenschaftliche Veröffentlichungen angefertigt bzw. öffentliche Vorträge bez. des REIF-Projekts gehalten.

Alle gesteckten Ziele wurden erreicht und der geplante Personalaufwand von zwei PM konnte eingehalten werden.

### 2.1.5.4 Validierter KI-Prototyp

In dem Rahmen dieses Projektes wurde ein Reinforcement Learning Algorithmus entwickelt, um die Liefer- und Produktionspläne der Westfleisch SCE mbH so zu optimieren, dass die Kenngröße der Einfriermenge minimiert wird. Letztere drückt die überschüssige Menge an Produkten aus, welche aufgrund fehlender Bedarfe gelagert werden müssen. Da es sich bei den gelagerten Produkten um verderbliche Ware handelt, führt das Lagern dieser Produkte bei ausbleibenden Bedarfen teilweise dazu, dass die Ware verfällt und entsorgt werden muss.

Die KI-basierten Optimierungen gilt es auch visuell für die Mitarbeiter der Westfleisch SCE mbH nachvollziehbar zu machen. Aus diesem Grund wurden mit den Technologien SAP UI5 und Fiori-Elements drei Applikationen entwickelt, welche in den nachfolgenden Kapiteln für den Benutzer erläutert werden. Zu diesen Applikationen gehören eine Applikation zu der Verwaltung aller Lieferungen, eine Applikation zu der Verwaltung aller Kundenaufträge und eine Applikation zu der Übersicht aller wichtigen Kennzahlen. Die genannten Applikationen sind über die REIF-Plattform nutzbar.

### 2.1.5.5 Lieferungen

Die Applikation „Lieferungen“ wird genutzt, um alle Lieferungen darzustellen und Lieferterminvorschläge der KI-basierten Optimierung zu betrachten, bestätigen oder abzulehnen.

Nach dem Starten der „Lieferungen“ Applikation ist Folgendes zu sehen:

The screenshot shows the 'Lieferungen' application interface. At the top, there is a 'Standard' filter dropdown and a 'Start' button. Below this is a filter bar with fields for 'Planungstag', 'Liefernummer', 'Ursprünglicher Liefertermin', 'Vorgeschlagener Liefertermin', 'Verschiebung akzeptiert', 'Verschiebung geplant', 'PUSH-HKKL', and 'Stück'. The main part of the interface is a table with the following columns: 'Liefernummer', 'Position', 'Planungstag', 'PUSH-HKKL', 'Stück', 'Ursprünglicher Liefertermin', 'Vorgeschlagener Liefertermin', 'Verschiebung akzeptiert', 'Verschiebung geplant', and two action buttons: 'Verschiebung Bestätigen' and 'Verschiebung Ablehnen'. The table contains four rows of data.

Liefernummer	Position	Planungstag	PUSH-HKKL	Stück	Ursprünglicher Liefertermin	Vorgeschlagener Liefertermin	Verschiebung akzeptiert	Verschiebung geplant		
1	10	02.02.2022	ME 05 DE	30	08.08.2022	08.08.2022	Nein	Nein	Verschiebung Bestätigen	Verschiebung Ablehnen
1	20	02.02.2022	SN ITW DE	11	08.08.2022	08.08.2022	Nein	Nein	Verschiebung Bestätigen	Verschiebung Ablehnen
1	30	02.02.2022	SN ITW DE DE	21	08.08.2022	08.08.2022	Nein	Nein	Verschiebung Bestätigen	Verschiebung Ablehnen
2	10	02.02.2022	ME 05 DE	22	08.08.2022	08.08.2022	Nein	Nein	Verschiebung Bestätigen	Verschiebung Ablehnen

Abbildung 46: Übersicht der App „Lieferungen“ (eigene Darstellung)

Das in Abbildung 46 zu sehende UI bietet dem Anwender die Möglichkeit, nach dem Planungstag, der Liefernummer, dem ursprünglichen Liefertermin, dem vorgeschlagenen Liefertermin, der Push Herkunftsklasse (Push-HKKL) und der Menge der Lieferposition zu filtern. Zusätzlich kann auch nach dem Status der Lieferung gefiltert werden. Dies beinhaltet das Filtern der Lieferungen nach bestätigten oder unbestätigten Lieferterminverschiebungen und möglichen geplanten Lieferterminverschiebungen. Sofern der Wert eines Datensatzes für die Spalten „Ursprünglicher Liefertermin“ und „Vorgeschlagener Liefertermin“ divergiert, ist eine Lieferterminverschiebung möglich. Hierzu muss der Anwender lediglich auf den Button „Verschiebung bestätigen“ drücken. Die Verschiebung einer Lieferposition hat natürlich die Verschiebung aller weiteren Lieferpositionen dieser Lieferung zufolge. Gleiches gilt auch für das Ablehnen eines Lieferterminvorschlages. Abgelehnt wird ein Lieferterminvorschlag dabei durch das Drücken des Buttons „Verschiebung ablehnen“.

### 2.1.5.6 Kundenaufträge

Die Applikation „Kundenaufträge“ stellt alle Kundenaufträge tabellarisch dar. Zu sehen ist dies auf der folgenden Abbildung 47.

Auftragsnummer	Position	Spät	Produktionsdatum	Kundennummer	Kunde	Produktbezeichnung	Verkaufszahl	Produktionszahl	Verfallsdatum	Push-HKKL	Änderung der Push-HKKL	Gebuchte Push-HKKL	Kundenanforderung	Auftragsmenge in Stück	Planungsdatum	Spätmenge
417.864	210	0 %	11.08.2022			W/S-Schalter Teile	233.026	100.271	11.08.2022	SN ITW DE NRW	kein	SN ITW DE NRW	SN ITW DE NRW	708	02.02.2022	708
	200	0 %	13.08.2022			W/KOT-Komplet Mac	233.039	100.008	13.08.2022	SN ITW DE NRW	kein	SN ITW DE NRW	SN ITW DE NRW	5.000	02.02.2022	5.000
418.112	40	0 %	13.08.2022			W/S-Schalter Teile	250.425	100.262	13.08.2022	SN QS DE	kein	SN QS DE	SN QS	335	02.02.2022	335
417.025	70	0 %	10.08.2022			W/S-Schalterteile 124	280.800	100.048	10.08.2022	SN QS DE Zusauf W16	ja	SN QS DE Zusauf W16	SN QS DE	85	02.02.2022	0

Abbildung 47: App „Kundenaufträge“ (eigene Darstellung)

Da die Qualitätsanforderungen der Abnehmer jedoch divergieren, wird auch dies bei den Lieferterminverschiebungen der KI berücksichtigt. Aufgrund dessen ist es notwendig, dass auch Veränderungen an dem Attribut „Push-HKKL“ durch die KI vorgenommen werden. Die „Push-HKKL“ beinhaltet die auszuliefernde Qualität der Produkte. Nur so wird für die Abnehmer immer die richtige Qualität sichergestellt und dennoch die Einfrieremenge reduziert. Folglich werden die von dem KI-Algorithmus vorgenommenen Veränderungen in dieser Applikation dargestellt.

### 2.1.5.7 Balancing Analyse

Die „Balancing Analyse“ Applikation bietet für den Benutzer die Möglichkeit, alle von der KI berechneten wichtigen Kennzahlen zu visualisieren und zu analysieren. Für die Analyse der Daten bietet diese Applikation eine tabellarische Darstellung, eine Metriken-Analyse und eine grafische Visualisierung. Natürlich sind die Daten dabei in allen genannten Darstellungen synchronisiert. Letzteres ist bei dem Filtern der KI-Planungsergebnisdaten von Bedeutung. So kann der Benutzer die Daten nach dem Planungstag, nach dem Datum, dem Material und der Qualität filtern. Der Planungstag bezieht sich auf das Datum, an dem die KI die Planungsergebnisse berechnet hat. Somit kann dieses Datum nur in der Gegenwart und in der Vergangenheit liegen. In der folgenden Abbildung 48 ist ein Screenshot der tabellarischen Darstellung zu sehen, welche KI-Planungsergebnisse vom 22.11.2022 beinhalten.

Tag	Datum	Nettomenge	Einfrieremenge	Zugangsmenge	Bedarf	Verfallene Kundenaufträge
0	05.08.2022	0	0	0	0	0
1	06.08.2022	0	0	0	0	0
2	08.08.2022	113046	0	132596	-19550	0
3	09.08.2022	213621	98927	121473	-23962	-3064
4	10.08.2022	206805	95845	117115	-27734	-2730
5	11.08.2022	206505	89231	120066	-25723	-1202
6	12.08.2022	200310	85608	115729	-32693	0
7	13.08.2022	154362	88940	68992	-29332	0
8	15.08.2022	65926	65926	0	0	-504

Abbildung 48: Tabellarische Darstellung der App „Balancing Analyse“ (eigene Darstellung)

Unter dem Abschnitt der Metriken-Analyse folgt eine Sektion mit einer grafischen Analyse der Daten. Diese Sektion soll die aggregierten Daten in angemessenen Diagrammen visuell darstellen. Dabei hat der Benutzer die Wahl zwischen zwei Diagrammtypen. Zum einen kann ein Linien-/Balken-Diagramm gewählt werden. In diesem Diagrammtyp sind die Kennzahlen „Zugang“, „Bedarf“, „verfallene Kundenaufträge“, „Nettomenge“ und „Einfrieremenge“ dargestellt. Zu den erstgenannten kann der Benutzer zusätzlich zwischen einer Linien- oder Balkendarstellung wählen. Dabei enthält die x-Achse das jeweilige

Datum, auf das sich die Daten beziehen, wohingegen die y-Achse absolute Zahlen enthält. Durch das Drücken auf eine der Kennzahlen auf der Legende oder in dem Diagramm selbst kann der Datensatz farblich hervorgehoben werden (Abbildung 49).

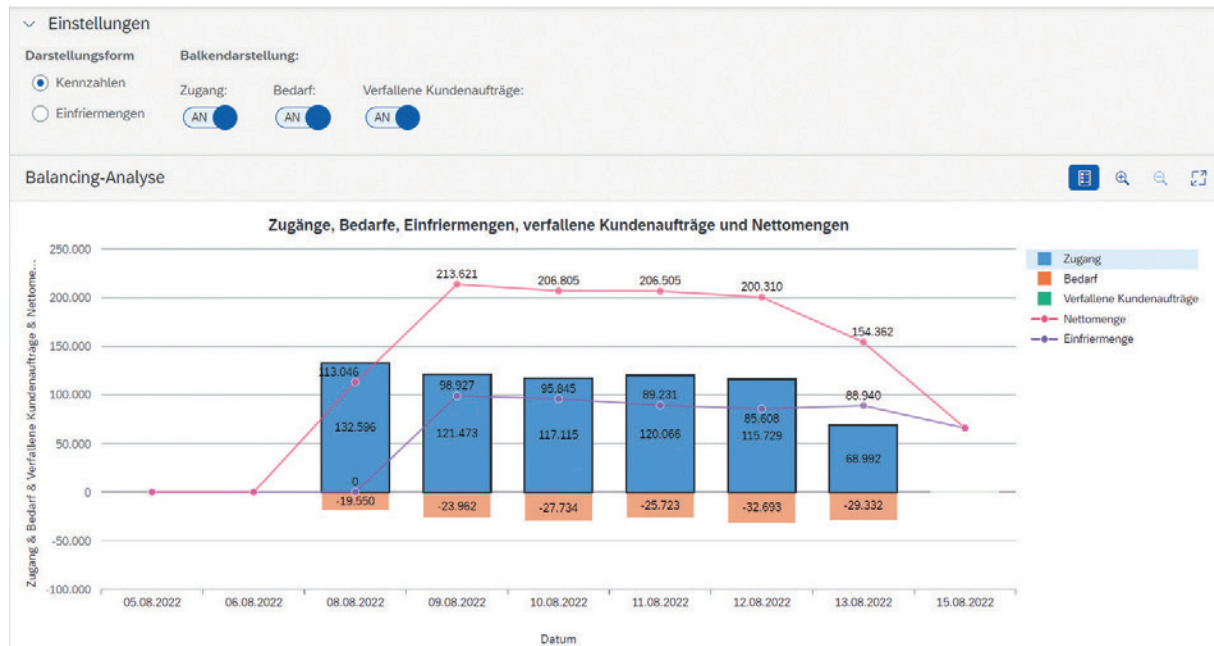


Abbildung 49: Grafische Analyse in der App „Balancing Analyse“ (eigene Darstellung)

Neben dem gezeigten Liniendiagramm existiert mit dem Drücken auf die Option „Einfriermenge“ ein Wasserfalldiagramm. Letzteres ist auf der Abbildung 50 zu sehen. Während sich die x- und y-Achse nicht von dem vorherigen Diagramm unterscheiden, wird die Einfriermenge über die Tage des Planungshorizonts hinweg aggregiert. Da es sich bei der Kennzahl „Einfriermenge“ um die zu minimierende Größe der KI handelt, hat diese Kennzahl eine besondere Bedeutung. Somit kann der Benutzer mithilfe des Wasserfalldiagramms sowohl nachvollziehen, an welchem Tag wie viel von einer bestimmten Ware eingefroren werden musste als auch die absolute Menge der eingefrorenen Ware über die Tage des Planungshorizonts hinweg betrachten. Letzteres ist sehr wichtig, da bestimmt werden kann, ab welchem Tag beispielsweise ein durch den Benutzer definierter Schwellenwert überschritten wird.



Abbildung 50: Grafische Analyse Wasserfalldiagramm (eigene Darstellung)

### 2.1.5.8 Integration des KI-Prototypen in die REIF-Plattform

Für die Integration des KI-Prototypen wurde ein Account auf der REIF-Plattform eingerichtet. Dieser wurde über den folgenden Link angelegt: <https://reif.sagresearch.de/de/signup>. Nachdem die nötigen Daten durch den Benutzer eingetragen wurden und ein Account auf der REIF-Plattform erstellt wurde, musste die Option „Marktplatz“ auf der REIF-Plattform aufgerufen werden. Wie in der Abbildung 51 zu sehen ist, muss nun der KI-Prototyp mit dem Namen „Bedarfsgerechte Produktionsplanung“ aufgerufen werden. Die Integration erfolgte über eine API-Konfiguration in Form eines OData-Services.

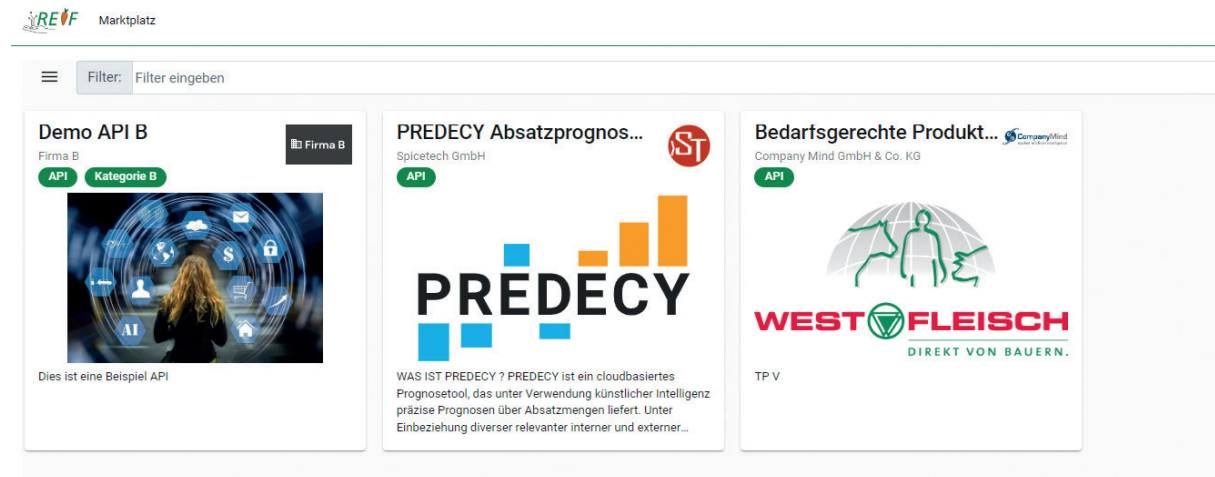


Abbildung 51: Marktplatz der REIF-Plattform (eigene Darstellung)

### Literatur

Die Literatur ist analog zu Kapitel 1.2.5

## 2.1.6 Teilprojekt VI – Zuverlässigkeit der Produktion

Becker, Ingo (Inotec GmbH/Handtmann Unternehmensgruppe), Fink, Klaus und Zimmermann, Patrick (Fraunhofer IGCV)

Aktive Partner: **Inotec GmbH/ Handtmann Unternehmensgruppe**, Fraunhofer IGCV, Westfleisch SCE mbH

Assoziierte Partner: -

In der Fleischverarbeitungsindustrie hat die Zuverlässigkeit der Produktion eine entscheidende Bedeutung für die Gewährleistung der Produktqualität, der Produktsicherheit und der Rentabilität. Die Integration von Künstlicher Intelligenz (KI) in den Produktionsprozess bietet Potenzial für die Verbesserung dieser Aspekte. Allerdings sind konkrete Anwendungsfälle (*Use Cases*) zur Erhöhung der Zuverlässigkeit der Produktion durch den Einsatz von KI noch nicht definiert. In diesem Artikel wird der aktuelle Stand der Technik in der Fleischverarbeitungsindustrie diskutiert. Betrachtet wird die Rezepturarbeit beim Mischen. Dabei wird auf die Herausforderungen in der Qualitätsbestimmung und die Möglichkeiten für den Einsatz von KI eingegangen.

### 2.1.6.1 Bestimmung geeigneter Anwendungsfälle (Use Cases)

Mit dem Ziel der Erhöhung der Zuverlässigkeit in der Produktion wurde in Teilprojekt VI untersucht, wie innerhalb der Fleischverarbeitung die Lebensmittelverschwendung mittels Künstlicher Intelligenz auf Maschinen- und Anlagenebene reduziert werden kann. Als Fleischverarbeitungsmaschine wurde hierbei ein Mischer der Marke Inotec gewählt (IVM 150), dessen KI-Potentiale näher betrachtet wurden. In der Praxis werden die Maschinen und Anlagen der Fleischverarbeitungsindustrie von erfahrenen bedienenden Personen häufig manuell eingestellt und nach Erfahrungswerten betrieben. Oftmals werden keine gesonderten Einstellungen je nach Produktrezeptur, Zusammensetzung der Rohstoffe oder Beladung der Verarbeitungsmaschinen vorgenommen. Der Prozess des Mischens der Produktrezeptur erfolgt nach einer Vorzerkleinerung der Ausgangsrohstoffe in einem Fleischwolf auf z. B. 13 mm Korngröße. Im Anschluss wird in der Praxis das gemischte Produkt gefüllt, portioniert und abgepackt.

Die gewählten Prozess- und Maschinenparameter des Mixers sind in der Regel nicht von außen auslesbar oder erfassbar und verbleiben auf der jeweiligen Produktionsmaschine. Eine dynamische Anpassung der Parameter ist bislang nicht vorgesehen. Im ersten Schritt definierte das Projektteam verschiedene *Use Cases*, welche grundsätzlich mit Methoden aus dem Bereich der Datenanalyse und der Künstlichen Intelligenz umgesetzt werden können.

In gemeinsamen Workshops konnte das Team, bestehend aus dem Maschinenhersteller Firma Inotec (in der Zwischenzeit zur Handtmann Firmengruppe zugehörig), der Firma Westfleisch als fleischverarbeitendes Unternehmen und Endanwender sowie dem Fraunhofer IGCV als Forschungsinstitut, insgesamt neun *Use Cases* identifizieren. Diese reichten von stark maschinenbezogenen Anwendungsfällen wie dem *Condition Monitoring* oder einer optimierten Anlagenreinigung bis hin zu verschiedenen Produktverbesserungspotentialen, beispielsweise durch optimierte Mischzeitvorgabe und Temperaturregelung, einer Verminderung des Energieeintrags oder einer optimalen Chargierung.

