



Resource-efficient, Economic and Intelligent Foodchain

# Einsatz Künstlicher Intelligenz mittels innovativer Sensorkonzepte in der Backwarenindustrie

Gefördert durch:



aufgrund eines Beschlusses  
des Deutschen Bundestages

Das Projekt REIF ist Teil des Innovationswettbewerbs „Künstliche Intelligenz als Treiber für volkswirtschaftlich relevante Ökosysteme“ und wird vom Bundesministerium für Wirtschaft und Klimaschutz aufgrund eines Beschlusses des Deutschen Bundestages gefördert. Weitere Informationen zum Projekt finden Sie unter [www.ki-reif.de](http://www.ki-reif.de).

## Inhaltsverzeichnis

<b>1</b>	<b>Das Große Ganze: REIF in Kürze</b>	<b>3</b>
<b>2</b>	<b>Kurz &amp; knapp: Bisherige Ergebnisse aus den Teilprojekten</b>	<b>5</b>
2.1	TP I – REIF-Ökosystem	5
2.2	TP II – Verlustoptimierte Beschaffungs- und Verkaufsstrategie	6
2.3	TP III – Koordination im Wertschöpfungsnetzwerk	7
2.4	TP IV – Verschwendungsminimierende Produktionssysteme	8
2.5	TP V – Bedarfsgerechte Produktionspläne	9
2.6	TP VI – Zuverlässigkeit der Produktion	10
2.7	TP VII – Rückverfolgbarkeit	11
2.8	TP VIII – Qualitätsgeführte Verarbeitungsprozesse für die Backwarenindustrie	12
<b>3</b>	<b>Einsatz Künstlicher Intelligenz mittels innovativer Sensorkonzepte in der Backwarenindustrie</b>	<b>13</b>
3.1	Maschinelles Lernen als „Enabler“ für KI in der Backwarenproduktion	13
3.2	Allgemeines Vorgehensmodell für Maschinelles Lernen	14
3.3	MANU-ML: Vorgehensmodell für ML in der Produktion	15
3.4	Innovative Sensortechnik am Beispiel der ultraschallbasierten Strukturanalyse während der Aufschäumung feiner Backwaren	18
3.5	Weitere Anwendung im Kontext von REIF	21
3.6	Literatur	22

### Hinweis des Herausgebers

© Herausgeber dieser Dokumentation ist das Projekt REIF – vertreten durch Prof. Dr.-Ing Stefan Braunreuther, Technische Hochschule Augsburg (Konsortialleitung). Wir weisen darauf hin, dass das Urheberrecht sämtlicher Texte und Grafiken in diesem Bericht bei den jeweiligen Autoren und das Urheberrecht des Berichts als Ganzes bei dem Herausgeber liegt. Jede Form der Vervielfältigung auf drucktechnischem oder elektronischem Weg – auch auszugsweise – bedarf der ausdrücklichen, schriftlichen Zustimmung sowohl des Herausgebers als auch der jeweiligen Autoren. Für alle Inhalte und Beiträge sind die Verfasser verantwortlich.

## 1 Das Große Ganze: REIF in Kürze

Hans-Martin Braun, Stefan Braunreuther

*Fakultät für Maschinenbau und Verfahrenstechnik, Technische Hochschule Augsburg, Augsburg*

Das Ziel des REIF-Projektes ist es, durch den Einsatz von Künstlicher Intelligenz (KI) die Verschwendung von Lebensmitteln im Produktionsprozess deutlich zu reduzieren, insbesondere in drei Branchen mit hohem Klimafußabdruck, nämlich bei Fleisch- bzw. Wurstwaren, Milchprodukten und Backwaren. Der Fokus liegt dabei auf der Verringerung von Ausschuss und einer bedarfsgerechten Produktionsmenge (Vermeidung von Überproduktion). Gefördert wird das Projekt „REIF – Resource-efficient, Economic and Intelligent Foodchain“ durch das Bundesministerium für Wirtschaft und Klimaschutz (BMWK, zuvor BMWi).

Im Rahmen des Projekts REIF werden Potenziale der Verschwendungsreduzierung mittels KI in den Branchen Molkerei, Fleisch und Backwaren erarbeitet. Angestrebt wird dabei eine Reduzierung der Lebensmittelverluste um bis zu 90 Prozent. 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 Künstliche Intelligenz innovative Lösungsansätze. Beispielsweise kann mithilfe von KI die Nachfrage der Konsumenten genauer prognostiziert werden oder die Produktionsinfrastruktur dazu befähigt werden, kurzfristig sowohl auf schwankende Nachfrage als auch auf schwankende Rohstoffqualitäten zu reagieren.