Anschließend erfolgte eine Einordnung der *Use Cases* bezüglich ihres Potentials zum Einsatz von KI sowie dem Beitrag zur Reduktion der Lebensmittelverschwendung. Einige der *Use Cases* hatten zwar ein hohes Potential zum Einsatz von KI-Methoden, jedoch nur geringe Einsparpotentiale in Bezug auf die Lebensmittelverschwendung. Mit der Realisierung des Anwendungsfalles „*Condition Monitoring*“ kann beispielsweise der Maschinenzustand überwacht und durch Datenanalyse geeigneter Merkmale frühzeitiger auf mögliche Fehler hingewiesen werden. Somit können Defekte während des Betriebs sowie ungeplante Stillstandszeiten vermieden werden. Derartige Ereignisse treten nur selten auf und verschwinden dabei in der Regel ausschließlich den Inhalt einer einzigen Charge. Verglichen mit der Gesamtmenge an verarbeitetem Fleisch bietet dieser Anwendungsfall prozentual gesehen somit nur ein

geringes Einsparpotential.

Stattdessen sollte ein Anwendungsfall gewählt werden, welcher für jede verarbeitete Charge potenziell positive Auswirkungen auf die Vermeidung von Lebensmittelverschwendung hat. Da keiner der ermittelten Use Cases alleinstehend diesbezüglich genügend Potenzial zeigte bei gleichzeitiger Eignung für die KI-basierte Datenverarbeitung, wurde übergeordnet die Erhöhung der Mindesthaltbarkeit des Fleischgemischs als Anwendungsfall im Projektteam festgelegt. Durch gezielte Veränderung der Stellgrößen im Mischer mithilfe von KI kann hier das insgesamt größte Potenzial erreicht werden. Stellgrößen sind hierbei unter anderem die Mischdauer oder auch die zusätzlich eingebrachte Kühlung des Produkts beim Mischvorgang. Eine weitere Untersuchung der benötigten Parameter für den hierbei zu verwendenden KI-Algorithmus brachte schnell die Erkenntnis, dass die Rückführgröße „Mindesthaltbarkeitsdatum“ oder „Alterungsgeschwindigkeit“ bei jedem Mischvorgang ermittelt werden müsste, um genügend Trainingsdaten zur Modellierung der Zusammenhänge zu erhalten. Die Bestimmung erfolgte jedoch im Labor mit mehreren Wochen Verzögerung, was bezüglich Messfrequenz und Zuordnung zu den einzelnen Mischchargen nicht ausreichend ist. Eine Inline-Messung, das bedeutet direkt in der Maschine bzw. der Produktionslinie bei laufendem Prozess messend, ist noch nicht im Stand der Technik verfügbar.

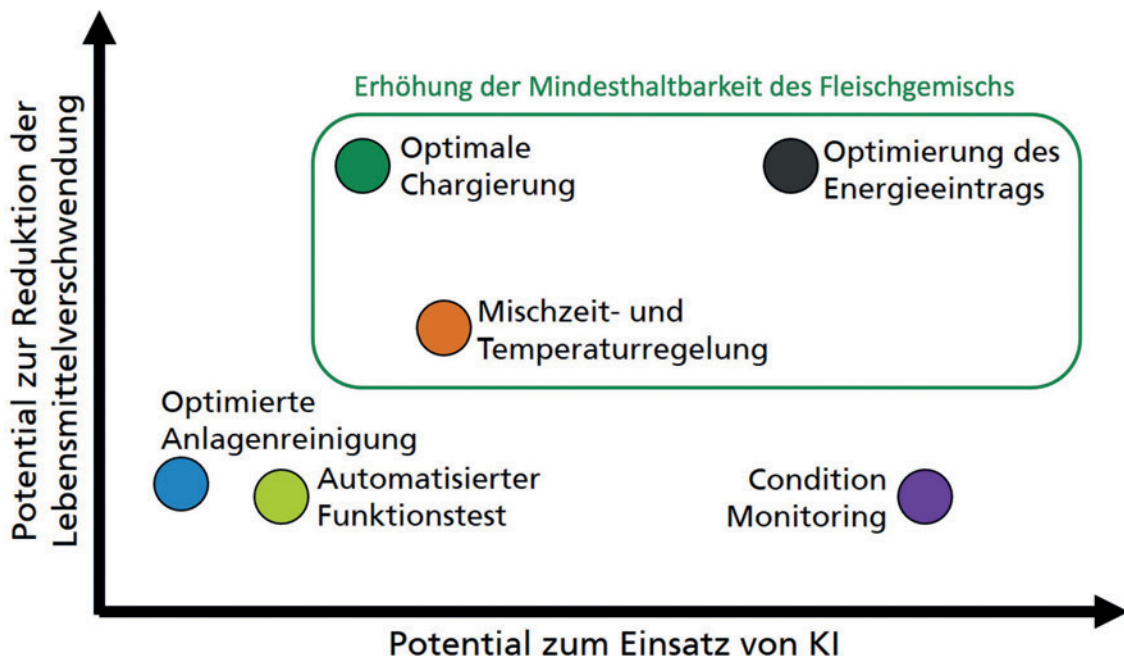


Abbildung 52: Darstellung der Einordnung der Use Cases (eigene Darstellung)

Es wurde weiterhin beschlossen, das Konzept einer „Erhöhung der Mindesthaltbarkeit“ als Kombination aus den Fällen „optimale Chargierung“, „Optimierung des Energieeintrags“ und „Mischzeit- und Temperaturregelung“ (Abbildung 52) zu verfolgen. Hierfür mussten zunächst die Voraussetzungen bezüglich der Sensorik für die Maschine, den Prozess und die Produktion geschaffen werden.

### 2.1.6.2 Ermittlung und Betrachtung geeigneter Messgrößen und der Sensorik

Zur Erfassung der Qualitätsparameter bedarf es geeigneter Sensorik aus dem Bereich der Spektroskopie. Da erkannt wurde, dass ein zu geringes Wissen über die Spektralanalyse hinsichtlich geeigneter Wellenlängen für den Qualitätszustand, den Eiweißaufschluss und der Alterung von Wurst- und Fleischerzeugnissen vorliegt, lag ein Teilziel des Projekts fortan darin, eine Messung der Mindesthaltbarkeit bzw. deren signifikantesten Einflussgrößen zu ermöglichen.

Die Feststellung der Produktbelastung und -qualität von Wurst- und Fleischerzeugnissen in Bezug auf Effekte, die durch die Verarbeitung in einem Misch- oder Zerkleinerungsprozess entstehen, ist derzeit



noch wenig erforscht. Die Recherche, einen Nachweis für einen direkten Zusammenhang zwischen Energieeintrag in ein frisches Wurst- oder Fleischprodukt (z. B. frische Bratwürste oder Hackfleisch (-produkte)) und dessen Haltbarkeit zu finden, blieb ohne Ergebnis. Um diesen Zusammenhang festzustellen, sind zunächst die bestehenden Wissenslücken zu identifizieren und zu schließen. Das betrifft die Zusammenhänge zwischen den Eingangsgrößen, wie die Beschaffenheit der einzelnen Rezeptur-Komponenten des gewünschten Lebensmittelprodukts, deren Verteilung im Mischraum, der gewählten Maschineneinstellungen und der Beladung sowie die Ausgangsgrößen: Beschaffenheit des fertig angemischten Lebensmittelprodukts, dessen Eiweißaufschlusses, des Alterungszustandes und der Beladung durch Mikroben, um eine Vorhersage über die Alterungsgeschwindigkeit zu treffen.

Da die tatsächliche Mindesthaltbarkeit durch mehrtägige bis mehrwöchige Labormessungen erfolgte, wurden andere direkt messbare Größen ermittelt, aus welchen sich kumuliert auf eine prognostizierte Mindesthaltbarkeit schließen lässt. Ein solches Konzept kann als „Softsensor“ (Kofferwort aus Software und Sensor) bezeichnet werden, da die Zielgröße indirekt über Software heuristisch hergeleitet und nicht unmittelbar ermittelt wird.

In verschiedenen Workshops mit Lebensmitteltechnologe:n haben sich insbesondere für den Mischprozess die Betrachtung der Größen „Homogenität“ (als direkte Zielgröße des Mischprozesses), Eiweißaufschluss (unerwünschte Nebenwirkung des Mischprozesses) und „Energieeintrag“ (Messbarkeit indirekt über die mechanische Leistungsabgabe gegeben) als zielführend erwiesen.

Diese drei Parameter besitzen einen Zusammenhang, da eine längere Mischdauer einen größeren Energieeintrag in das Fleisch zufolge hat, andererseits dadurch aber auch die Homogenität bis zu einer Grenze ansteigt. Grundsätzlich wird ein geringerer Energieeintrag als förderlich für die Verlängerung der Mindesthaltbarkeit angenommen. Eiweißaufschluss bedeutet das Herauslösen von Proteinen aus der Fleischmatrix an die Fleischoberfläche. Wie durch Berger et al. 2022 beschrieben, nimmt der Anteil an gelösten Proteinen im vorgewolften rohen Hackfleisch im Mischprozess zu. Die Kinetik des Wachstums von Mikroorganismen in Hackfleisch hängt von der Verfügbarkeit von Nährstoffen ab. Während Glukose bevorzugt wird, können fast alle Bakterien der Fleischmikrobiota auch andere Substrate wie Aminosäuren, Nukleotide oder wasserlösliche Proteine verstoffwechseln (vgl. Nychas et al. 2008, Casaburi et al. 2015). Diese sind im Fleischserum vorhanden und mit zunehmendem Herauslösen, d. h. mit zunehmendem Eiweißaufschluss als Substrat für das Wachstum von Mikroorganismen verfügbar.

Ziel war es, mithilfe der Messung über geeignete Sensorik den Zusammenhang zwischen Homogenität und Mischdauer bzw. dem damit zusammenhängenden Energieeintrag zu ermitteln bei gleichzeitiger Überwachung des Eiweißaufschlusses des Lebensmittelprodukts. In den Vorüberlegungen wurde dabei prognostiziert, dass der Energieeintrag linear mit der Mischdauer zusammenhängt. Zudem wurde vorhergesagt, dass, ab einer Sättigung, bei weiterer Mischdauer die Homogenität nicht mehr signifikant ansteigt. Auch die Beladung des Mischraumes (Batchgröße) und die Mischstrategie, also die Wellen-Drehzahl, Intervall-Dauer, Anzahl der Richtungsumkehr der Wellen und die Gesamt-Mischzeit, können hierbei einen Einfluss haben; daher wurden sie näher untersucht.

Ziel war auch, mithilfe der Datenanalyse die Zusammenhänge der Einflüsse über Korrelationen abzubilden, sodass auf Basis einer Nutzervorgabe der angestrebten Homogenität die optimale Mischstrategie passend zur Beladung ermittelt werden konnte. Diese sollte einen minimalen Eiweißaufschluss bewirken, um dadurch indirekt die Haltbarkeit des Lebensmittelprodukts nicht unnötig zu verringern.

Um den Energieeintrag zu ermitteln, konnten die Maschinenparameter und Messdaten des Mixers verwendet werden, welche die eingebaute Steuerung erfasst und in einem bestimmten Zeitintervall speichert. Erfasste Messgrößen waren hier beispielsweise Temperaturen an zwei Stellen im Mischraum, die Ist-Drehzahlen der Mischwellen und die Werte, die die beiden Frequenzumrichter von den Mischwellenantrieben liefern (Drehmoment, Strom, Leistung usw.). Aus diesen Größen ließ sich im Rahmen der Messgenauigkeiten auf die Zielgröße des mechanischen Energieeintrages ins Produkt rückschließen. Die für die per Softsensor zu messende Zielgröße der Mindesthaltbarkeit bzw. des Eiweißaufschlusses sowie die Homogenität des Produkts konnten hingegen nicht direkt inline gemessen werden, obwohl es für die Zielerreichung notwendig gewesen wäre. Aus diesem Grund wurde im Projektteam beschlossen, zusammen mit Experten im Bereich der Lebensmitteltechnologie und Spektros-

kopie, eine industrietaugliche Lösung hierfür zu erforschen und zunächst auf am Markt verfügbare Technik als Basis zurückzugreifen.

### 2.1.6.3 Zink-Protoporphyrin-Bildung als Indikator für die Alterung von Fleisch

Während des Alterungsprozesses von Fleisch finden verschiedene biologische, physikalische und chemische Prozesse statt. Durch die Verwendung spektralanalytischer Verfahren zur spezifischen Detektion charakteristischer Substanzen, deren stoffliche Veränderung im Zusammenhang mit der Fleischalterung stehen, kann indirekt eine Aussage über den Alterungszustand einer Probe getroffen werden.

Für Hackfleisch eignet sich die Detektion von Zink-Protoporphyrin. Protoporphyrin IX (PP) ist eine natürlich vorkommende Vorstufe von Häm, daher ist seine Bildung während des nach dem Tod eintretenden Häm-Abbaus wahrscheinlich. Aus der Literatur sind drei Hypothesen für die Bildung von Zink-Protoporphyrin in Fleisch bekannt, die je nach Anwendungsfall unterschiedlich diskutiert werden:

- Nicht enzymatische Chelatbildung von Zn (II) durch Protoporphyrin IX
- Enzymatisch induzierte Substitution von Fe (II) aus Häm mit Zn (II) durch endogene Ferrochelatase (FECH)
- Bakterieninduzierte enzymatische Reaktion

Protoporphyrin IX wird mit Eisen-II cheliiert, Protonen werden abgespalten, Häm b entsteht. Umgekehrt kann das Enzym Ferrochelatase (aus Bakterien oder der Fleischmatrix) auch die Entfernung des Metallions beim Abbau verschiedener Häme katalysieren. Unter anderem wird in der Literatur Schneider et al. 2008 A beschrieben, dass experimentell gezeigt werden konnte, dass die bakteriell induzierte ZnPP-Bildung (Hypothese 3) in ausreichender Menge stattfinden kann, wenn die Proteine der Matrix als „wässrige“ Fleischextrakte vorliegen. Stehen die Fleischproteine nur in fester Struktur und oberflächlich zur Verfügung, ist der Einfluss von Bakterien auf die Zn-PP Bildung gering. Die Zunahme an Zink-Protoporphyrin kann daher als Indikator für Alterungsprozesse herangezogen werden, welche sowohl durch fleischeigene Enzyme als auch exogene Bildung durch die vorhandenen Mikrobiota des Fleisches gebildet werden.

### 2.1.6.4 Tastversuche für den Misch- und Zerkleinerungsprozess

Eine besondere Herausforderung war es, dass zur Erhebung von möglichst weitreichenden Daten auch jene Maschinenzustände eingestellt werden sollten, welche gezielt einen n.i.o-Zustand im Endergebnis herstellen. Die Durchführung solcher Untersuchungen in einem realen Prozessumfeld bei einem Anwender ist denkbar ungünstig, da wenig Dynamik gewünscht ist und dort in der Regel kein Experimentierspielraum gegeben ist. Die Versuche wurden daher in einer Laborumgebung mit speziell für die Tastversuche hergestellten Rezepturen durchgeführt.

Die ersten Vorversuche mit realen Lebensmittelprodukten fanden in der Woche 37/2022 im Kundenforum (Laborumgebung) der Fa. Inotec/Handtmann statt. Dazu legte sich das Projektteam auf die Untersuchung der Herstellung von Würstchen auf Basis einer Rezeptur für Wiener Würstchen fest. Für deren Herstellung sind folgende übergeordnete Prozessschritte notwendig:

1. Zerkleinerung von Fleisch und Fett über einen Fleischwolf zu grobkörnigem Hackfleisch,
2. Vermischung des Hackfleischs mit Gewürzen und Eiswasser mittels Mischer,
3. Feinstzerkleinerung des Gemisches zu Brät durch einen Zerkleinerer,
4. Abfüllung des Bräts in Naturdärme (hier: Kunstdärme) mittels Füller und
5. Trocknung, Räuchern und Kochen erfolgt im Räucherofen.

Basierend auf den Vorversuchen und den erstellten Hypothesen in Bezug auf den Energieeintrag in Abhängigkeit der verwendeten Maschinen wurde durch das Projektteam für die Durchführung der Hauptversuche der Prozessschritt (2) für die Herstellung von Wiener Würstchen identifiziert. Hierbei

wird das Hackfleisch mit Gewürzen und Eiswasser mittels der Mischmaschine vermischt. Das eingebrachte Eiswasser soll das Gemisch während des Mischens auf einer konstanten Temperatur von  $-1\text{ }^{\circ}\text{C}$  halten. Bedingt durch die manuelle Beigabe der Gewürze und des Eiswassers vor dem Mischen sollte in den Hauptversuchen der Fokus auf den Maschinenparametern und deren Variationen liegen. Daher rückte die Mischmaschine für die Hauptversuche in den Fokus.

Als begleitende Messtechnik kamen die UV-VIS-Fluoreszenzspektroskopie und Nahinfrarotspektroskopie zum Einsatz, wie basierend auf einer Literaturrecherche in Erfahrung gebracht wurde (siehe Baakev 2010, Cobos et al. 2015). Mit beiden Messtechniken können ohne Probenvorbereitung, schnell, berührungs- und zerstörungsfrei Proben nahe dem Herstellungsprozess (at-line) untersucht werden.

### 2.1.6.5 Untersuchungen mittels UV-VIS-Fluoreszenzspektroskopie

Der Fokus der UV-VIS-Fluoreszenzspektroskopie liegt in den Tastversuchen auf der qualitativen und quantitativen Untersuchung der Fleischalterungsprozesse. Bei den Messungen der Fluoreszenz haben sich die Anregungswellenlängen von 280, 340 und 415 nm mit den Emissionsbereichen von 310 nm bis 450 nm, 430 nm bis 570 nm und 550 nm bis 740 nm als am aussagekräftigsten herausgestellt (vgl. Schneider et al. 2008 B). Bei einer Anregung mit einer Wellenlänge von 415 nm können während der Lagerung drei Fluoreszenzmaxima detektiert werden (Abbildung 53). Das erste gemessene Maximum liegt bei  $592 \pm 3\text{ nm}$ , das zweite bei  $636 \pm 2\text{ nm}$  und das dritte bei  $705 \pm 1\text{ nm}$ . Sie treten bei einer Lagerung des Fleisches bei  $4\text{ }^{\circ}\text{C}$  nach wenigen Tagen post mortem deutlich sichtbar auf.