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

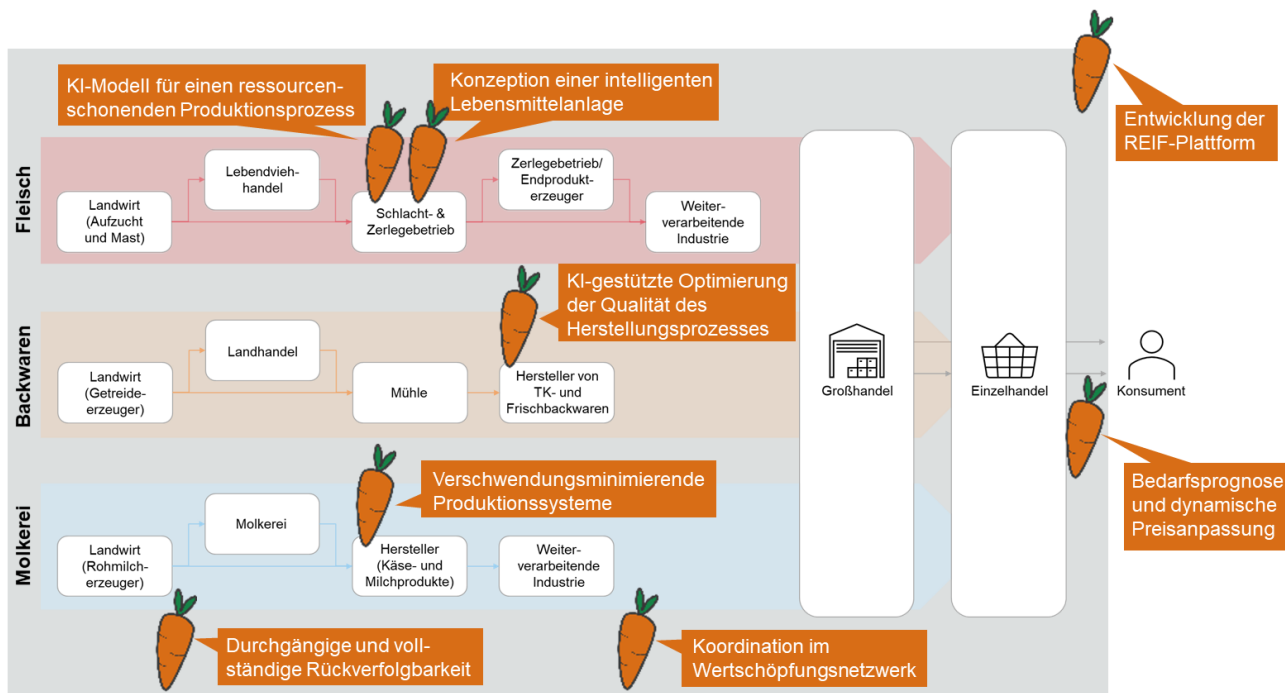


Abbildung 1: Teilprojekte von REIF

Aktuell engagieren sich 31 Projektpartner – von großen Namen, welche man vom täglichen Einkauf im Supermarkt kennt, bis hin zu innovativen Start-ups – aus Industrie, Verbänden und Forschung. Diese 31 Partner arbeiten in acht Teilprojekten entlang der Wertschöpfungsketten in den drei adressierten Branchen Molkerei, Fleisch und Backwaren (siehe Abbildung 1).

Neben vier KI-getriebenen Teilprojekten („KI-Modell für einen ressourcenschonenden Produktionsprozess“, „Konzeption einer intelligenten Lebensmittelanlage“, „KI-gestützte Optimierung der Qualität des Herstellungsprozesses“ und „Verschwendungsminimierende Produktionssysteme“) innerhalb der einzelnen Wertschöpfungsketten, welche auf eine ressourcenschonende und verwendungsminimierende Produktion abzielen, adressiert das Teilprojekt „Bedarfsprognose und dynamische Preisanpassung“ die Abhängigkeiten von Einzelhandel und Konsumenten. Die weiteren Teilprojekte („Durchgängige und vollständige Rückverfolgbarkeit“, „Koordination im Wertschöpfungsnetzwerk“ und „Entwicklung der REIF-Plattform“) adressieren jeweils Wertschöpfungsstufen und -ketten übergreifende Themenstellungen. Besonders die Entwicklung der REIF-Plattform stellt ein zentrales Element des REIF-Projekts dar, da sie das Ökosystem, in welchem alle weiteren Teilprojekte agieren, darstellt.

---

## 2 Kurz & knapp: Bisherige Ergebnisse aus den Teilprojekten

### 2.1 TP I – REIF-Ökosystem

Dirk Mayer

*Software AG, Saarbrücken*

Im Teilprojekt REIF-Ökosystem wurden, nach der Anforderungsaufnahme, Prototypen der Plattform und des Marktplatzes für die Schnittstellen (API) zu den KI-Services, den Datenquellen und Endsystemen entwickelt und implementiert. Parallel wurde eine DLT (Distributed-Ledger-Technologie) Infrastruktur in Form einer Blockchain aufgesetzt, betrieben und eine Integration zur Gesamtplattform umgesetzt. Weiterhin wurden rechtssichere Smart-Contracts entwickelt, erstellt und implementiert. Die Teilprojekte haben ihre APIs auf der Plattform registriert und die Verbindungen wurden erfolgreich getestet.

Weiterhin wurden die Grundzüge eines Betreiberkonzeptes für die REIF-Plattform sowie ein Konzept für die Plattform Governance erstellt. Aspekte der Rückverfolgbarkeit von (Vor-)Produkten wie auch Transaktionen wurden untersucht, ein entsprechendes Konzept erarbeitet und fertiggestellt. Einen großen Raum nahmen auch die juristischen Untersuchungen und Konzepte ein. So wurden nicht nur Arbeiten zu rechtssicheren Datenprodukten erstellt, sondern, vor allem im Hinblick auf einen potenziellen Betrieb der Plattform, auch die laufenden Gesetzgebungsverfahren der Europäischen Union untersucht und analysiert. Eines dieser Ergebnisse ist, dass die Plattform technisch in der Lage ist, die an sie gestellten Anforderungen der wertschöpfungskettenübergreifenden Verfügbarkeit von KI-Services und Daten zu gewährleisten, dies ist aber rechtlich ab 2023 mit Inkrafttreten des Data Governance Acts nicht mehr zulässig. Aus diesem Grund werden sich die Angebote auf der Plattform auf KI-Services beschränken, da das gemeinsame zur Verfügung stellen mit Daten auf einer Plattform untersagt ist.

Die Plattform kann von den Projektpartnern aufgerufen und getestet werden. Zusätzlich wurde für die breite Öffentlichkeit eine Informationsseite erstellt, welche Details und Beschreibungen der verfügbaren KI-Services zur Verfügung stellt.

## 2.2 TP II – Verlustoptimierte Beschaffungs- und Verkaufsstrategie

Judith Weber

*Spicetech GmbH, Stuttgart*

Das erste wesentliche Ziel dieses Teilprojekts war, herauszufinden, ob ein Austausch von Prognosen zwischen in der Wertschöpfungskette aufeinanderfolgenden Unternehmen die Planungssicherheit in den vorgelagerten Stufen verbessern kann. Dazu wurden einige Prognosen für die Supermarktkette tegut... als Feature-Vektor für die Prognosen für die Molkerei Hochland herangezogen. Es konnte gezeigt werden, dass die Prognosen sich durch diese Information wesentlich verbessern lassen. 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. Daher müssten in der Praxis für die hinteren Wertschöpfungsstufen oftmals allein zum Zwecke des Prognoseaustauschs längerfristige Prognosen erstellt werden als für deren eigene Planung notwendig ist.

Das zweite Kernelement des Teilprojekts ist die Entwicklung eines Algorithmus zur Preisreduktion in Abhängigkeit des Mindesthaltbarkeitsdatums (MHD) für den Lebensmitteleinzelhandel. Hier wurde im frühen Projektverlauf 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. Deshalb wurde ein Algorithmus entwickelt, der anhand der bekannten Daten (Lieferung inkl. MHD, Verkäufe, Bruch & 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. In der praktischen Erprobung, die seit Anfang Januar in einem tegut... Supermarkt stattfindet, wird zunächst die Qualität der Bestandsschätzungen evaluiert. Sofern diese ausreichend gut ist, schließt sich eine operative Erprobungsphase der vom Algorithmus berechneten Preisreduktionen mit begleitender Marktforschung an.