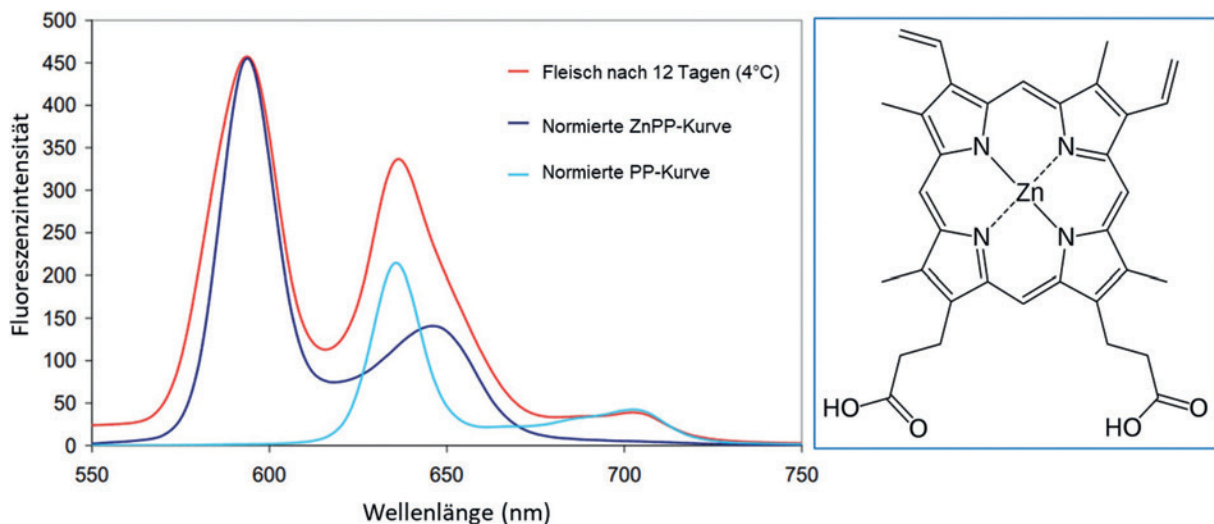


Abbildung 53: Fluoreszenzspektren ( $\lambda_{\text{exc}} = 415\text{ nm}$ ) über 12 Tage bei  $4\text{ }^{\circ}\text{C}$  Lagerungstemperatur von Proben aus Schweinefleisch (rot) und Lösungen von Protoporphyrin IX (dunkelblaue PP-Kurve) und Zink-Protoporphyryrin (hellblaue ZnPP-Kurve) normiert auf die Maximalhöhe bei  $592\text{ nm}$  des Spektrums. Rechts: Strukturformel von Zink-Protoporphyryrin (eigene Darstellung)

Die entstehenden Fluoreszenzmaxima können anhand von Modelllösungen auf die nativen und autofluoreszierenden Substanzen Protoporphyrin IX (PP) und Zink-Protoporphyryrin (ZnPP) zurückgeführt werden. Die Lösungen beider Stoffe zeigen je zwei Maxima, ZnPP bei etwa  $592\text{ nm}$  und  $644\text{ nm}$  und PP bei ca.  $634\text{ nm}$  und  $702\text{ nm}$ . PP ist eine natürlich vorkommende Vorstufe von Häm, daher ist seine Bildung während des nach dem Tod eintretenden Häm-Abbaus wahrscheinlich. Aus Literaturstudien ist bekannt, dass ZnPP vorwiegend durch Bakterien gebildet wird. Verschiedene Stämme von *Staphylococcus* konnten in fermentierten Würsten rote Myoglobin-Derivative bilden (vgl. Morita et al. 2006). Sehr frühe Arbeiten zeigen bereits den Abbau von Hämoglobin zu PP und anderen Porphyrinen durch Mischungen von Darmbakterienkulturen und Reinkulturen von z. B. *Escherichia coli* oder *Bacillus subtilis* (vgl. Kämmerer 1924). Bei Zink-Protoporphyryrin (ZnPP) wird anstelle eines zweiwertigen Eisen-Ions ( $\text{Fe}^{2+}$ ) ein zweiwertiges Zink-Ion ( $\text{Zn}^{2+}$ ) in Protoporphyrin IX eingebaut (Abbildung 53 rechts). Nach dem heutigen Stand der Wissenschaft können die genauen Bildungsmechanismen von PP und ZnPP in

frischem Fleisch bis jetzt noch nicht vollständig geklärt werden, aber es sind wahrscheinlich sowohl fleischinterne Prozesse als auch Mikroorganismen involviert.

Im Rahmen der in den Hauptversuchen durchgeführten Untersuchungen wurde deshalb vorwiegend der Bereich zwischen 570 nm bis 612 nm untersucht, da dieser im Zusammenhang mit Mikroorganismen und Alterungsprozessen die stärksten Fluoreszenzintensitäten aufzeigt.

### 2.1.6.6 Untersuchungen mittels Nahinfrarotspektroskopie

Der Fokus der Nahinfrarotspektroskopie lag im Rahmen der Tastversuche auf der Zuordnung und quantitativen Erfassung der Bestandteile der Proben. Es sollte herausgefunden werden, ob die eingestellten Maschinenparameter wie Drehzahl, Beladung und Mischzeit Einfluss auf das Spektralverhalten der Fleischproben über die Lagerungszeit haben. Für die Messung der Proben wurden die spektralen Daten nach dem *Pushbroom-Imaging* Prinzip aufgenommen (ElMasry et al. 2013, Barbin et al. 2013).

Die so ermittelten Spektren galt es räumlich aufzulösen, um eine Beurteilung der Mischqualität bzw. Homogenität durchführen zu können. Hierzu sollte später die Abhängigkeit der Homogenität und des Eiweißaufschlusses von den Mischer-Einstellungen bewertet werden können. Aufgrund der heterogenen Zusammensetzung der Proben zeigten die Spektralbilder unterschiedliche Areale mit Anteilen an Protein, Wasser und Fett. Die Spektren, die ermittelt wurden, waren im Wesentlichen die Schwingungen von kovalent gebundenen Wasserstoffatomen in Bindungen wie C-H, N-H und O-H. Bei der Nutzung der NIR-Absorptionsspektroskopie kann das Problem der Wasserabsorption zwar reduziert, jedoch nicht vollständig umgangen werden. Daher zeigten sich in den entsprechenden Spektren von Fleisch sehr ausgeprägte Signale des in hoher Konzentration im Fleisch vorkommenden Wassers. Durch die im Vergleich zur Fourier-Transform-Infrarotspektroskopie höhere Eindringtiefe in die Probe war hier auch eine Messung durch Verpackungen hindurch möglich, sofern diese für die Anregungsstrahlung hinreichend transparent waren (Grundvoraussetzung für die Lagerung der Proben). Die Einordnung der Proben erfolgte mittels der Partial-Least-Square (PLS) Methode als Regression anhand von Modellproben mit definiertem Fett- und Eiweißgehalt im Spektralbereich 1000 nm bis 1600 nm.

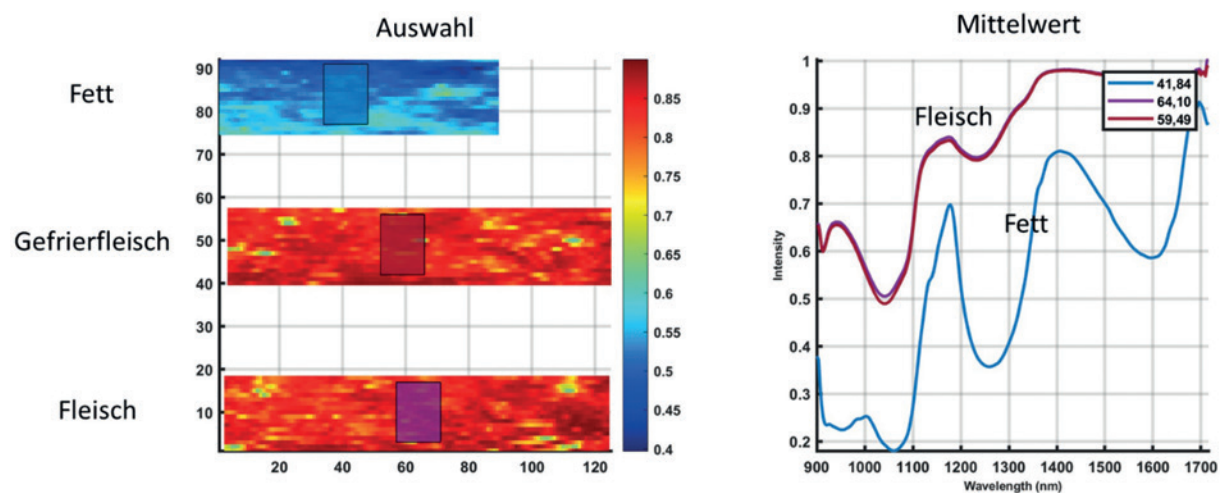


Abbildung 54: Spektralbilder für Fleisch, Gefrierfleisch und Fett sowie deren Mittelwertspektren aller Pixel im Auswertebereich (eigene Darstellung)

Die Unterschiede in der farblichen Zusammensetzung (Abbildung 54) resultierten aus der Heterogenität der Proben und den damit verbundenen Unterschieden in den Spektren mit hohem Fett oder Fleischanteilen. Die zu sehende Skala wurde mit Kalibrierungsproben eingestellt, die jeweils unterschiedliche Mengen der beiden Komponenten Fett und Fleisch enthielten. Das erhaltene Ergebnismodell zeigt somit ein relatives Verhältnis von Fett zu Fleisch und nicht die absolute Menge an Fett oder Fleisch. Die Modellgüte für eine PLS-Regression mit sieben Faktoren zeigt für die Messungen ein Bestimmtheitsmaß von 0,845. Basierend auf diesem Modell werden die Bestandteile der Spektren vorhergesagt.

### 2.1.6.7 Hauptversuche mit dem Fokus auf den Mischprozess

Für die Durchführung der Hauptversuche und für die Aufnahme der Maschinenparameter wurde durch das Projektteam erneut die bereits für die Datenerhebung vorbereitete Mischmaschine der Fa. Inotec/Handtmann vom Typ IVM150-V-DD-DM-N2 herangezogen. Die für die Hauptversuche relevanten Maschinenkomponenten, Messeinheiten und Produkte sind unter Abbildung 55 beschrieben:




Abbildung 55: Mischer vom Typ IVM150-V-DD-DM-N2 der Fa. Inotec/Handtmann mit den relevanten Maschinenkomponenten, Messeinheiten und Produkten zur Durchführung der Hauptversuche (1) Gehäuse, (2) Steuerungseinheit, (3) Mischraum, (4) Auslassschleuse, (5) Antriebseinheit/Motor Welle 1, (6) Antriebseinheit/Motor Welle 2, (7) Mischwellen, (8) Temperatursensor 1 und Temperatursensor 2, (9) Rückenspeck, (10) Schweineschulter frisch, (11) Schweineschulter gefroren (Quelle: Inotec/Handtmann)

#### 2.1.6.7.1 Beschreibung des Versuchsablaufs

Basierend auf den Erfahrungen der Vorversuche erstellte das Projektteam vorab für die Hauptversuche einen optimierten Versuchsablaufplan. Im Versuchsablaufplan wurden die einzelnen Durchläufe in zeitlicher Abfolge, die Zeitpunkte der Probenentnahme und die durchzuführenden und anschließenden Lagertests aufgeführt. Diese Hauptversuche fanden in KW 4/2023 sowie die Lagertests in den zwei darauffolgenden Wochen statt. Die gewählte Rezeptur bildete ein Schweinehackfleisch mit dem Zielfettgehalt 25 Prozent ab. Der Fleischanteil kam aus der Schweineschulter, wovon 80 Prozent am Vortag auf -4 °C gefrostet wurden, 20 Prozent wurden am Versuchstag als Frischfleisch hinzugegeben. Der Rückenspeck wurde mit einer Temperatur von -4 °C gefroren eingebracht. Das Produkt wurde zunächst vorgewolft auf 13 mm Körnung. Vor der Erstbefüllung wurde der Mischer zum Herunterkühlen mit Scherbeneis betrieben. Anschließend wurde das Eis entleert und der Mischer trocken gerieben. Die Reihenfolge der Zugabe erfolgte bei jedem Durchlauf gleich:

1. Magerfleisch, gefrostet
2. Magerfleisch, frisch
3. Rückenspeck.

Die Hauptversuche wurden anhand von zwölf Teilversuchen (Durchläufen) mit den unterschiedlichen Mischparametern durchgeführt. Die Mischparameter wurden anhand deren Beladung, Mischdauer, Drehzahlen der Mischwellen und Intervalldauer (= Mischstrategie) variiert. Die Beladung wurde dabei auf entweder 120 kg (entspricht 100 Prozent Beladung) und 60 kg (entspricht 50 Prozent Beladung)

eingestellt, was gleichzeitig der empirisch bekannten Mindestbeladung entspricht. Die Mischintervalle wurden auf 30 s und 120 s definiert, bevor jeweils die Laufrichtung der Wellen geändert wurde. Als Pausenzeit zwischen den Intervallen wurden 5 s eingestellt, um die Mischwellen vollständig zur Ruhe kommen zu lassen. Die Drehzahl während des Mischprozesses lag zwischen 4 und 14 Umdrehungen pro Minute (rpm) für die äußere, große Mischwelle. Die Drehzahl der inneren Mischwelle war dementsprechend die doppelte der äußeren. Für jeden Durchlauf wurden die gleichen Mischzeiten bei den Zeitintervallen von ein, zwei, vier, sechs, zehn und sechzehn Minuten eingestellt. Die Probenentnahme fand während der zwölf Durchläufe statt. Dabei wurden je Durchlauf sechs Proben in den Pausenzeiten zwischen den Intervallen entnommen. Pro Probe wurden ca. 200 g Fleisch aus dem Mischraum entnommen und in einem Kunststoffbeutel vakuumverpackt. Insgesamt konnten die Proben aus 11 von 12 Durchläufen verwertet werden. Pro Durchlauf wurden je 33 Proben hergestellt. Bei Lauf 4 gab es nur 30 Proben, sodass insgesamt 360 Proben innerhalb der zwei Tage hergestellt wurden.




Abbildung 56: Verpackte Proben und Messaufbau für die at-line Spektroskopie (eigene Darstellung)

Begleitend zu den Versuchen wurden zwei spektroskopische Methoden direkt am Versuchsaufbau eingesetzt (Abbildung 56: Verpackte Proben und Messaufbau für die at-line Spektroskopie). Zum einen wurde die Fluoreszenzspektroskopie mit den Anregungswellenlängen 280 nm, 340 nm und 415 nm verwendet, zum anderen kam die Nahinfrarotspektroskopie im Wellenlängenbereich zwischen 1000 nm und 1700 nm zum Einsatz.

Bei der Fluoreszenzspektroskopie ergaben sich aus den 360 Proben über eine Messzeit von 14 Tagen mit drei Anregungswellenlängen von 280 nm, 340 nm und 415 nm insgesamt 226.800 Spektren, die aufgenommen wurden.

Mit der Nahinfrarotspektroskopie wurden für die 360 Proben innerhalb von 14 Messtagen mehr als 11,5 Mio. Spektren aufgenommen und ausgewertet. Damit wurde gewährleistet, dass die Heterogenität der Probe basierend auf den Maschinenparametern vollständig erfasst wird.

Aufgrund der hohen Spektranzahl und verschiedenen Datenquellen musste eine geeignete Software in Matlab programmiert werden, die eine systematische Auswahl, Datenvorverarbeitung und Auswertung nach Durchlauf, Mischzeit und Strategie, Drehzahl sowie Intensitäten und spektralen Eigenschaften zulässt.

### 2.1.6.7.2 Auswertung der Fluoreszenz-Spektraldaten

Bezüglich der Veränderungen der Maschinenparameter wie der Mischzeit bei gleicher Beladung und Drehzahl wurde nun versucht, die unterschiedlichen Intensitäten mit der Mischzeit zu korrelieren. Für die Darstellung der Varianzen in den Spektren wurde die Hauptkomponentenanalyse (Principal Component Analysis, PCA) verwendet. Abbildung 57 zeigt den Score-Plot von PC1 und PC2 für Lauf 1 Tag 1 aller Mischzeiten im Spektralbereich 380 nm bis 612 nm. Auffällig war, dass zu Beginn der verschiedenen Mischzeiten zwischen 1 min und 6 min die Score-Werte sehr weit streuten und keiner eindeutigen Gruppe zuzuordnen waren. Erst bei den Mischzeiten 10 min und 16 min wurde deutlich, dass die Score-Werte dichter zusammenliegen. Dies repräsentierte die Ähnlichkeit der Spektren zueinander und bedeutete, dass die Spektren ab 10 min Mischzeit sich von den Spektren der Mischzeit von 16 min nicht mehr messbar unterschieden. Damit konnte ausgesagt werden, dass mit den eingestellten Maschinenparametern eine Homogenität bereits nach 10 min erreicht war. Die Anregungswellenlänge eignete sich daher auch für eine qualitative Aussage über die Heterogenität bzw. Homogenität einer Probe.

Die Lagertests und deren Analysen wurden ab dem zweiten Tag der Entnahme, also am 26.01.2023, für die ersten sechs Teilversuche und am 27.01.2023 für die weiteren fünf Teilversuche durchgeführt. Die Lagertests wiederholten sich am dritten, am sechsten, am neunten, am elften, am dreizehnten und am fünfzehnten Tag nach der jeweiligen Entnahme der Proben.

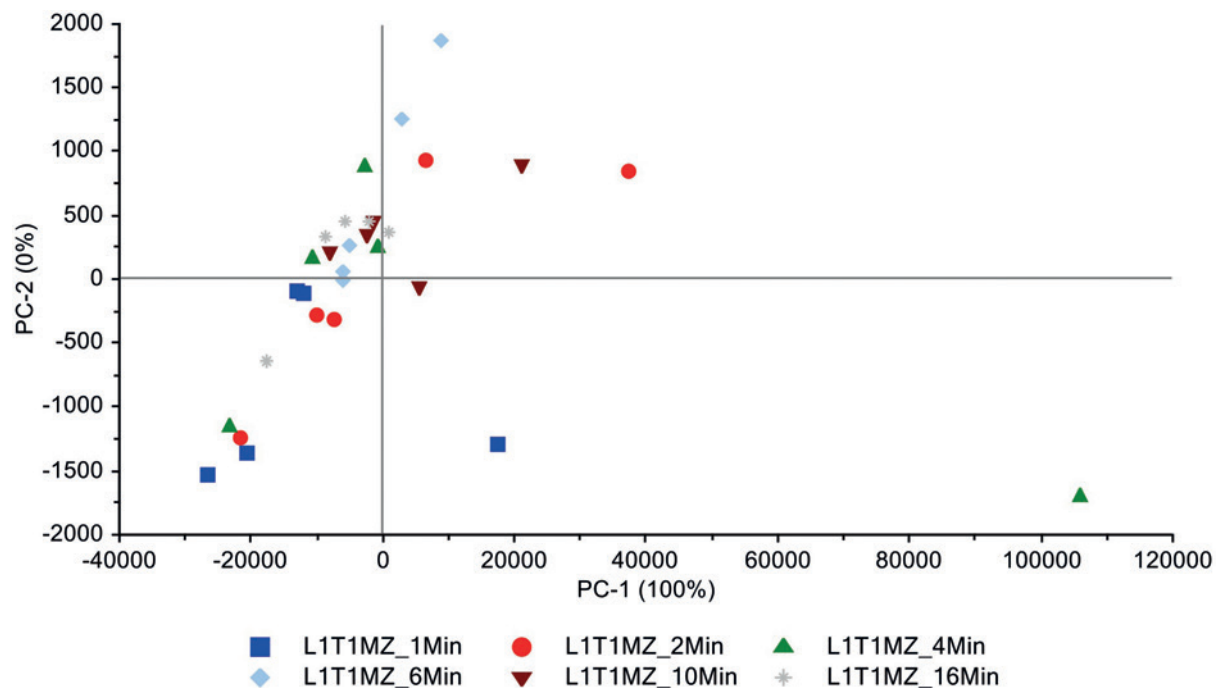


Abbildung 57: Score-Plot der Hauptkomponentenanalyse für Lauf 1 Tag 1 für alle Mischzeiten im Spektralbereich 380 nm bis 612 nm (eigene Darstellung)

Abbildung 58 zeigt den Emissionsbereich für die Tage 1 bis 14 für Lauf 7 bei einer gleichbleibenden Mischzeit von 16 min. Die Auswertungen zeigen hierbei eine deutliche Änderung der Intensität bei 590 nm über die Messtage. Über die Lagerungszeit finden Alterungsprozesse und Bakterienansiedlungen im Fleisch statt, die einen Einfluss auf das Spektrum haben. Die Messung der Fluoreszenzstrahlung lässt einen Rückschluss auf den Frischezustand des Fleisches zu. Bei den nachfolgenden Auswertungen wird hierzu dieses charakteristische Wellenlängenspektrum berücksichtigt, welches vorwiegend vom Zn-PP emittiert wird.

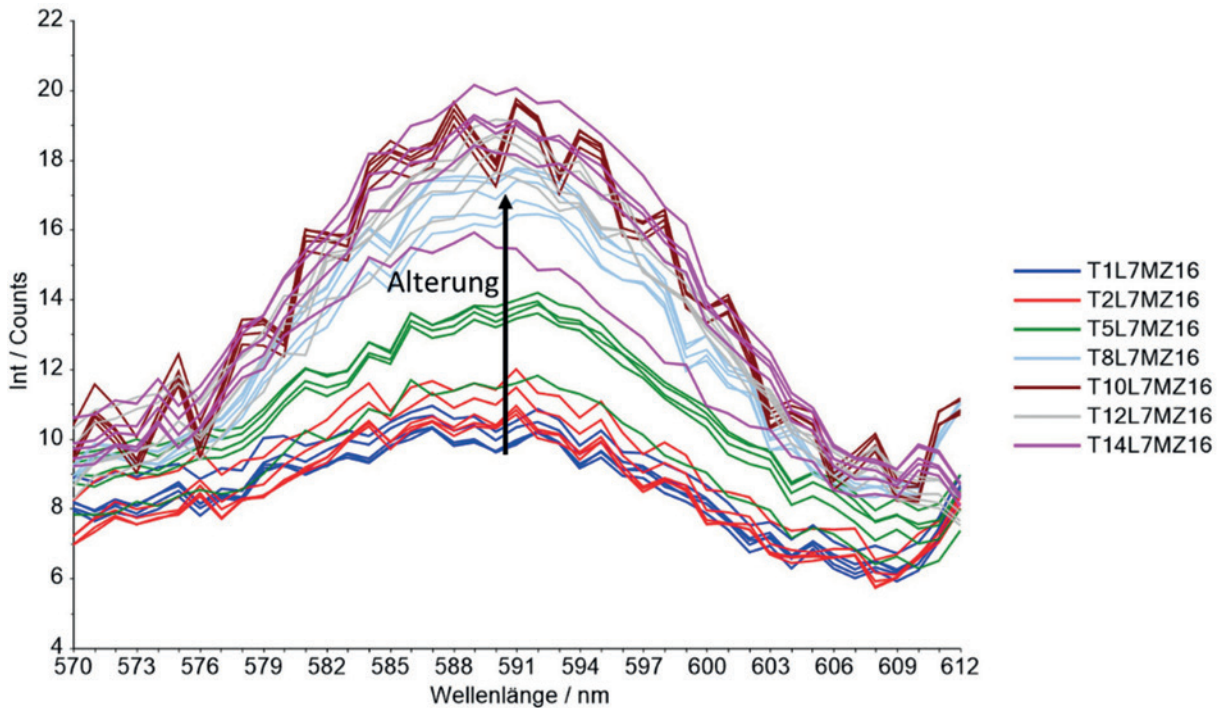


Abbildung 58: Emissionsspektren der Anregungswellenlängen bei 415 nm. Gezeigt sind Spektren von Lauf 7 über die gesamte Messdauer von Tag 1 bis Tag 14 bei einer definierten Mischzeit von 16 min (eigene Darstellung)

Das Modell zeigt eine sehr gute Vorhersage für die unterschiedlichen Tage (Abbildung 59). Als Fehlerkennzahl wurde die Wurzel des mittleren quadratischen Fehlers (Root Mean Squared Error, RMSE) verwendet. Das Modell kann die Lagerungszeit der Fleischproben auf ca. 1,5 Tage (36 Stunden) genau vorhersagen. Für einzelne Durchläufe kann diese sogar auf 0,8 Tage (19,2 Stunden) genau vorhergesagt werden.




Abbildung 59: Partial-Least-Square-Regression für Lauf 7 Mischzeit 1 min, alle Tage 570 nm bis 612 nm Alterung (eigene Darstellung)



Die Einflüsse der verschiedenen Maschinenparameter beeinflussen auch das spektrale Verhalten je Einstellung. Dies kann mit einem höheren und niedrigeren Energieeintrag der Maschinenparameter begründet werden. Proben, die einen höheren Energieeintrag erfahren haben, zeigen auch durchschnittlich höhere Fluoreszenzintensitäten auf. Dies zeigt sich im PCA-Verlauf (Abbildung 60) sehr gut. Vermutlich resultiert aus einem höheren Energieeintrag eine schnellere Alterung sowie vermehrte bakterielle Umsetzung von Häm-Fe(II) zu Häm-Zn und damit Zn-PP.

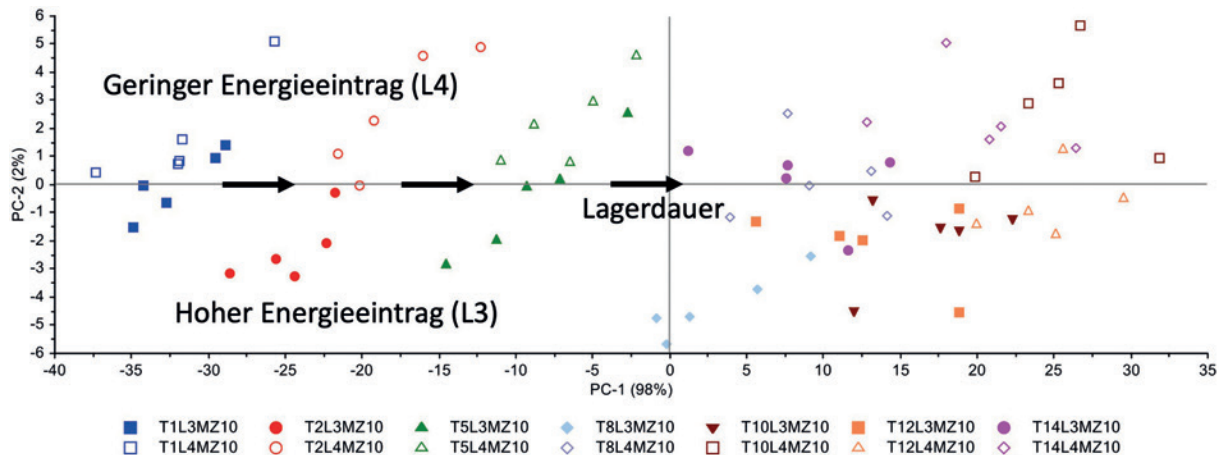


Abbildung 60: PCA Lauf 3 gegen Lauf 4, Mischzeit 10 min, Emissionsbereich 570 nm bis 612 nm (eigene Darstellung)

Es ist davon auszugehen, dass durch den höheren Energieeintrag mehr Proteine über die Lagerzeit gelöst werden. Dies geht mit einer vermehrten Zn-PP Bildung und damit höherer Fluoreszenz einher.

Unterschiedliche Mikroorganismen haben unterschiedliche Stoffwechselprozesse. Die Zunahme in der Zn-PP Bildung lässt daher nur indirekt auf die Anzahl koloniebildender Einheiten (KBE) schließen, da die Bildung von der Zusammensetzung der Fleischmikrobiota abhängt. Sie steht somit in keinem direkten Zusammenhang zur Zn-PP Bildung. Die Korrelation der Spektren mit der KBE-Zahl ist daher nur mit einem hohen Fehler möglich. Ein möglicher Grund für den hohen Vorhersagefehler liegt zusätzlich daran, dass während der Probennahme und Messung regelbasierte Fehler auftraten, die systematische Fehler verursachen können. Aufgrund der komplexen Prozesskette treten auch zufällige Fehler auf, die Einfluss auf die Präzision haben. Weiterhin sind nicht alle veränderten Maschinenparameter im Modell berücksichtigt. Dadurch kommt es auch zu Abweichungen in der Vorhersage. Die Vorhersagequalität entspricht nicht den Anforderungen der Praxis, da der Fehler größer ist als der kritische Warnwert für KBE/g in Hackfleisch.

### 2.1.6.7.3 Auswertung der Nahinfrarot-Spektraldaten

Die gemessenen Proben waren sehr heterogen in der Zusammensetzung. Daher war eine ortsauflöste Methode zur Auswertung der Spektren sinnvoll. Um eine anschauliche Aussage über den Einfluss der Maschinenparameter bezüglich des Fett- und Eiweißgehaltes zu bekommen (Abbildung 61 oben links), wurde nach einer neuen Auswertemöglichkeit gesucht, die einfache Aussagen über die gesamten Spektraldaten zulässt.

Dazu wurde jeder Wert der Vorhersage als grafische Darstellung der Häufigkeitsverteilung als skaliertes Merkmal in einem Histogramm dargestellt (Abbildung 61 oben rechts). Die Einteilung der Daten erfolgte dabei in Klassen mit konstanter Breite. Die Daten wurden zuvor flächennormiert. Um zu einer übersichtlichen Darstellung zu gelangen, wurden die Rechtecke der Klassen in Linien umgewandelt (Abbildung 61 unten links). Zu sehen sind Unterschiede in den Counts sowie der Verteilung in den vorhergesagten Werten. Rechts daneben finden sich die Loadings für die Faktoren 1 und 2 des Modells.

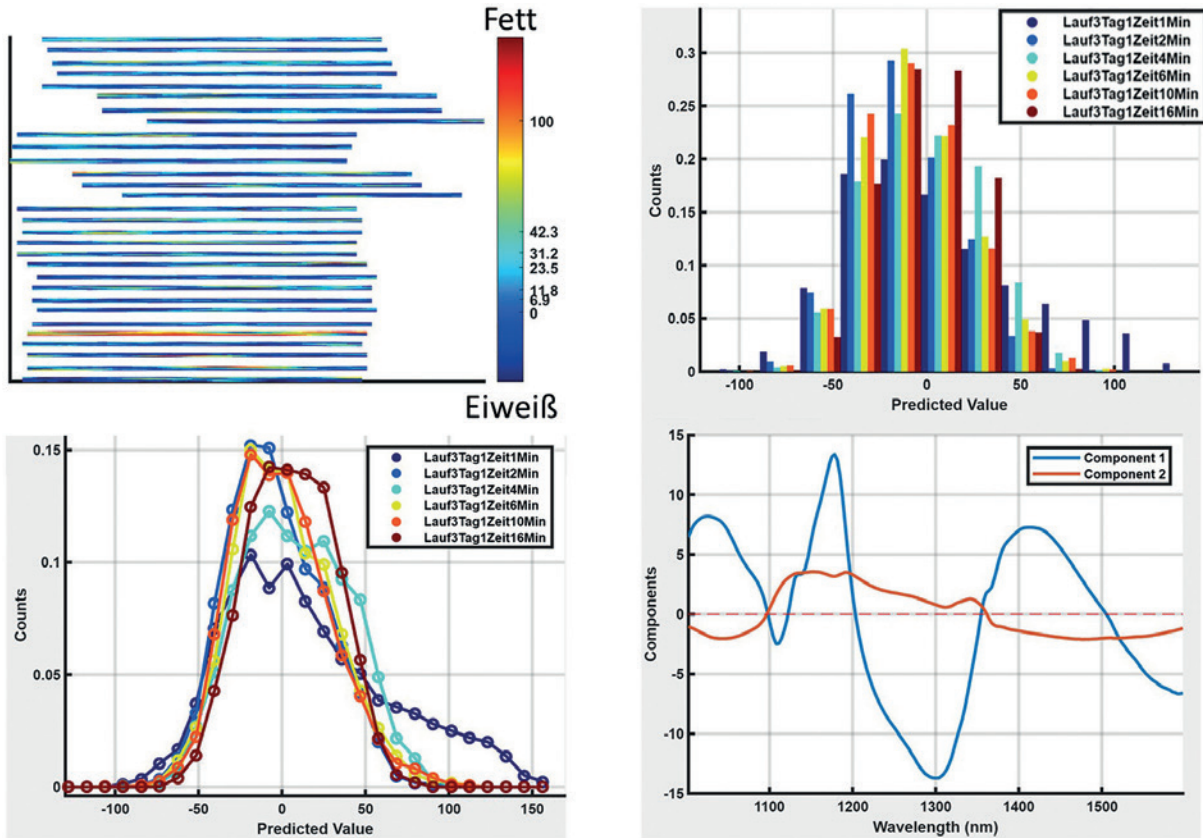


Abbildung 61: Auswertung der Hyperspektraldaten mit Vorhersage und Histogramm-Darstellung (eigene Darstellung)

Abbildung 62 zeigt beispielhaft die Auswertung für Lauf 3 nach der neuen Histogramm-Methode für die Tage 1 bis 14. Dieser Lauf steht exemplarisch für einen Mischvorgang mit hohem Energieeintrag. Hier sind Veränderungen in Abhängigkeit der Mischzeiten erkennbar. Zu sehen ist die Durchmischung von 1 min bis 16 min. Die Entwicklung der Alterung kann entlang der Diagramme verfolgt werden. Bis zu diesem Punkt werden alle Proben mit der Zeit immer homogener, was durch die im Laufe der Zeit stattfindenden Alterungsprozesse und auftretenden Eiweißaufschlüsse erklärt werden könnte. Ausschlaggebend hierfür ist die Abnahme der Halbwertsbreite (*full width at half maximum, FWHM*) der einzelnen Peaks.

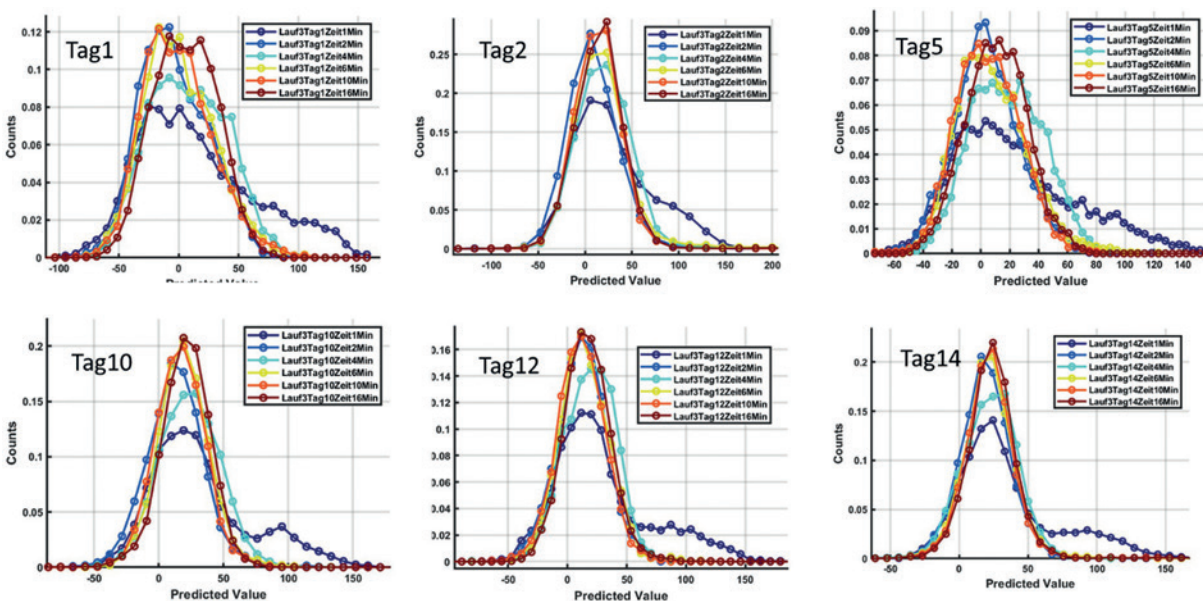


Abbildung 62: Auswertung von Lauf 3 nach der Histogramm-Methode für die Tage 1 bis 14 (eigene Darstellung)

In Abbildung 63 sieht man die Auswertung für Lauf 4 nach der Histogramm-Methode für die Tage 1 bis 14. Im Gegensatz zu Lauf 3 sollte Lauf 4 einen geringeren Energieeintrag durch den Mischvorgang besitzen. Hier ist es nicht direkt möglich abzuschätzen, wann die optimale Durchmischung erreicht ist, da alle Histogramm-Profile im Zeitverlauf sehr ähnlich aussehen. Auch Unterschiede in der Alterung lassen sich mit der Zeit nicht verfolgen, was, wie auch zu erwarten, darauf hindeutet, dass bei minimalem Energieeintrag die Mischzeit eine weit weniger bedeutende Rolle spielt. Und alle Proben entwickeln sich im Laufe der Zeit konstant, obwohl der Eiweißaufschluss ebenfalls stattfindet und die Proben homogener werden.

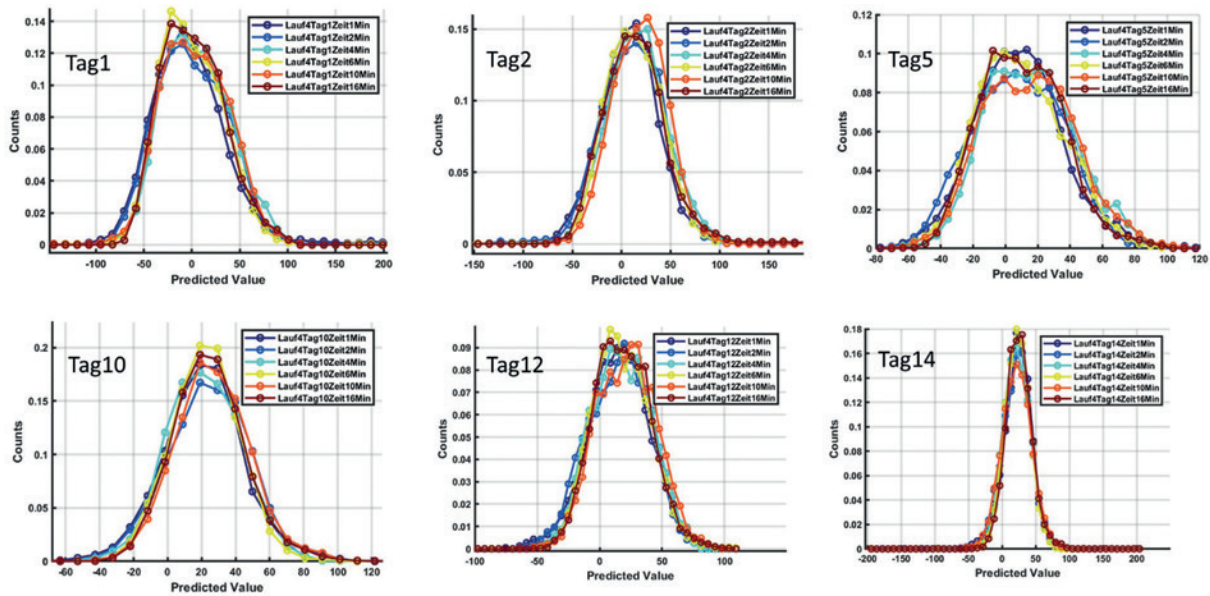


Abbildung 63: Auswertung von Lauf 4 nach der Histogramm-Methode für die Tage 1 bis 14 (eigene Darstellung)

#### 2.1.6.7.4 Auswertung der Maschinendaten

Im Folgenden werden die Ergebnisse der Maschinenparameter und deren Abhängigkeiten zueinander während der Durchführung der Hauptversuche beschrieben.

Es wurden die eingestellten und tatsächlichen Maschinenparameter von der Maschine in einem Log-File aufgezeichnet. Folgende Maschinenparameter wurden mit einer Abtastrate von einer Sekunde aufgezeichnet:

- |  |                                  |
|--|----------------------------------|
| 1. Zeit                                | 10. Drehzahl Motor 2 tatsächlich |
| 2. ERP-Nummer                          | 11. aufgenommener Strom Motor 2  |
| 3. Teilversuchsnummer (DataRecordName) | 12. Drehmoment Motor 2           |
| 4. Drehzahl Motor 1 eingestellt        | 13. Motorleistung Motor 2        |
| 5. Drehzahl Motor 1 tatsächlich        | 14. Masse der Beladung           |
| 6. aufgenommener Strom Motor 1         | 15. Temperatur Sensor 1          |
| 7. Drehmoment Motor 1                  | 16. Temperatur Sensor 2          |
| 8. Motorleistung Motor 1               | 17. Temperatur gemittelt         |
| 9. Drehzahl Motor 2 eingestellt        | aus Sensor 1 und Sensor 2        |

Für die Analyse der Daten und die Untersuchungen der Maschinenparameter auf deren Korrelationen wurden die Log-Files als csv-Dateien aus der Maschine geladen und abgespeichert.