## 2.3 TP III – Koordination im Wertschöpfungsnetzwerk

Günther Gaßner

*Technische Universität München, Freising*

Das TP III beschäftigt sich mit unternehmensübergreifender Synchronisierung von Angebot und Nachfrage als Basis für die Koordination des gesamten Wertschöpfungsnetzwerks mit dem Ziel der Reduktion von Lebensmittelverschwendung.

Zunächst wurden der Status quo untersucht und bestehende Modelle und Systeme ermittelt, um einen bewerteten Überblick zu erhalten. Aus diesen Ergebnissen wurden Anforderungen an die Modellierung und Simulation abgeleitet und als Basis für den Modellaufbau herangezogen.

Zur weiteren Bewertung der möglichen Handlungsalternativen hat das CSCP (Collaborating Centre on Sustainable Consumption and Production) in Abstimmung mit den Projektpartnern u. a. den in Frankreich entwickelten Eco-Score analysiert und untersucht. Zusammenfassend ist der Eco-Score für die Bewertung der Umweltwirkung verschiedener Handlungsoptionen (als Zusatzkriterium zur reinen Kostenbewertung) geeignet. Denn er berücksichtigt 16 Wirkungskategorien (z. B. Klimawandel, Wasserverbrauch, Landverbrauch, Feinstaub oder Versauerung), die die Umweltwirkung eines Produkts von der Erzeugung bis zur Entsorgung ganzheitlich abbilden, sowie zusätzliche Nachhaltigkeitskriterien wie Biodiversität, Wiederverwertbarkeit der Verpackungen oder Zertifizierungen der Inhaltsstoffe.

Bisher wurde in TP III vor allem die Gesamtarchitektur für die vorgesehene optimierte Koordination von Bestellmengenverteilungen in Wertschöpfungsnetzwerken umgesetzt und im Zuge dessen laufend weiterentwickelt. In der aktuellen Ausbaustufe steht ein auf dem Fraunhofer IGCV-Rechencluster entwickeltes generalisiertes Materialflusssimulationsmodell zur Verfügung. Es dient als Umgebung für die Anwendung des vom Projektpartner TU München entwickelten Multiagentensystems (MAS) für die Vermeidung von Lebensmittelverschwendung auf Wertschöpfungsnetzwerkebene. Im Modell sind die Stufen Landwirtschaft, Produktion, Großhandel und Point of Sale abgebildet. Die einzelnen Stufen wurden so modelliert, dass sie bei gleichbleibender Logik entsprechend dem Anwendungsfall parametrisiert werden können. Für den Aufbau des Systems wurde dabei prototypisch der vorgesehene Anwendungsfall Molkereiindustrie herangezogen. Der anwendungsfallspezifische Datensatz wurde so dimensioniert, dass das Modell die bayerische Molke-reibranche in skaliertem Form allgemein repräsentiert und gleichzeitig den Projektpartner.

## 2.4 TP IV – Verschwendungsminimierende Produktionssysteme

Philipp Theumer

*Fraunhofer IGCV, Augsburg*

Die Produktionskomplexität in Unternehmen – getrieben durch externe und interne Faktoren – nimmt stetig zu. Gleichzeitig stoßen herkömmliche Ansätze der Datenverarbeitung bei der Analyse von großen Datenmengen in kurzer Zeit an ihre Grenzen. KI-Technologien bieten die Chance, diese Limitierungen zu überwinden und Prozesse auf unterschiedlichen Ebenen der Automatisierungspyramide – vom Shop Floor bis zur Unternehmensleitebene – zu verbessern. Im Rahmen von Teilprojekt IV – Verschwendungsminimierende Produktionssysteme, werden anhand von vier unterschiedlichen Fragestellungen aus unterschiedlichen Ebenen der Automatisierungspyramide die Potenziale für den Einsatz von KI in der Molkereibranche untersucht.

Ziel der Implementierung von Softsensoren ist es, die Pumpfähigkeit der Käsemasse schon während des Mischvorgangs vorherzusagen. Hierfür werden unterschiedliche chemische Daten sowie die aktuellen Maschinenparameter verwendet. Mithilfe dieser Daten wird ein KI-Modell trainiert, welches in Echtzeit prognostiziert, ob ein Verlust der Pumpfähigkeit auftreten wird. Die selbstoptimierende Anlage nutzt u. a. den entwickelten Softsensor und unterstützt den Anlagenbediener bei seinen Entscheidungen. Falls eine Störung des Produktionsprozesses vorhergesagt wird, wird automatisch eine entsprechende Warnung an den Leitstand übermittelt, um optimierend in den Prozess eingreifen zu können.