Für die Analyse und Weiterverarbeitung der Daten orientierte sich das Projektteam an dem etablierten Vorgehen des Knowledge Discovery in Databases (KDD) nach Fayyad et al. 1996. Der KDD-Prozess ermöglicht, basierend auf Maschinendaten, Wissen und somit Korrelationen zu generieren. Der KDD-Prozess ist in folgende sechs Stufen unterteilt:

1. Rohdaten generieren

2. Zieldaten selektieren
3. bereinigte Daten generieren
4. transformierte Daten erzeugen
5. Clusterung und Interpretation der Daten
6. Extraktion und Evaluation von Wissen.

Basierend auf dem KDD-Prozess wurden im ersten Schritt die (1.) Rohdaten als csv-Datei generiert, die (2.) Zieldaten der Hauptversuche in Excel identifiziert und die (3.) bereinigten Daten in Excel abgeleitet und generiert. Ein Auszug der bereinigten Daten für Motor 1 ist Abbildung 64 zu entnehmen.

Time	EPP-Number	DataRecordName	MHL_N_Setup	MHL_N_Act	MHL_N_Act_Nom_ABS	MHL_L_Act_A	MHL_L_Act_Nm	MHL_P_Act_Nom_ABS	Flaschenberechnung_X	Fläche	Total_Fläche	SD	MHL_P_Act_Liv	MHL_P_Act_ABS	Flaschenberechnung_X	Fläche	Total_Fläche	
24.01.2023 09:18:02.000	DL 1	Test5	4,00	0,00	0,00	2,80	4,97	0,00	1,00	6,08	0,18	0,18	1,00	0,00	1,00	0,23	2,00	0,26
24.01.2023 09:18:03.000	DL 1	Test5	4,00	3,00	3,00	4,80	-4,78	7,18	2,00	6,30	0,27	0,27	2,00	0,27	2,00	0,26	2,00	0,26
24.01.2023 09:18:04.000	DL 1	Test5	4,00	4,00	4,00	4,80	-7,18	6,81	3,00	6,82	0,24	0,24	3,00	0,25	3,00	0,25	3,00	0,25
24.01.2023 09:18:05.000	DL 1	Test5	4,00	4,00	4,00	4,80	-6,81	6,83	4,00	7,14	0,25	0,25	4,00	0,25	4,00	0,27	4,00	0,27
24.01.2023 09:18:06.000	DL 1	Test5	4,00	4,00	4,00	4,80	-7,64	7,64	5,00	6,72	0,28	0,28	5,00	0,28	5,00	0,28	5,00	0,28
24.01.2023 09:18:07.000	DL 1	Test5	4,00	4,00	4,00	4,80	-5,80	5,80	6,00	6,01	0,23	0,23	6,00	0,22	6,00	0,22	6,00	0,22
24.01.2023 09:18:08.000	DL 1	Test5	4,00	4,00	4,00	4,80	-6,21	6,21	7,00	5,85	0,23	0,23	7,00	0,22	7,00	0,22	7,00	0,22
24.01.2023 09:18:09.000	DL 1	Test5	4,00	4,00	4,00	4,80	-5,48	5,48	8,00	5,85	0,20	0,20	8,00	0,21	8,00	0,21	8,00	0,21
24.01.2023 09:18:10.000	DL 1	Test5	4,00	4,00	4,00	4,80	-5,81	5,81	9,00	6,36	0,21	0,21	9,00	0,23	9,00	0,23	9,00	0,23
24.01.2023 09:18:11.000	DL 1	Test5	4,00	4,00	4,00	4,80	-6,54	6,54	10,00	6,50	0,24	0,24	10,00	0,24	10,00	0,24	10,00	0,24
24.01.2023 09:18:12.000	DL 1	Test5	4,00	4,00	4,00	4,80	-6,45	6,45	11,00	7,08	0,24	0,24	11,00	0,27	11,00	0,27	11,00	0,27
24.01.2023 09:18:13.000	DL 1	Test5	4,00	4,00	4,00	4,80	-7,71	7,71	12,00	7,02	0,29	0,29	12,00	0,29	12,00	0,29	12,00	0,29
24.01.2023 09:18:14.000	DL 1	Test5	4,00	4,00	4,00	4,80	-6,32	6,32	13,00	6,37	0,23	0,23	13,00	0,24	13,00	0,24	13,00	0,24
24.01.2023 09:18:15.000	DL 1	Test5	4,00	4,00	4,00	4,80	-6,41	6,41	14,00	6,50	0,24	0,24	14,00	0,24	14,00	0,24	14,00	0,24
24.01.2023 09:18:16.000	DL 1	Test5	4,00	4,00	4,00	4,80	-6,59	6,59	15,00	6,25	0,24	0,24	15,00	0,23	15,00	0,23	15,00	0,23
24.01.2023 09:18:17.000	DL 1	Test5	4,00	4,00	4,00	4,80	-5,38	5,38	16,00	6,38	0,22	0,22	16,00	0,24	16,00	0,24	16,00	0,24
24.01.2023 09:18:18.000	DL 1	Test5	4,00	4,00	4,00	4,80	-6,85	6,85	17,00	6,50	0,25	0,25	17,00	0,25	17,00	0,24	17,00	0,24
24.01.2023 09:18:19.000	DL 1	Test5	4,00	4,00	4,00	4,80	-6,15	6,15	18,00	6,88	0,23	0,23	18,00	0,26	18,00	0,26	18,00	0,26
24.01.2023 09:18:20.000	DL 1	Test5	4,00	4,00	4,00	4,80	-7,60	7,60	19,00	7,73	0,28	0,28	19,00	0,28	19,00	0,28	19,00	0,28
24.01.2023 09:18:21.000	DL 1	Test5	4,00	4,00	4,00	4,80	-7,86	7,86	20,00	7,33	0,29	0,29	20,00	0,27	20,00	0,27	20,00	0,27
24.01.2023 09:18:22.000	DL 1	Test5	4,00	4,00	4,00	4,80	-6,74	6,74	21,00	7,83	0,24	0,24	21,00	0,26	21,00	0,26	21,00	0,26

Abbildung 64: Manuell bereinigte Daten der Mischmaschine in Microsoft Excel zur Weiterverarbeitung nach dem KDD-Prozess (eigene Darstellung)

Im zweiten Schritt wurden basierend auf dem KDD-Prozess die (4.) transformierten Daten erzeugt und (5.) die Daten geclustert und interpretiert. Im Folgenden werden die ersten sechs Teilversuche anhand deren verschiedenen Maschinenparameter dargestellt. Die Darstellung erfolgt grafisch und zusammenfassend anhand übersichtlicher Ergebniscockpits. Innerhalb der Ergebniscockpits zeigen die y-Achsen der Grafen die Messpunkte entlang der Zeitstempel auf der x-Achse der Grafen. Darauf aufbauend erfolgt je Ergebniscockpit die Interpretation der Ergebnisse.




Abbildung 65: Versuchscockpit 1: Drehzahl Motor 1 (blaue Linie) in Abhängigkeit der Beladung des Mixers (orange Linie) (eigene Darstellung)

Der durchgeführte Versuchsablauf mit den Mischintervallen und Probenentnahmen wird in Abbildung 65 ersichtlich. Dabei spiegelt die blaue Linie die Wellen-Drehzahl an Welle 1 wider. Die orange Linie gibt Aufschluss über die gemessene Beladung, welche messtechnischen Schwankungen unterliegt. Diese wird für die weitere Untersuchung geglättet, zeigt aber einen abnehmenden Trend auf, der als Bezug zur Probenentnahme erklärbar ist.

Die erzielte Homogenität soll anhand der Schwankungen des Energieeintrags, gemessen am Variationskoeffizienten (Standardabweichung geteilt durch den Mittelwert) der jeweiligen Mischintervalle, bewertet werden. Außerdem wird für jedes Mischintervall der kumulierte, mechanische Energieeintrag festgehalten, der auf die jeweilige entnommene Probe wirksam war. Der Energieeintrag wird berechnet aus der mechanisch eingetragenen Wellenleistung über beide Mischwellen, als Produkt aus Drehmoment und Drehzahl. Dadurch, dass die Beladung des Mixers über den Versuchsverlauf reduziert wurde, wird auf diese standardisiert. Zur übersichtlichen Darstellung wurde hierfür eine Korrelationstabelle erstellt, welche die gemessenen Spektralinformationen und die Maschinendaten in Übereinstimmung bringt und die Zusammenhänge aufdecken soll.

### 2.1.6.7.5 Fazit

Diese Zusammenhänge müssen noch näher untersucht und Ableitungen getroffen werden. Die Ergebnisse dieser Untersuchung bzw. die Korrelationen der Maschinendaten, NIR-Spektroskopie-Daten sowie Fluoreszenz-Spektroskopie-Daten können in ein KI-Modell überführt und zum Vorschlag von geeigneten Mischparametern verwendet werden. Die Ergebnisse der fluoreszenz-spektroskopischen Untersuchung können insbesondere zur Bestimmung des Alterungszustandes von Fleischproben genutzt werden. Dies ist interessant im Nachfolgeprozess nach erfolgtem Transport und Lagerung, bei der Qualitätseingangsprüfung z. B. in Supermärkten, an der Ladentheke oder gar beim Konsumenten.

## Literatur

- Bakeev, K. A. (Ed.) (2010). *Process analytical technology: Spectroscopic tools and implementation strategies for the chemical and pharmaceutical industries*. (2nd ed.). Chichester, West Sussex: Wiley.
- Barbin, D. F.; ElMasry, G.; Sun, D.-W. & Allen, P. (2013). Non-destructive determination of chemical composition in intact and minced pork using near-infrared hyperspectral imaging. *Food chemistry*, 138, S. 1162–1171.
- Berger, Lisa M., Franziska Witte, Nino Terjung, Jochen Weiss and Monika Gibis. Influence of Processing Steps on Structural, Functional, and Quality Properties of Beef Hamburgers. *Applied Sciences* 12, no. 15 (July 22, 2022): S. 7377.
- Casaburi, A.; Piombino, P.; Nychas, G.-J.; Villani, F.; Ercolini, D.: Bacterial populations and the volatile associated to meat spoilage, *Food Microbiology*. Volume 45, Part A, S. 83–102.
- Cobos, Á. & Díaz, O. (2015). Chemical Composition of Meat and Meat Products. In P. C. K. Cheung & B. M. Mehta (Eds.), *Handbook of Food Chemistry* (pp. 471–510). Berlin, Heidelberg: Springer Berlin Heidelberg.
- ElMasry, G.; Sun, D.-W. & Allen, P. (2013). Chemical-free assessment and mapping of major constituents in beef using hyperspectral imaging. *Journal of Food Engineering*, 117, S. 235–246.
- Fayyad, U.; Piatetsky-Shapiro, G.; Smyth, P. (1996). The KDD process for extracting useful knowledge from volumes of data. *Communications of the ACM*, Volume 39, Issue 1101, S. 27–34.
- Inotec/Handtmann (2023), *Mischer vom Typ IVM150-V-DD-DM-N2* (Abbildung 55)
- Kämmerer, H. (1924). Über das durch Darmbakterien gebildete Porphyrin und die Bedeutung der Porphyrinprobe für die Beurteilung der Darmfäulnis. *Deutsches Archiv für klinische Medizin* 145, S. 257–284.
- Morita, H.; Niu, J.; Sakata, R. & Nagata, Y. (1996). Red pigment of Parma ham and bacterial influence on its formation. *Journal of Food Science* 61, S. 1021–1023.
- Nychas, G.-J. E.; Skandamis, P. N.; Tassou, C. C.; Koutsoumanis, K. P.: Meat spoilage during distribution, *Meat Science*, Volume 78, Issues 1–2, S. 77–89.
- Schneider, J.; Wulf, J.; Surowsky, B.; Schmidt, H.; Schwägele, F.; Schlüter, O. (2008). Fluorimetric detection of protoporphyrins as an indicator for quality monitoring of fresh intact pork meat. *Meat Science*, 80, S. 1320–1325.
- Schneider, J. et al. (2008) *Mitteilungsblatt der Fleischforschung Kulmbach* 47, Nr. 181, S. 139–144.

## 2.1.7 Teilprojekt VII – Rückverfolgbarkeit

Kaufmann, Klaus (GS1 Germany GmbH)

Aktive Partner: **GS1 Germany GmbH**, Arxum GmbH, BayWa AG, tegut... GmbH & Co. KG, Westfleisch SCE mbH

Assoziierte Partner: -

### 2.1.7.1 AP VII.1 Analyse der Ist-Situation der Lieferkettenprozesse

Das Arbeitspaket hatte zum Ziel, eine Übersicht der Gemeinsamkeiten und Besonderheiten im Lieferprozess zwischen den verschiedenen Branchen herauszuarbeiten. Es wurde im Projektjahr eins abgeschlossen.

Zum Auftakt wurden allgemeine Informationen und Trends in den unterschiedlichen Branchen umfangreich gesichtet. Hierbei wurden Erkenntnisse von AP I.4 miteinbezogen. Darauf aufbauend wurden die bestehenden Lieferprozesse sowie deren Teilnehmenden in den unterschiedlichen Lebensmittelsektoren mit den Partnern analysiert und die bestehenden Verfahren zur Rückverfolgbarkeit von Lebensmitteln identifiziert und aufbereitet.

### 2.1.7.2 AP VII.2 Definition spezifischer Soll-Prozesse

Für dieses AP wurden allgemeine Informationen und Trends in den unterschiedlichen Branchen umfangreich gesichtet. Hierbei wurden Erkenntnisse von AP I.4 miteinbezogen. Darauf aufbauend wurden die bestehenden Lieferprozesse sowie deren Teilnehmenden in den unterschiedlichen Lebensmittelsektoren mit den Partnern analysiert und die bestehenden Verfahren zur Rückverfolgbarkeit von Lebensmitteln identifiziert und aufbereitet.

Auf Basis verschiedener Expertendiskussionen erfolgte die Aufnahme und Moderation von beiderseitigen Anforderungen zum Lieferprozess zwischen Industrie und Handel mit dem Ziel, eine Übersicht der Anforderungen der unterschiedlichen Marktteilnehmenden zu erhalten.

### 2.1.7.3 AP VII.3 Konzeptionierung der elektronischen End-to-End-Rückverfolgbarkeit

Basis für dieses AP ist ein Überblick über die funktionellen Anforderungen der Traceability-Systeme bezüglich der jeweiligen Marktteilnehmenden. Hierfür erfolgte die Ermittlung funktionaler Anforderungen der unterschiedlichen Marktteilnehmenden zur Rückverfolgbarkeit. Als Ergebnis steht ein Dokument zu funktionalen und nicht funktionalen Anforderungen an ein Traceability-System. Dieses Dokument wurde als Projektergebnis bereitgestellt.

### 2.1.7.4 AP VII.4 Erprobung und Validierung im Use Case

Dieses Arbeitspaket startete im dritten Projektjahr. Hier soll bis zum Ende des Projektes eine funktionsfähige und validierte Vermeidungsstrategie erarbeitet werden, welche bei der verlustoptimierten Beschaffungs- und Verkaufsstrategie und der Koordination im Wertschöpfungsnetzwerk verwendet werden kann.

## Literatur

Keine

## 2.1.8 Teilprojekt VIII – Qualitätsgeführte Verarbeitungsprozesse

Metzenmacher, Michael, Geier, Dominik und Becker, Thomas (Technische Universität München), Maier, Sebastian (Fraunhofer IGCV), Jank, Rüdiger und Weber, Matthias (Kuchenmeister GmbH), Schulze, Tania, Büssow, Richard und Hylla, Eike (Industrial Analytics GmbH)

Aktive Partner: **Technische Universität München**, Fraunhofer IGCV, Industrial Analytics GmbH, Kuchenmeister GmbH

Assoziierte Partner: -

Die Qualität von Backwaren wird durch viele Parameter bestimmt. Während der Produktion lassen sich dabei mittels Dichte- und Strukturanalysen Rückschlüsse auf die Intermediat- und Endproduktqualität ziehen. Die Veränderung der Dichte und Struktur von Teigen und Massen beeinflusst sowohl die Verarbeitbarkeit als auch die Qualität des Produkts nach der thermischen Fixierung. Weiterhin ist eine angepasste Steuerung der Gare und des Backprozesses für eine gleichbleibende Qualität nötig. Der Mangel an ausgebildetem Fachpersonal in der Backbranche und schwankende Rohstoffqualitäten bedingen jedoch immer wieder die Produktion von Ausschussware. Eine Beurteilung der Qualität von Backwaren während der Produktion spielt daher eine immer größere Rolle. Fehlerkosten können damit bereits während der Produktion durch korrigierendes Eingreifen reduziert werden.

Eine wesentliche Grundlage für die Einführung von Künstlicher Intelligenz in Herstellungsprozessen ist der Einsatz effizienter onlinefähiger Analytik. Online-Sensoren erlauben ein Monitoring des Produktes während der Herstellung und eine schnelle Auswertung direkt an der Prozesslinie. Weiterhin ermöglicht dies die Entwicklung innovativer Regelungskonzepte, welche Echtzeitdaten nutzen, um auch auf kurzfristige Prozessänderungen reagieren zu können. Durch den Einsatz von Verfahren der Künstlichen Intelligenz werden somit aus onlinefähigen Sensordaten Informationen für eine kontinuierliche Prozessüberwachung und -steuerung generiert, welche qualitätsgeführte Verarbeitungsprozesse in der Backwarenindustrie ermöglichen. Dies wurde in diesem Teilprojekt in drei Schritten untersucht:

- AP1: Umsetzung in der Backwarenproduktion
- AP2: Etablierung technischer Essentials
- AP3: Entwicklung und Implementierung von KI-Ansätzen

### 2.1.8.1 AP1: Umsetzung in der Backwarenproduktion

#### 2.1.8.1.1 Vorgegebene Ziele

AP VIII.1VIII.1.1	Prozessparameter, KI-Schnittstellen und Datenmodelle identifiziert
AP VIII.1VIII.1.2	KI-Schnittstellen, Evaluierung und Etablierung von Referenzmessmethoden und Prozess Sensorik implementiert
AP VIII.1VIII.1.3	Statistisch abgesicherte Datenbasis aufgestellt
AP VIII.1VIII.1.4	Ansätze zur KI-Analyse vorhanden, Prozesswissen digitalisiert, KI-basierte Steuerung entwickelt
AP VIII.1VIII.1.5	Einschätzung über Einsparpotential, Übertragbarkeit, Potential analysiert

### 2.1.8.1.2 Erzielte Ergebnisse

Gemeinsam mit den Projektpartnern wurden KI-Technologien und deren Implementierung in den Musterprozess Backwarenproduktion erarbeitet, konzipiert, dokumentiert und evaluiert. Das Projekt umfasste mehrere Phasen, in denen kontinuierlich weitere Ergebnisse aus Abstimmungs- und Erhebungsarbeits-treffen in die Arbeit integriert wurden, um die Ergebnisse zu erweitern und zu verfeinern. Der Musterprozess wurde definiert und etabliert. Im ersten Schritt der Umsetzung wurde der Ist-Zustand an der Produktionslinie in Bezug auf Prozessparameter, Datenaufnahme und IT-Schnittstellen erfasst. Hierbei wurden verschiedene Messtechniken eingesetzt, um eine detaillierte Prozesskontrolle zu ermöglichen. Unter anderem wurden Druckaufnehmer zur Bestimmung der Schaumkonsistenz eingesetzt. Durch die Messung des Drucks konnte die Qualität des Schaums überwacht und kontrolliert werden. Des Weiteren wurde die Dichte des gebackenen Produkts mithilfe von Online-Höhen- und Gewichtsmessungen bestimmt. Parallel zur Datenaufnahme wurden auch die erforderlichen IT-Schnittstellen implementiert, um eine nahtlose Integration der erhobenen Daten in das KI-System zu ermöglichen. Die gesammelten Daten wurden in Echtzeit erfasst und an die KI-Algorithmen weitergeleitet, um eine automatische Auswertung und Analyse durchzuführen. Dabei kamen fortschrittliche KI-Technologien wie maschinelles Lernen und Data Mining zum Einsatz, um Muster und Zusammenhänge in den Daten zu erkennen und wertvolle Erkenntnisse für die Prozessoptimierung zu gewinnen. Diese zusätzlichen Messungen trugen dazu bei, ein umfassendes Bild des Prozesses zu erhalten und eine genauere Überwachung der Produktqualität zu ermöglichen. Auf Grundlage der gegebenen Prozessparameter wurde die Anforderungsanalyse an den Use Case erarbeitet. Referenz-Methodiken und Sensoren für den Musterprozess wurden evaluiert und festgelegt. Die Messtechnik wurde dabei durch Offline-Referenzmessungen der Schaumstruktur und der ausgebackenen Produkte erweitert (Abbildung 66).

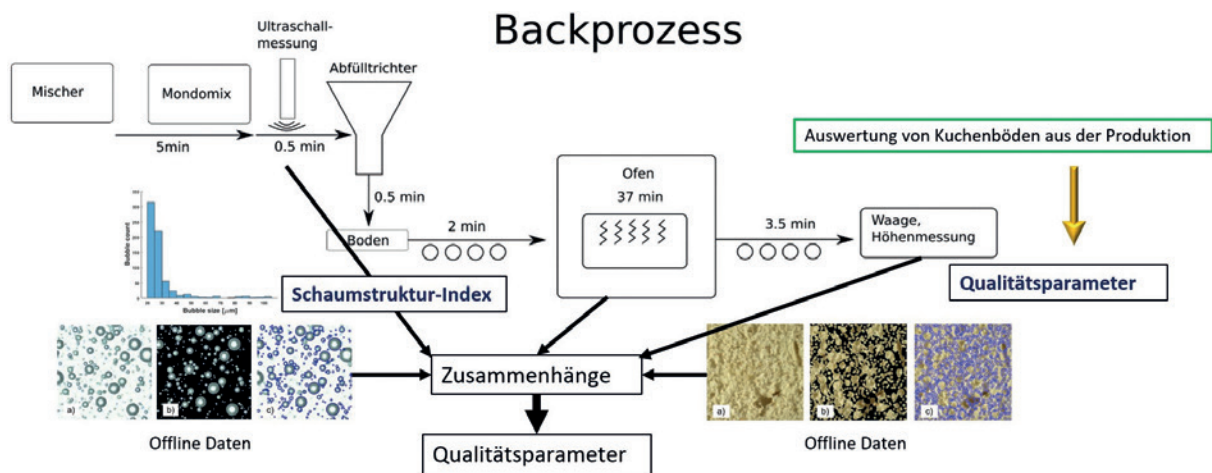


Abbildung 66: Schematische Darstellung des Backprozesses und der qualitätsbestimmenden Zusammenhänge (eigene Darstellung)

Des Weiteren wurden Versuche der TU München zur Bestimmung der Blasenverteilung mittels Ultraschallmessung an der Produktionsanlage begleitet, wobei definierte Prozessparameter variiert wurden. Neben den Daten wurden auch Endprodukte gesammelt und nach einer optischen Qualitätsbewertung an die TU München geschickt.



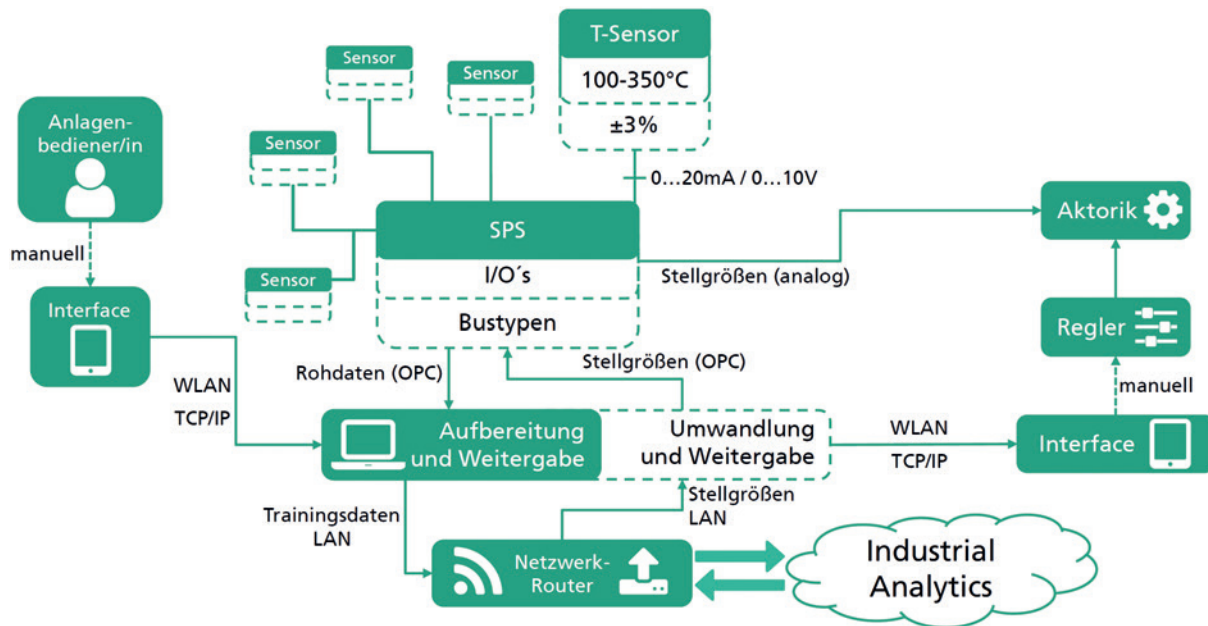


Abbildung 67: Schematische Darstellung des Datennetzwerkes (eigene Darstellung)

In einem weiteren Schritt wurde die Messtechnik kalibriert, Daten aufgenommen und diese in eine Cloud hochgeladen (Abbildung 67). Die fortschreitende Digitalisierung und der Einsatz von Künstlicher Intelligenz (KI) revolutionieren die Art und Weise, wie industrielle Prozesse gesteuert und überwacht werden. In diesem Arbeitspaket wurde die Ankopplung von Sensoren mittels speicherprogrammierbarer Steuerungen (SPS) und Open Platform Communications (OPC) zur Cloud evaluiert. SPS spielen eine entscheidende Rolle bei der Steuerung industrieller Prozesse. Durch die Kopplung von Sensoren mit SPS-Einheiten können Echtzeitdaten erfasst und an die Cloud übertragen werden. OPC, ein Industriestandard für die Kommunikation zwischen verschiedenen Geräten und Systemen, ermöglicht die nahtlose Integration von SPS und anderen industriellen Komponenten in die Cloud-Infrastruktur. In der Cloud können so große Mengen an Sensordaten gespeichert und mit Hilfe von KI-Algorithmen analysiert werden. Durch maschinelles Lernen und Data Mining können Muster und Zusammenhänge in den Daten entdeckt werden, die für die Optimierung von Produktionsprozessen oder die Vorhersage von Wartungsbedarf von großer Bedeutung sein können.

Die Cloud bietet die notwendige Rechenleistung und Skalierbarkeit, um komplexe KI-Analysen effizient durchzuführen. Nachdem die Daten in der Cloud analysiert wurden, können die gewonnenen Erkenntnisse an die Aktoren in der Prozessumgebung zurückgespielt werden. Dies ermöglicht eine automatische Anpassung und Optimierung der Prozessparameter in Echtzeit. Beispielsweise können Aktoren wie Ventile oder Motoren entsprechend den ermittelten Ergebnissen gesteuert werden, um die Effizienz zu verbessern oder Fehler zu korrigieren. Durch die Nutzung von KI in der Cloud können Prozesse optimiert, Ausfallzeiten minimiert und die Produktqualität verbessert werden. Die zentrale Verarbeitung und Analyse von Daten ermöglichen eine umfassende Überwachung und Steuerung mehrerer Standorte oder Anlagen. Allerdings mussten auch Herausforderungen berücksichtigt werden, wie die Datensicherheit, Latenzzeiten bei der Datenübertragung und die Integration bestehender Prozesssteuerungssysteme mit der Cloud-Infrastruktur.

Die Ankopplung von Sensoren mittels SPS und OPC zur Cloud ermöglichte damit die effiziente Erfassung, Verarbeitung und Analyse von Echtzeitdaten in industriellen Prozessen. Durch den Einsatz von KI-Algorithmen in der Cloud können nun wertvolle Erkenntnisse gewonnen und an Aktoren zurückgespielt werden, um Prozesse kontinuierlich zu verbessern. Die Entwicklungen in diesem Bereich eröffnen zudem weitere Möglichkeiten zur Effizienzsteigerung und zur Optimierung industrieller Prozesse und damit eine Ressourceneinsparung in einer zunehmend digitalisierten Welt. Dennoch ist es wichtig, die Herausforderungen der Datensicherheit und der Integration zu beachten, um den vollen Nutzen dieser Technologien zu realisieren.

## 2.1.8.2 AP2: Etablierung technischer Essentials

### 2.1.8.2.1 Vorgegebene Ziele

AP VIII.2VIII.2.1	Vorgehensmodell für die Integration von Datenaufzeichnungssystemen inkl. Peripherie vorhanden
AP VIII.2VIII.2.2	Systeme zur Aufzeichnung von Zeitreihen hinsichtlich Speichereinsatz, Synchronisierung und Effizienz bei typischen Zugriffen bewertet. Fog-Computing-Konzepte entwickelt
AP VIII.2VIII.2.3	Bibliothek zur Datenvorverarbeitung vorhanden

### 2.1.8.2.2 Erzielte Ergebnisse

Gemeinsam mit den Projektpartnern wurden Anlagenvoraussetzungen zum Einsatz der entwickelten KI-Technologien, deren Datenmanagement und notwendige Datenvorverarbeitung definiert und deren Implementierung in den Musterprozess Backwarenproduktion erarbeitet, konzipiert und dokumentiert. Diese werden über den Projektzeitraum sukzessive um weitere Ergebnisse aus Abstimmungs- und Erhebungsarbeitstreffen erweitert und geschärft. Gemeinsam mit den Projektpartnern wurde in Abstimmungstreffen die entwickelten Datenaufzeichnungskonzepte diskutiert und bewertet. Die Aufzeichnung der Daten ist nun über eine Cloud-Lösung etabliert und wurde kontinuierlich angepasst.

Im Rahmen des Teilprojektes wurde seitens Fraunhofer IGCV das allgemeine Vorgehensmodell zur Anwendung maschinellen Lernens in industriellen Prozessen am Beispiel eines Geothermie-Kraftwerks evaluiert. Dabei wurden alle Schritte anhand des Vorgehensmodells durchlaufen und mehrere Use Cases erfolgreich umgesetzt. Damit ist die Evaluierung des Vorgehensmodells abgeschlossen.

Zur Identifikation relevanter Anlageparameter wurde eine Methode entwickelt, die mittels maschinellem Lernens Versuchspläne zur Verbesserung der Performance von künstlichen neuronalen Netzen zur Regression des Anlagenverhaltens generiert. Durch den Aufbau dieser Modell-Bibliothek stehen damit Methoden zur Verfügung, welche auch für die Datenvorverarbeitung in Cloud-Systemen geeignet sind. Diese neuronalen Netze können wiederum verwendet werden, um die Relevanz der Anlageparameter zu bestimmen.

#### **Maschinelles Lernen als „Enabler“ für KI in der Backwarenproduktion**

Die steigende Verfügbarkeit und Anzahl von Sensoren in vernetzten Fertigungssystemen erzeugen Daten, die wertvolle Erkenntnisse über die Prozesse enthalten. Maschinelles Lernen (ML) hat sich als effektives Werkzeug bei der Nutzung großer Datenmengen in verschiedenen Bereichen erwiesen. So hat die Einführung von ML in der Fertigung unter anderem Vorteile wie höhere Produktqualität oder Prozesseffizienz (Shang und You 2019; Sisinni et al. 2018; Weichert et al. 2019). Obwohl KMUs meist über Jahre hinweg ein tiefes Verständnis für ihre Produktionsprozesse entwickeln konnten, haben sie Schwierigkeiten, die Komplexität des ML-Bereichs zu durchdringen und anzuwenden. Dies wirkt sich sowohl auf die Implementierung von ML-Algorithmen aus als auch auf die vorausgehende Erfassung von Daten des Produktionsprozesses. Hierzu zählt beispielsweise die Auswahl von Hardwarekomponenten und Kommunikationsprotokollen in der eigenen Fertigung. Die Überbrückung der Grenze zwischen Betriebstechnologie (Operational Technology, OT) und Informationstechnologie (Information Technology, IT) ist für jeden datengesteuerten Ansatz von grundlegender Bedeutung. Die Verschmelzung von OT und IT birgt jedoch auch Sicherheitsrisiken, da viele OT-Geräte nicht über ausreichende Authentifizierungsverfahren verfügen. Außerdem verwenden OT-Geräte verschiedene, meist proprietäre Kommunikationsprotokolle, die eher auf Robustheit und Verfügbarkeit als auf Sicherheit und Verschlüsselung ausgelegt sind (Garimella 2018). Der Aufbau einer IT-Schnittstelle für diese Geräte ist zeitaufwendig und stellt neue Anforderungen an die IT-Infrastruktur. KMUs benötigen ein Vorgehensmodell, das ihnen hilft, die erforderlichen Ressourcen und technischen Bedingungen für ML zu verstehen und gleichzeitig einen unkomplizierten Arbeitsablauf für den Einsatz von ML in ihren Prozessen bietet. Der Einsatz von KI-Methoden des maschinellen Lernens kombiniert mit innovativen Sensorkonzepten ermöglicht damit

eine Vielzahl an Anwendungen. Dies soll im Folgenden ausführlicher im Kontext REIF am Beispiel der Backwarenproduktion dargestellt werden.

### Allgemeines Vorgehensmodell für maschinelles Lernen

Die Idee eines Vorgehensmodells für datengetriebene Ansätze ist nicht neu. Data Mining (DM) nutzt Methoden, um Datensätze zu untersuchen, Muster zu entdecken, Anomalien zu erkennen und neue Erkenntnisse zu gewinnen. Als Teilbereich der Künstlichen Intelligenz (KI) entdeckt ML Muster und lernt die ihnen zugrunde liegenden Strategien, um Vorhersagen über zukünftige Daten zu treffen. Sowohl DM als auch ML sind analytische Prozesse, die Daten nutzen.

Mit „Knowledge Discovery in Databases“ (KDD) wurde das erste Vorgehensmodell etabliert, das DM als Teil eines umfassenderen Prozesses enthielt. Der KDD-Prozess definiert die Schritte Auswahl, Vorverarbeitung und Umwandlung von Daten, um einen besser handhabbaren Datensatz zu erhalten. Anschließend wird aus dem transformierten Datensatz interpretierbares Wissen gewonnen (Fayyad 1996). Der später entstandene „Cross-Industry Standard for Data Mining“ (CRISP-DM) ist das bis heute bekannteste Vorgehensmodell für DM-Projekte. CRISP-DM beleuchtet neben der technischen Umsetzung auch Schritte zur klaren Definition der Problemstellung und Ziele des Projekts (Shearer 2009). Während auf CRISP-DM basierende Vorgehensmodelle wie „Data Mining Methodology for Engineering Applications“ (DMME) (Huber et al. 2019) die Methodik um produktionstechnisch relevante Aspekte erweitert, gilt Analytics Solutions Unified Method for Data Mining /Predictive Analytics (ASUM-DM, IBM 2023) als agiler Nachfolger von CRISP-DM. Während KDD, CRISP-DM und ASUM-DM die Implementierung von DM-Prozessen auf der IT-Seite eines Unternehmens eingehend beschreiben, fehlt ihnen ein Workflow auf OT-Seite.

Vorgehensmodelle wie DMME, welche auch die OT-Seite umfassen, bieten zwar erste Hilfestellungen für das produzierende Gewerbe, beschreiben einige Schritte aber nur oberflächlich und bieten keine ausreichende Anleitung. Unternehmen, insbesondere KMUs, benötigen eine Methodik, die sie durch den Prozess eines ML-Projekts führt. Dies reicht von der Entscheidung, ob ihr Unternehmen mit seinen derzeitigen Ressourcen von ML profitieren kann, bis hin zum Aufbau einer vollständig in den Fertigungsprozess integrierten ML-Anwendung.

### MANU-ML: Vorgehensmodell für ML in der Produktion

MANU-ML (Methodology for the application of machine learning in manufacturing processes) ist ein auf CRISP-DM und DMME basierendes Vorgehensmodell, welches es Unternehmen ermöglicht, ML in ihren Prozessen zu implementieren und anzuwenden (Maier et al. 2022).

Die Anwendung von ML in der Produktion ist eine interdisziplinäre Herausforderung. Daher werden Stakeholder-Rollen eingeführt, welche unterschiedliche Prioritäten und Fähigkeiten besitzen. Daraus ergeben sich klare Zuordnungen zu anstehenden Aufgaben bei der Durchführung des Vorgehensmodells. Jeder Schritt des Vorgehensmodells listet eine oder mehrere der folgenden Stakeholder-Rollen auf, die zur Erfüllung der anstehenden Aufgaben erforderlich sind:

#### I. Management:

- a) Entscheidungsgewalt über finanzielle Mittel und Prioritäten
- b) Ausrichtung des Projektes mit der Unternehmensstrategie
- c) Überblick über intern vorhandene Kompetenzen

#### II. Prozessfachkräfte:

- a) Verständnis der Produktion, Sub-Prozesse & Parameter

#### III. Prozesstechnische Fachkräfte:

- a) Kennt verbaute Komponenten (Hardware & Software)
- b) Programmierung von SPSen und Implementierung von Protokollen (OT)

#### IV. Data Scientists:

- a) Fachkraft im Verarbeiten und Analysieren von Daten
- b) Implementierung und Auswertung von ML-Modellen

#### V. IT-Integratorinnen und -Integratoren:

- a) Implementierung der Software-Komponenten in die IT-Infrastruktur des Unternehmens

Das Vorgehensmodell ist in Abbildung 68 dargestellt:

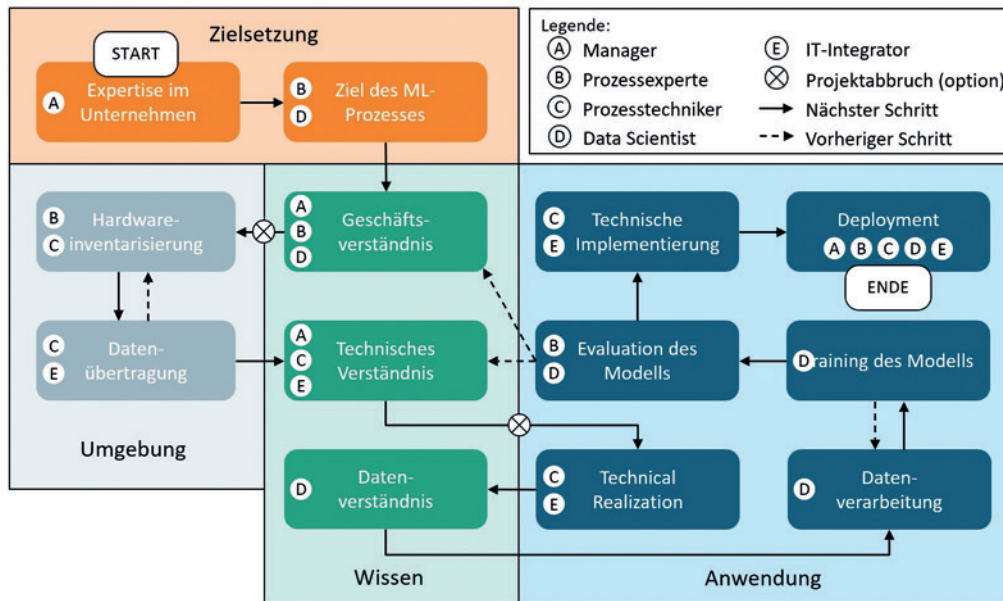


Abbildung 68: Schematische Darstellung der MANU-ML (eigene Darstellung)

Der erste Arbeitsblock, „**Expertise im Unternehmen**“, führt in das Konzept der Stakeholder-Rollen ein und erläutert deren Verantwortungsbereich. Alle Mitarbeitende im Unternehmen können diesen Arbeitsblock anstoßen, jedoch führt das Management den Schritt selbstständig aus und identifiziert die Mitarbeitenden entsprechend den Stakeholder-Rollen. Wenn das Fachwissen für eine oder mehrere Rollen nicht im Unternehmen vorhanden ist, sucht das Management für jede fehlende Rolle externe Beratung.