Hierfür gibt ein trainiertes Künstliches Neuronales Netzwerk (KNN), basierend auf den aktuellen Systemdaten, den Mitarbeitenden Handlungsempfehlungen, um somit eine potenzielle Störung zu vermeiden, bevor diese auftritt. Der intelligente Mixer hat das Ziel, Schwankungen des Produktionsprozesses zu verhindern und in ebendiesen einzugreifen, um somit die Schwankungen in den Eingangsqualitäten zu kompensieren. Dies soll eine Verringerung des Ressourcenverbrauchs ermöglichen und präventiv die Lebensmittelverschwendung reduzieren. Im Rahmen der optimierten Produktionssteuerung wird der hochkomplexe Zielkonflikt produktionslogistischer Einflussfaktoren und Randbedingungen adressiert. Dieser Zielkonflikt äußert sich in der Forderung nach einer möglichst hohen Logistikleistung (hohe Termintreue und kurze Durchlaufzeiten) bei gleichzeitig möglichst geringen Logistikkosten (geringer Bestand und hohe Auslastung) sowie der Reduzierung der steuerungsbedingten Lebensmittelverschwendung. Hierfür wird ein KI-basiertes System zur Entscheidungsunterstützung unter Berücksichtigung der genannten Einflussfaktoren entwickelt. Ziel des KI-basierten Systems ist es, ausgehend vom aktuellen Zustand des Produktionssystems, den Mitarbeitenden die aus Unternehmenssicht bestmögliche Maßnahme unter Berücksichtigung der Lebensmittelverschwendung vorzuschlagen. Durch das KI-basierte System kann die produktions-



steuernde Person perspektivisch bei den täglichen Aufgaben unterstützt werden, wodurch sich einerseits die Entscheidungsqualität verbessert und andererseits die Reaktionsfähigkeit auf bspw. Störungen erhöht wird. Durch die unterschiedlichen betrachteten Use Cases können exemplarisch für unterschiedliche Ebenen des Unternehmens die Potenziale für den Einsatz von KI gezeigt werden.

## **2.5 TP V – Bedarfsgerechte Produktionspläne**

Alica Höpken

*Jade Hochschule, Wilhelmshaven*

In Deutschland werden jährlich circa 18 Millionen Tonnen Lebensmittel entsorgt. 60 Prozent der entsorgten Lebensmittel stammen jedoch nicht aus Privathaushalten, sondern aus Unternehmen der Lebensmittelproduktion. Auch in der Fleischindustrie besteht diese Problematik. Folglich soll die KI-basierte Liefersteuerung verhindern, dass es zu überschüssiger Ware kommt und diese teilweise wegen des Mindesthaltbarkeitsdatums entsorgt oder tiefgekühlt werden muss. Somit gilt es die Einfriermenge zu minimieren.

Im Rahmen des Teilprojekts V zur Entwicklung ressourcenschonender Produktionsprozesse durch den Einsatz von KI-Modellen, optimiert das Projektteam, bestehend aus Mitarbeitenden der Westfleisch SCE mbH, der Jade Hochschule, dem Fraunhofer IGCV sowie der CompanyMind GmbH & Co. KG, den bestehenden Produktionsplanungsprozess hinsichtlich einer ressourcenschonenden Konzeption. Darüber hinaus wurden die Geschäftsprozesse im Sinne einer optimierten Produktionsplanung neu entworfen.