Der zweite Arbeitsblock, „**Zielsetzung des ML-Prozesses**“, fragt nach dem Ziel, welches das Unternehmen mit einem ML-Projekt erreichen möchte. Anstatt ML zu implementieren und nach einem Anwendungsfall zu suchen, konzentriert sich dieser Schritt auf aktuelle Probleme und mögliche Verbesserungen, um zu bewerten, ob ML sinnvoll ist. Es werden klare Kriterien definiert, die das ML-Projekt erfüllen muss, und die zur Erreichung dieser Kriterien erforderlichen Ressourcen werden abgeschätzt.

Im folgenden Arbeitsblock „**Geschäftsverständnis**“ stellen sowohl Data Scientists als auch die Prozessfachkräfte ihre Anwendungsfälle dem Business Management vor, wobei sie sich auf die erwarteten Verbesserungen durch ML und die damit verbundenen geschätzten Ressourcen konzentrieren. Das Business Management bewertet Kosten und Nutzen, schätzt Risiken ein und prüft die Ausrichtung mit den Zielen des Unternehmens. Am Ende dieses Arbeitsblocks entscheidet das Business Management, ob die Planung des ML-Projekts fortgesetzt wird.

Der folgende Schritt „**Hardwareinventarisierung**“ zielt auf einen vollständigen Überblick über die vorhandene Hardware im Prozess ab. Die prozesstechnische Fachkraft erstellt eine Liste aller Komponenten, einschließlich Sensoren, Aktoren, SPS und Peripheriegeräte. Die Prozessfachkraft erstellt eine Liste der Prozessfaktoren, die sich auf das im zweiten Arbeitsblock definierte Ziel des ML-Projekts auswirken könnten. Sowohl die Prozessfachkraft als auch die Prozessingenieurinnen und -ingenieure gehen dann die Hardwareliste durch und stellen fest, ob die aktuelle Hardware alle Daten für die benötigten Einflussgrößen erzeugt. Ist dies nicht der Fall, suchen sie nach neuen Hardwarekomponenten, die zur Abdeckung aller möglichen Einflussgrößen notwendig sind, und vermerken diese in einer neuen Liste.

Der folgende Arbeitsblock „**Datenübertragung**“ sammelt alle im Betrieb verwendeten Kommunikationsprotokolle, die die prozesstechnische Fachkraft in einer Liste vermerkt. Zusätzlich listet die Fachkraft für IT-Systemintegration alle Protokolle auf, die zur Datenverarbeitung auf der IT-Seite verwendet werden – sofern vorhanden. Anhand dieser Listen entscheiden die Fachkraft für IT-Systemintegration und die prozesstechnische Fachkraft, welche Protokolle in Zukunft verwendet werden sollen. Da die

prozesstechnische Fachkraft einen Überblick über die Hardware aus dem vorherigen Schritt hat, kann diese Person in den vorherigen Arbeitsblock zurückgehen und die Liste der neuen Hardware entsprechend der Entscheidung in diesem Schritt bearbeiten. Bei der Verwendung von proprietären Protokollen auf der OT-Seite könnte beispielsweise ein Edge-Gateway erforderlich sein, um Daten zu sammeln und zu puffern, bevor sie über ein anderes Protokoll an die Cloud gesendet werden.

Im nächsten Schritt, dem „**Technischen Verständnis**“, stellen die prozesstechnische Fachkraft und die Fachkraft für IT-Systemintegration ihre Listen der Geschäftsführung vor, wobei sie sich auf die personellen und finanziellen Ressourcen konzentrieren. Auf der Grundlage dieser Informationen entscheidet das Business Management, ob das ML-Projekt fortgesetzt wird. Da sich das Projekt noch in einem frühen Stadium von MANU-ML befindet, hat das Unternehmen bisher weder Soft- noch Hardware angeschafft. Die investierten Personalressourcen sind im Vergleich zu den anstehenden Arbeitsblöcken gering. Wird das ML-Projekt fortgesetzt, erstellt die Geschäftsführung einen Projektplan und entscheidet, ob neue Mitarbeitende die fehlenden Stakeholder-Rollen perspektivisch füllen sollen, oder ob auf externe Dienstleister zurückgegriffen werden soll.

Im nächsten Arbeitsblock, „**Technische Realisierung**“, wird ein Testaufbau zusammengestellt sowie alle notwendigen Komponenten wie Sensoren und Kommunikationsprotokolle auf der OT-Seite integriert.

Der Data Scientist führt die anstehenden Arbeitsblöcke „**Datenverständnis**“ und „**Datenverarbeitung**“ gemäß CRISP-DM aus. „Datenverständnis“ besteht aus der Sammlung und Beschreibung von Daten, der Exploration und der Qualitätsprüfung. Der anschließende Schritt „Datenverarbeitung“ wandelt den Rohdatensatz in den endgültigen Datensatz um.

Die beiden folgenden Arbeitsblöcke „**Training des Modells**“ und „**Evaluation des Modells**“ umfassen die Auswahl, Erstellung und Bewertung verschiedener ML-Methoden. Da viele ML-Methoden unterschiedliche Anforderungen an den Datensatz stellen, kann es notwendig sein, mehrmals zur „Datenverarbeitung“ zurückzukehren. Gemeinsam mit der Prozessfachkraft vergleicht der Data Scientist die Ergebnisse des Modells mit den in „Zielsetzung des ML-Projektes“ definierten Kriterien und prüft, ob diese ausreichend erfüllt sind. Diese Auswertung kann zu einem tieferen „Geschäftsverständnis“ führen und übersehene Faktoren aufdecken. In diesem Fall kann eine neue Iteration des Vorgehensmodells verbesserte Ergebnisse liefern.

Analog zu DMME wandeln die Prozessingenieurinnen und -ingenieure sowie die Fachkraft für IT-Systemintegration im folgenden Arbeitsblock „**Technische Implementierung**“ den Testaufbau zu integrierter IT-Infrastruktur um.

Erfüllt das Modell alle Kriterien, nutzen alle Beteiligten die ausgewerteten Ergebnisse im letzten Schritt, dem „**Deployment**“. Abhängig vom Anwendungsfall kann dies z. B. die Produktion mit verbesserten Prozessparametern oder eine Echtzeit-Prozessüberwachung sein.

### 2.1.8.3 AP3: Entwicklung und Implementierung von KI-Ansätzen

#### 2.1.8.3.1 Vorgegebene Ziele

AP VIII.3VIII.3.1	Softsensoren entwickelt
AP VIII.3VIII.3.2	Zeitlich normierte Daten vorhanden, BSPC entwickelt
AP VIII.3VIII.3.3	Produktionsverlauf per Human Machine Interfaces überwachbar

#### 2.1.8.3.2 Erzielte Ergebnisse

Gemeinsam mit den Projektpartnern wurden zur Verbesserung des Musterprozesses KI-Technologien identifiziert, welche zur Optimierung des Backprozesses geeignet sind. Diese wurden über den Projektzeitraum sukzessive anhand des entstehenden Prozessdatenpools erweitert und geschärft. Gemein-

sam mit den Projektpartnern wurden bereits in Abstimmungstreffen Zielgrößen identifiziert und deren Abhängigkeit von Prozessgrößen anhand von bereits erhobenen Daten eines Modellprozesses evaluiert. Die ersten Softsensorkonzepte wurden diskutiert und bereits in das neu entwickelte Datensystem eingepflegt. Konzepte der State Estimation wurden in die entwickelte Cloud-Umgebung integriert, um die Prozessqualität beurteilen zu können.

Um den Versuchsaufwand zur Bestimmung relevanter Anlagenparameter so gering wie möglich zu halten, findet ein initiales Training von neuronalen Netzen auf Basis von historischen Daten statt. Im Anschluss wird die initiale Relevanz der Parameter über Permutation und „SHapley Additive exPlanations“ (SHAP) bestimmt und verglichen.

Neben der Relevanz der Parameter ist eine hohe Performance des Modells im Betrieb notwendig. Für den historischen Datensatz werden nach dem Training des Modells alle Faktorzusammenstellungen (Inputs) auf deren epistemische Unsicherheit untersucht. Datenpunkte mit einer hohen epistemischen Unsicherheit sind demnach für einen Versuchsplan zur Verbesserung der Modell-Performance von höherer Relevanz als solche mit niedriger epistemischer Unsicherheit.

Zur Erstellung des Versuchsplans wurden alle Datenpunkte mit hoher epistemischer Unsicherheit auf eine festgelegte Anzahl an Versuchen geclustert. Die zuvor ermittelte Relevanz der Faktoren wird dabei als Gewichtung in das Clustering miteinbezogen.

Zur besseren Auswertung der Daten wurde von Industrial Analytics ein erweitertes Dashboard ausgerollt (Abbildung 69). Das Dashboard ermöglicht, die Daten zu labeln und die Events zu annotieren. Die Möglichkeit zur Darstellung und Datenzuordnung des Zeitablaufschemas wurde implementiert.

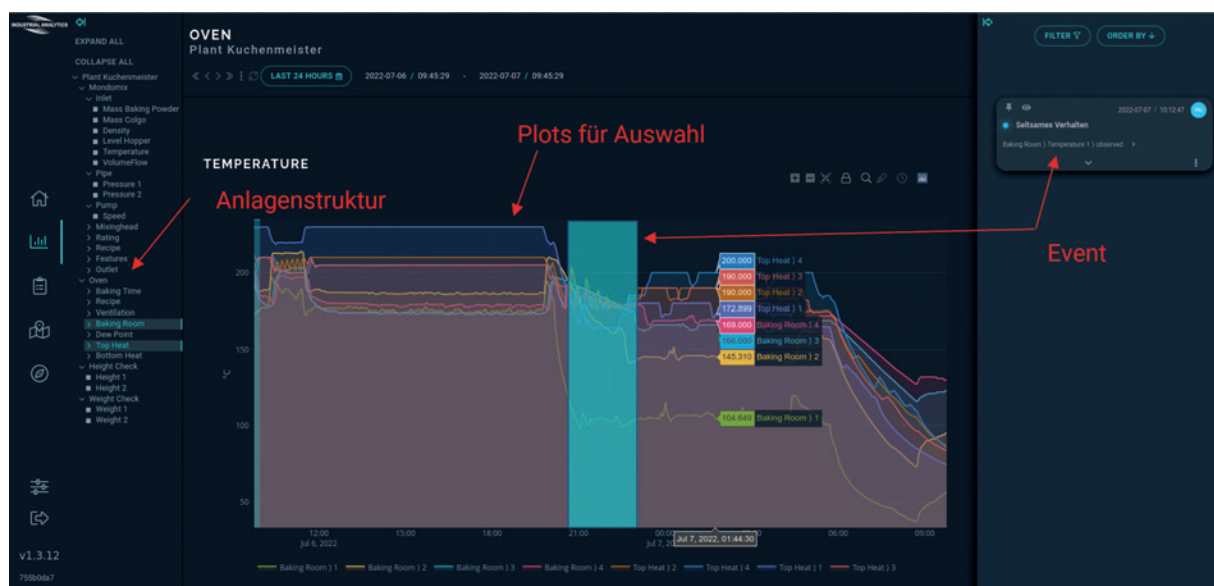


Abbildung 69: Darstellung des erweiterten Dashboards von Industrial Analytics mit Anlagenstruktur, Datendarstellung und Events (eigene Darstellung)

Innovative Sensortechnik und Softsensoren am Beispiel der ultraschallbasierten Strukturanalyse während der Aufschäumung feiner Backwaren

Aktuell erfolgt die Überwachung der Schaumstruktur von feinen Backwaren größtenteils über visuelle und haptische Eindrücke des Fachpersonals. Vielversprechende bildgebende Methoden wie die konfokale Laser-Scanning-Mikroskopie (CLSM) und Röntgenuntersuchungen des Schaums (Computertomographie, CT) sind reine Labormethoden und können daher nicht die Prozessdynamik abbilden. Die genannten Methoden zur Erfassung des Eintrags von Luftporen in getreidebasierten Schäumen sind nicht echtzeitfähig, wodurch eine direkte technologische Anpassung des Prozesses nicht möglich ist. Die Strukturanalyse von Massen mittels ultraschallbasierter Methoden ist daher eine innovative Anwendungsmöglichkeit der nicht invasiven und nicht destruktiven Messung. Durch die Echtzeitfähigkeit der Methode können ungewollte Prozessabweichungen frühzeitig erkannt und korrigierend eingegriffen werden.

Die Grundlage der ultraschallbasierten Messung beruht auf dem Einsatz von mechanischen Wellen mit Frequenzen oberhalb von etwa 20 kHz (Dubbel et al. 2014). Die eingesetzten Ultraschall-Transducer wandeln dabei durch den piezoelektrischen Effekt elektrische Energie in mechanische Energie um. Da die Ultraschallsensoren von außen an die Anlage adaptiert werden können, kann diese Messmethode im Gegensatz zu anderen Methoden sowohl nicht destruktiv als auch nicht invasiv eingesetzt werden. Das entwickelte Messsystem besteht aus einem Mikrocontroller, welcher sowohl zur Signalerzeugung als auch zur Signalaufzeichnung genutzt wird. Die am Lehrstuhl für Brau- und Getränketechnologie entwickelten Ultraschall-Transducer nutzen eine Frequenz von 2 MHz, um eine ausreichende Signallauf- lösung zu gewährleisten. Da die Durchschallung von stark aufgeschlagenen Massen limitiert ist, beruht das hier verwendete Messprinzip auf der Pitch-Catch-Methode auf Basis von Oberflächenwellen. Die Schallenergie wird durch einen Ultraschallwandler über die Rohrleitung in das Medium (Biskuitmasse) eingebracht (Abbildung 70). Dabei läuft ein Teil der entstehenden Ultraschallwelle an der Grenzfläche zwischen Rohrleitung und Biskuitmasse. An der Grenzfläche zwischen der Rohrleitung und der Masse wird, bedingt durch die akustische Impedanz  $Z$ , ein Teil der Schallenergie reflektiert:

$$Z = \frac{p}{u} = \rho c \quad (\text{Gleichung 1})$$

$p$ : Schalldruck,  $u$ : Schallschnelle,  $\rho$ : Dichte,  $c$ : Ultraschallgeschwindigkeit

Die akustische Impedanz ist dabei abhängig vom Schalldruck  $p$ , der Schallschnelle  $u$ , der Dichte  $\rho$  und der Schallgeschwindigkeit  $c$ . Trifft die von der Schallquelle emittierte Ultraschallwelle nun auf eine Grenzschicht zweier Medien mit unterschiedlichen akustischen Eigenschaften, so wird die Schallwelle im Verhältnis des Reflexionskoeffizienten reflektiert:

$$R = \frac{p_r}{p_i} = \frac{Z_2 - Z_1}{Z_2 + Z_1} \quad (\text{Gleichung 2})$$

$Z_1$ : akustische Impedanz von Medium  $M_1$ ,  $Z_2$ : akustische Impedanz von Medium  $M_2$ ,  $p$ : Schallenergie,  $i$ : einfallende Welle,  $r$ : reflektierte Welle




Abbildung 70: A) Schematische Darstellung der Pitch-Catch Methode, B) Ultraschall-Sensoranordnung am Messrohr zur Inline-Bestimmung der Strukturparameter in Biskuitmassen (eigene Darstellung)

Das Verhältnis von emittierter Schallenergie zu detektierter Schallenergie ist dabei von den akustischen Eigenschaften der Grenzschicht und somit direkt von den akustischen Impedanzen  $Z_1$  des Mediums  $M_1$  und  $Z_2$  des Mediums  $M_2$  abhängig. Durch das Aufschlagen der Massen und damit einhergehend dem Eintragen von Luft ändern sich die akustischen Eigenschaften der Masse ( $M_2$ ) und somit der Reflexionskoeffizient. Die alleinige Betrachtung des Reflexionskoeffizienten zur Bestimmung der Dichte ist jedoch nicht ausreichend. Daher wurden die Ultraschallsignale zusätzlich sowohl in der Zeit- als auch in der Frequenzdomäne analysiert. Eventuell auftretende Störgeräusche, hervorgerufen durch z. B. Pumpen oder Motoren, konnten mit geeigneten digitalen Filtermethoden (Butterworth-Bandpass-IIR-Filter) eliminiert werden. Aus den so bereinigten Daten konnten anschließend geeignete Signalparameter gewonnen werden, welche den Prozess beschreiben. Dafür wurden sowohl physikalisch bedingte

Abhängigkeiten wie akustische Impedanz oder Signalenergie als auch unspezifische Parameter aus der Zeit- und Frequenzdomäne berücksichtigt. Durch maschinelle Lernverfahren werden die Signalparameter mit Strukturparametern der Biskuitmassen verknüpft. Die somit gewonnenen Informationen aus den Ultraschallsignalen konnten durch Korrelation mit laboranalytischen Referenzmessungen während des Aufschlagprozesses verifiziert und validiert werden (Metzenmacher et al. 2023). Damit konnten wichtige Prozessparameter, wie beispielsweise die Dichte, online während der Aufschäumung überwacht werden (siehe Abbildung 71).

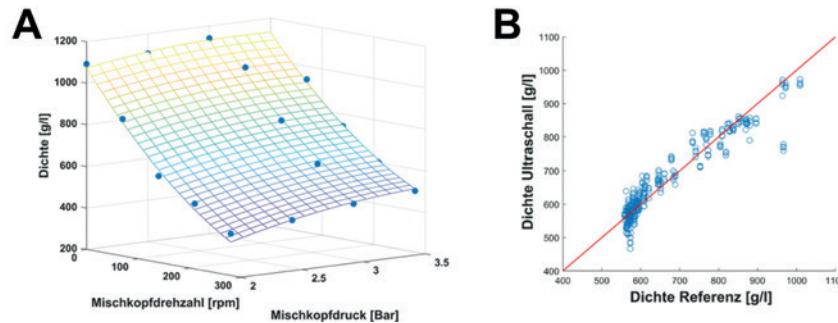


Abbildung 71: A) Zusammenhang zwischen Mischkopfdrehzahl, Mischkopfdruck und Dichte beim Aufschlagen von Biskuitmassen mittels Rotor-Stator-Mischeinheit, B) Gegenüberstellung der vorhergesagten Dichte per Ultraschall und maschinellem Lernen sowie Referenzmessungen (gravimetrische Bestimmung),  $R^2 > 0,9$  (eigene Darstellung)

Durch das damit erreichte Online-Monitoring des Prozesszustandes können die Prozesse auch granularer gesteuert werden. Neben den rein datengetriebenen, maschinellen Lernalgorithmen kann auch vorhandenes Expertenwissen durch bspw. Fuzzy-Algorithmen in die Steuerungskonzepte integriert werden.

Die Schaumstruktur spielt eine entscheidende Rolle für die Textur, den Geschmack und die Haltbarkeit von Biskuitprodukten. Eine gut entwickelte Schaumstruktur mit einer angemessenen Blasenanzahl und -größe führt zu einem luftigen und leichten Endprodukt. Die Dichte des Schaums beeinflusst die Konsistenz und das Volumen des Biskuits, während der Sauter Radius und der relative Span das Maß an Elastizität und Stabilität bestimmen. Die Blasenanzahl in der Biskuitmasse hat direkte Auswirkungen auf die Textur des ausgebackenen Produkts. Eine zu geringe Anzahl von Blasen führt zu einem kompakten und dichten Biskuit mit einer festen Konsistenz. Andererseits kann eine übermäßige Blasenbildung zu einem grobporigen und porösen Produkt führen. Eine optimale Blasenanzahl sorgt für eine gleichmäßige Verteilung von Luftblasen im Teig und führt zu einem leichten und fluffigen Biskuit.

Im Rahmen dieses Projektes wurde die Bedeutung der Schaumstruktur in der Biskuitproduktion erkannt und daraufhin eine Softsensorgroße, der sogenannte Schaumstrukturindex, entwickelt. Dieser Index dient als Maß für die Qualität der Schaumstruktur und wurde mittels Ultraschallmessungen direkt zu Beginn des Prozesses ermittelt. Durch diese Messungen war es möglich, bereits frühzeitig Aussagen über die Schaumqualität zu treffen. Parallel dazu wurden die ausgebackenen Biskuitböden über die gesamte Prozesszeit hinweg bewertet, um den Qualitätsparameter zu bestimmen. Dieser Parameter wurde auf einer Skala von 1 (gut) bis 5 (schlecht) ausgegeben und diente als Indikator für die Qualität des Endprodukts.



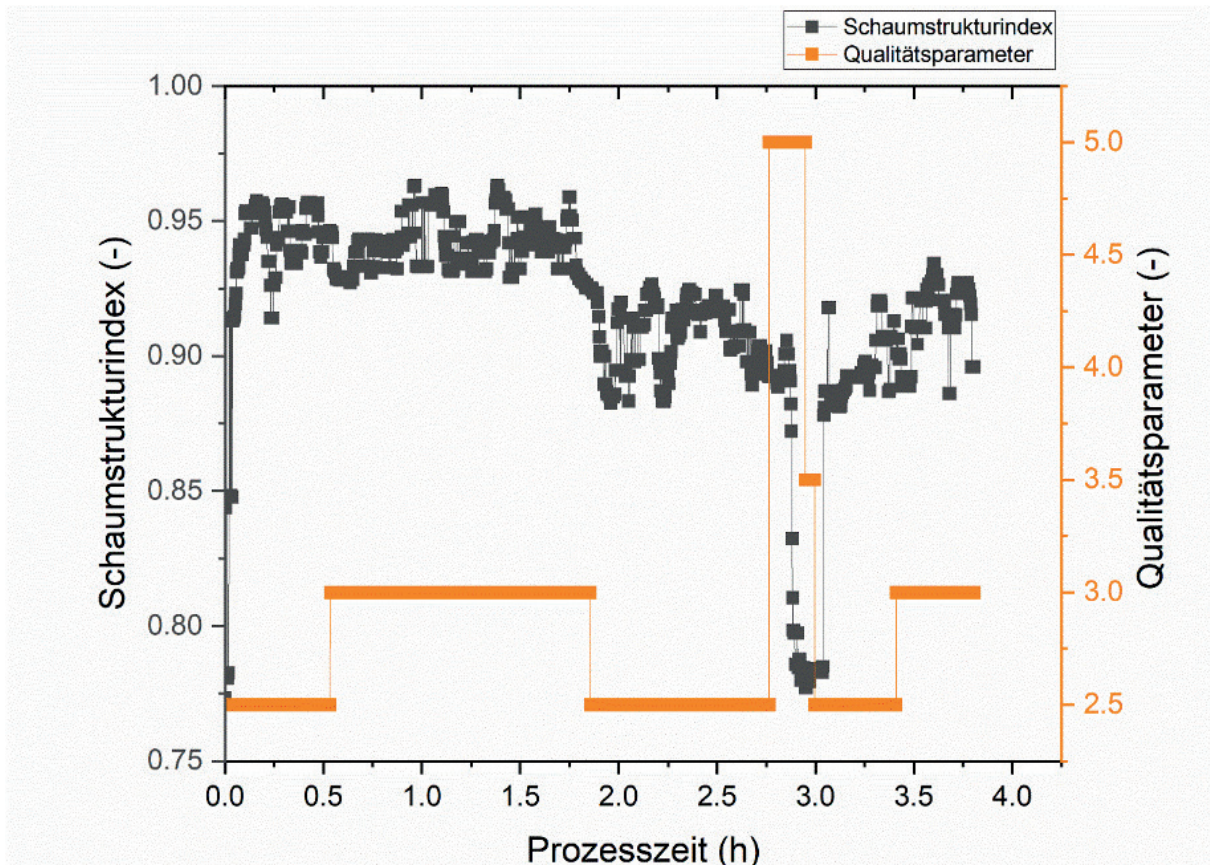


Abbildung 72: Schaumstrukturindex (Online-Messung) der Biskuitmassen über die Prozesszeit im Vergleich zum Qualitätsparameter der resultierenden ausgebackenen Produkte (Offline-Messung) (eigene Darstellung)

Die Schaumstrukturparameter der Biskuitmasse, bestehend aus den Informationen über Blasenanzahl, Dichte, Sauter Radius und relativen Span, spielen eine entscheidende Rolle bei der Beeinflussung der Qualität und Eigenschaften des ausgebackenen Biskuits. Eine optimale Kontrolle und gezielte Optimierung dieser Parameter während des Herstellungsprozesses ermöglichen die Herstellung von hochwertigem Biskuit mit einer ansprechenden Textur, einem angenehmen Geschmack und einer guten Haltbarkeit. Besonders interessant ist die Erkenntnis, dass der Schaumstrukturindex proportional zum Qualitätsparameter des Endprodukts korreliert werden kann. Eine höhere Schaumstrukturqualität, die durch einen höheren Schaumstrukturindex gekennzeichnet ist, deutet auf eine bessere Qualität des ausgebackenen Biskuits hin. Dies zeigt, wie die Onlinebestimmung der Schaumstruktur während des Produktionsprozesses eine Vorhersage über die spätere Produktqualität ermöglichen kann. Die Kombination aus der Kenntnis der Schaumstrukturparameter und der KI-basierten Verknüpfung mit den Qualitätsparametern des Endprodukts bietet Bäckereien und Herstellern wertvolle Informationen zur Prozessoptimierung und Qualitätskontrolle. Durch die gezielte Anpassung der Prozessparameter können die Produktionsabläufe optimiert und die Qualität der Biskuitprodukte weiter verbessert werden. Dies hat nicht nur positive Auswirkungen auf die Kundenzufriedenheit, sondern trägt auch zur Reduzierung von Lebensmittelverschwendung bei. Die Verknüpfung von Schaumstruktur und Qualitätsparametern durch den Einsatz von KI-Technologien ermöglicht eine präzisere und effizientere Überwachung des Produktionsprozesses. Die fortlaufende Analyse der Schaumstrukturdaten in Echtzeit erlaubt eine frühzeitige Erkennung von Abweichungen und potenziellen Qualitätsproblemen. Auf Basis dieser Erkenntnisse kann schnell reagiert und Maßnahmen zur Prozessoptimierung ergriffen werden. Insgesamt bietet die Verknüpfung von Schaumstruktur, KI-Technologien und Qualitätsparametern in der Backwarenproduktion vielversprechende Möglichkeiten. Es ist zu erwarten, dass diese Erkenntnisse und Technologien zukünftig weiterentwickelt und in der Industrie breit eingesetzt werden, um qualitativ hochwertige Backwaren herzustellen.

## Literatur

- Dubbel, Heinrich, Jörg Feldhusen und Karl-Heinrich Grote (Hrsg.). 2014. Dubbel: Taschenbuch für den Maschinenbau, 24. Aufl. Berlin: Springer.
- Fayyad, Usama. 1996. From Data Mining to Knowledge Discovery in Databases. *AI Magazine* (17). doi: 10.1609/aimag.v17i3.1230.
- Garimella, Phani Kumar. 2018. IT-OT Integration Challenges in Utilities. In 2018 IEEE 3rd International Conference on Computing, Communication and Security (ICCCS): IEEE. doi: 10.1109/cccs.2018.8586807.
- Huber, Steffen, Hajo Wiemer, Dorothea Schneider und Steffen Ihlenfeldt. 2019. DMME: Data mining methodology for engineering applications – a holistic extension to the CRISP-DM model. *Procedia CIRP* 79: 403–408. doi: 10.1016/j.procir.2019.02.106.
- IBM. 2023. Analytics Solutions Unified Method. <ftp://ftp.software.ibm.com/software/data/sw-library/services/ASUM.pdf>.
- Maier, Sebastian, Patrick Zimmermann und Julia Berger. 2022. MANU-ML: Methodology for the application of machine learning in manufacturing processes. *Procedia CIRP* 107: 798–803. doi: 10.1016/j.procir.2022.05.065.
- Metzenmacher, Michael, Dominik Geier und Thomas Becker. 2023. Ultrasonic Wave Mode-Based Application for Contactless Density Measurement of Highly Aerated Batters. *Foods* (Basel, Switzerland) 12 (9). doi: 10.3390/foods12091927.
- Shang, Chao und Fengqi You. 2019. Data Analytics and Machine Learning for Smart Process Manufacturing: Recent Advances and Perspectives in the Big Data Era. *Engineering* 5 (6): 1010–1016. doi: 10.1016/j.eng.2019.01.019.
- Shearer, Peter M. 2009. *Introduction to Seismology*. Cambridge: Cambridge University Press.
- Sisinni, Emiliano, Abusayeed Saifullah, Song Han, Ulf Jennehag und Mikael Gidlund. 2018. Industrial Internet of Things: Challenges, Opportunities, and Directions. *IEEE Transactions on Industrial Informatics* 14 (11): 4724–4734. doi: 10.1109/TII.2018.2852491.
- Weichert, Dorina, Patrick Link, Anke Stoll, Stefan Rüping, Steffen Ihlenfeldt und Stefan Wrobel. 2019. A review of machine learning for the optimization of production processes.

## 2.2 Nutzen und Verwertbarkeit der Ergebnisse

Der Einsatz von Künstlicher Intelligenz in der Lebensmittelbranche birgt erhebliches Potential zur Einsparung von Lebensmittelverlusten bzw. zur Reduzierung der Lebensmittelverschwendung. So hat das REIF-Projekt in den unterschiedlichen exemplarischen Anwendungsfällen gezeigt, dass die Mengen an Ausschuss reduziert und die Produktionsplanung und -steuerung hin zu bedarfsgerechten Plänen optimiert werden kann. Darüber hinaus können Beschaffungs- und Verkaufsstrategien sowie die Koordination von Angebot und Nachfrage im Wertschöpfungsnetz mit Hilfe von Künstlicher Intelligenz verfeinert werden.

Auf Ebene der Projektpartner sind die voraussichtlichen Nutzen bzw. die Verwertbarkeit der Ergebnisse auf verschiedenste Weisen gegeben. Die Forschungseinrichtungen (Fraunhofer IGCV, TU München, HS Augsburg, HS Hof, Jade HS) verbreiteten das generierte Wissen bereits während der Projektlaufzeit durch wissenschaftliche Veröffentlichungen und beabsichtigen, weiterhin auf REIF-Ergebnissen basierende Veröffentlichungen zu tätigen. In Kooperation mit verschiedenen Projektpartnern entstand unter Federführung der Hochschule Hof ein Herausgeber-Band zum Thema „Data Governance“. Darüber hinaus wird ein Übertrag des erlangten Wissens auf die Bereiche Produktionstechnik (besonders durch die HS Augsburg) und Datenrecht (HS Hof) angestrebt. Weiter wird das Wissen im Rahmen von Lehrveranstaltungen Studierenden vermittelt bzw. durch verschiedenste Formate und Medien (z. B. Vorträge und Industrieprojekte) in die Industrie transferiert.

Sowohl den im Projekt beteiligten IT-Dienstleistern als auch den Anwendungspartnern ermöglichen die Projektergebnisse, wirtschaftliche Nutzen aus den Projektarbeiten zu ziehen. Die IT-Dienstleister

(Software AG, CompanyMind, Spicetech, Infoteam SAG, ARXUM, Industrial Analytics, GS1 Germany, fTrache, TIKI) können zum einen die Projektergebnisse in zukünftige Kundenprojekte einbringen und zum anderen ihre Produktportfolios erweitern bzw. in die Lebensmittelbranche hinein ausweiten. Die Anwendungspartner (Westfleisch, Kuchenmeister, Hochland, tegut, Georg Jos. Kaes GmbH, BayWa, Krones, GEA, Inotec) werden die Ergebnisse nach Projektende (gegebenenfalls mit den während des Projekts beteiligten Partnern) weiterentwickeln und in einen Zustand der industriellen Reife überführen, so dass diese nicht nur im prototypischen Betrieb genutzt werden können. Sind die industriellen Anwendungen entwickelt und nach einer anschließenden Evaluation weiterhin positiv bewertet, erfolgt ein Ausrollen auf weitere Standorte. Sowohl die Erweiterung des Produktportfolios der IT-Dienstleister als auch die Nutzung der entwickelten Lösungen bei den Anwendungspartnern führt schließlich zur Stärkung der (internationalen) Wettbewerbsfähigkeit der genannten Unternehmen, was ein Ziel des Innovationswettbewerbs „Künstliche Intelligenz als Treiber für volkswirtschaftlich relevante Ökosysteme“ darstellt. Dieses Ziel wird im Falle der Anwendungspartner durch eine Reduzierung der Lebensmittelverschwendung bzw. der Lebensmittelverluste und der damit einhergehenden wirtschaftlicheren Nutzung von Ressourcen erreicht.

Um der Allgemeinheit – im Sinne der deutschen Wirtschaft – einen Nutzen zu gewährleisten, stellen REIF-Partner als Multiplikatoren ihre Verbindungen und Netzwerke zur Verfügung. Mit Hilfe der Multiplikatoren (Bayerischer Bauernverband, CSCSP, DLG, IVLV, VDMA, WWF, Bayerisches Staatsministerium für Landwirtschaft und Forsten) erfolgte bereits während der Projektlaufzeit ein breiter Wissenstransfer der Ergebnisse in einen großen Anwenderkreis.

### 2.3 Externe Fortschritte während der Projektlaufzeit

TP	Themengebiet	Stichwortartige Beschreibung	Wer?	Wann veröffentlicht?
II	Dynamic Pricing	Working Paper Dynamic Pricing and Organic Waste Bans: A Study of Grocery Retailers' Incentives to Reduce Food Waste <a href="https://ssrn.com/abstract=2994426">https://ssrn.com/abstract=2994426</a> Zeigt, dass Dynamic Pricing effektiver bei der Reduktion von Lebensmittelabfällen ist als Strafgebühren.	Sanders, Robert Evan	12.05.2020
II	Dynamic Pricing	Working Paper Consumer (In)attention to Expiration Dates: A Field Study <a href="https://ssrn.com/abstract=3898800">https://ssrn.com/abstract=3898800</a> Etwa die Hälfte der Konsumenten im Supermarkt achten nicht auf das MHD; erst wenn das MHD sehr nah ist, fangen einige an, nach frischeren Produkten zu suchen. Eine rechtzeitige Preisreduktion und eine Platzierung älterer Produkte vorne im Regal können dieses Verhalten minimieren.	Hansen, Karsten; Misra, Kanishka; Sanders, Robert Evan	30.06.2021
II	Dynamic Pricing	Working Paper Inventory Record Inaccuracy Explains Price Rigidity in Perishable Groceries <a href="https://ssrn.com/abstract=3808358">https://ssrn.com/abstract=3808358</a> Das größte Hindernis für effiziente Preisanpassungen in Echtzeit ist nicht das Fehlen einfacher Preisänderungsmechanismen (z. B. über ESLs), sondern die Unkenntnis des genauen Inventars.	Chehrazi, Naveed; Sanders, Robert Evan; Stamatopoulos, Ioannis	19.03.2021

Tabelle 5: Während der Durchführung des Vorhabens bekannt gewordener Fortschritt auf diesem Gebiet bei anderen Stellen (eigene Darstellung)

### 3 Autoren



**Achhammer, Thomas**  
(TI.KI GmbH)




**Barthelmé, Nicolas**  
(CSCP)



**Becker, Ingo**  
(Inotec GmbH)



**Becker, Thomas**  
(TUM)



**Braun, Hans-Martin**  
(Technische Hochschule Augsburg)




**Braunreuther, Stefan**  
(Technische Hochschule Augsburg)



**Büssow, Richard**  
(Industrial Analytics IA GmbH)



**Colombo, Michael**  
(TI.KI GmbH)



**Fink, Klaus**  
(Fraunhofer IGCV)



**Gaßner, Günther**  
(TUM)



**Geier, Dominik**  
(TUM)



**Heim, Albert**  
(Hochland SE)



**Hylla, Eike**  
(Industrial Analytics IA GmbH)



**Jank, Rüdiger**  
(Kuchenmeister GmbH)



**Kalchschmid, Vincent**  
(IGCV)



**Kaufmann, Klaus**  
(GS1 Germany GmbH)



**Maier, Sebastian**  
(Fraunhofer IGCV)



**Mayer, Dirk**  
(Software AG)



**Metzenmacher, Michael**  
(TUM)



**Özdemir, Julia**  
(Hochschule Hof, iisys)



**Pargmann, Hergen**  
(CompanyMind GmbH & Co. KG)



**Petrausch, Ralf**  
(tegut... Logistik GmbH & Co. KG)



**Pils, Christian**  
(ARXUM GmbH)



**Schallner, Harald**  
(Jade Hochschule)



**Schaten, Daniel**  
(Westfleisch SCE mbH)



**Schulze, Tania**  
(Industrial Analytics IA GmbH)



**Theumer, Philipp**  
(Fraunhofer IGCV)



**Weber, Beatrix**  
(Hochschule Hof, iisys)



**Weber, Judith**  
(Spicetech GmbH)



**Weber, Matthias**  
(Kuchenmeister GmbH)



**Zaritzky, Fabian**  
(Hochschule Hof, iisys)



**Zimmermann, Patrick**  
(Fraunhofer IGCV)



## Das REIF-Projekt

In Deutschland werden bisher jedes Jahr ca. 11 Millionen Tonnen an Lebensmitteln während des Herstellungsprozesses in der Wertschöpfungskette vernichtet. Die Ursachen: Schwankungen in der Nachfrage, Überproduktion und/oder Ausschuss.

Die Lebensmittelindustrie ist komplex. Strenge Anforderungen an die Produktsicherheit, eine geringe Planbarkeit in der Landwirtschaft, unzählige produktspezifische Randbedingungen in der Lebensmittelverarbeitung, volatile Nachfrage und der Trend zu individualisierten Produkten haben eine Verringerung dieser Lebensmittelverschwendung bisher verhindert. Der Kampf gegen die Lebensmittelverschwendung ist jedoch sowohl aus ökonomischer als auch aus ökologischer Sicht von höchster Relevanz.

Das Potential Künstlicher Intelligenz ist unendlich groß und ein wichtiger Schlüssel zur drastischen Reduzierung von Lebensmittelverschwendung entlang der Wertschöpfungskette. Im REIF-Projekt arbeiten starke Partner aus Handel, Industrie, Forschung sowie Verbänden und NGOs zusammen an einem digitalen Marktplatz für KI sowie an der Entwicklung von innovativen KI-Services gegen die Lebensmittelverschwendung. Dieses Buch beschreibt Aufbau und Ziele des REIF-Projektes und berichtet über die Ergebnisse der dreieinhalbjährigen Projektlaufzeit.

Gefördert durch:



Bundesministerium  
für Wirtschaft  
und Klimaschutz

aufgrund eines Beschlusses  
des Deutschen Bundestages



ISBN 978-3-7690-0864-7



9 783769 008647