Mit dem entwickelten KI-Service „Bedarfsgerechte Produktionspläne“ ist es insbesondere durch die Senkung des Anteils tiefgekühlter Fleischmengen möglich, die Lebensmittelverschwendung zu reduzieren und Überproduktion zu vermeiden. Hierfür wurde ein Reinforcement Learning Algorithmus mit historischen Daten zu den qualitätsbezogenen Lieferungen und den daraus resultierenden Lagerbeständen trainiert. Dabei wurde ebenfalls die produzierte Menge berücksichtigt. Durch das Training mit diesen Daten können über einen bestimmten Planungshorizont konkrete Vorhersagen über den Bedarf von Produkten in der kommenden Woche getroffen werden. Das Ergebnis des KI-Services besteht in diesem Fall aus einem Plan für die nächsten acht Tage, der die Summe an Bedarfen, der Zugangsmenge, der Nettomenge, der Einfriermenge, der verfallenen Kundenaufträge und der Entwicklung dieser Größen während des Planungshorizonts darstellt. Darüber hinaus werden durch den Reinforcement Learning Algorithmus explizit Vorschläge für Lieferterminverschiebungen gemacht, die sich immer auf alle Positionen einer Lieferung beziehen. Da die Qualitätsanforderungen des Einzelhandels divergieren, wird auch dies bei den Lieferterminverschiebungen berücksichtigt. Somit wird für die Kunden immer die richtige Qualität sichergestellt und gleichzeitig die Einfriermenge reduziert.

## 2.6 TP VI – Zuverlässigkeit der Produktion

Ingo Becker,

*Inotec GmbH/Handtmann Unternehmensgruppe, Reutlingen*

Die Zielsetzung des TP VI ist die „Optimierung des Mischens von Fleisch in der Lebensmittelproduktvorbereitung“, um die Lebensmittelverschwendung durch eine Erhöhung der Mindesthaltbarkeit und der Produktqualität zu reduzieren. Dies wird indirekt durch schonenderes und zielgenaueres Mischen gewährleistet.

Im Normalfall wird der Mischprozess von erfahrenen Bedienern durch Parameter wie Mischdauer und Mischdrehzahl festgelegt. Die Intensität des Mischvorgangs wird auf Basis subjektiver Eindrücke festgelegt, was nicht immer die optimalen Mischparameter für die jeweilige Anwendung zur Folge hat. Dadurch wird oft intensiver gemischt als es für die Erreichung der angestrebten Homogenität notwendig ist. Im Falle von Hackfleisch ist das Ziel ein schnelles Erreichen einer hohen Mischgüte bzw. Homogenität (= gleichmäßige Verteilung der Bestandteile der Rezeptur) bei gleichzeitig geringem Energieeintrag. Anderenfalls kommt es zu einem erhöhten Eiweißaufschluss in Kombination mit dem Austritt von Fleischserum (bestehend u. a. aus Glukose und Aminosäuren). Aus mikrobiologischer Sicht ist genau das zu verhindern, da das Hackfleisch durch diese beiden Bestandteile schneller verderben kann.

Mithilfe von KI soll erreicht werden, dass stets ein optimaler Mischvorgang stattfindet, bei dem eine ausreichende Mischgüte möglichst schonend und effizient erzielt wird. Zu einem schonenden Mischvorgang gehört ein möglichst geringer Energieeintrag, welcher sich u. a. über die Mischdauer, Mischdrehzahl und die Mischstrategie definiert.

Ein besonderer Schwerpunkt war die Entwicklung einer Softsensorik zur Erkennung der Homogenität und des Produktalters auf optischem Weg.

## 2.7 TP VII – Rückverfolgbarkeit

Klaus Kaufmann

GS1 Germany GmbH, Köln

Im Rahmen des Teilprojekts VII zum Thema Rückverfolgbarkeit wurden während der Projektlaufzeit folgende Ergebnisse erzielt:

1. Analyse der Ist-Situation der Lieferkettenprozesse
  - Übersicht der Gemeinsamkeiten und Besonderheiten im Lieferprozess zwischen den verschiedenen Branchen.
  - Sammlung von allgemeinen Informationen und Trends in den unterschiedlichen Branchen.
  - Herausstellen von Gemeinsamkeiten und Besonderheiten zwischen den Branchen.
2. Definition spezifischer Soll-Prozesse
  - Ermittlung relevanter Anforderungen der jeweiligen am Markt Teilnehmenden.
  - Übersicht der Anforderungen der unterschiedlichen am Markt Teilnehmenden.
3. Konzeptionierung der elektronischen End-to-End-Rückverfolgbarkeit
  - Überblick über die funktionellen Anforderungen an Traceability-Systeme bezüglich der jeweiligen am Markt Teilnehmenden.
  - Überblick über die nicht-funktionalen Anforderungen an Traceability-Systeme bezüglich der jeweiligen am Markt Teilnehmenden.

Die o. g. Ergebnisse dienen als Grundlage zur weiteren Verbesserung der Rückverfolgbarkeit von Lebensmittelprodukten mit dem Ziel der verlustoptimierten Beschaffungs- und Verkaufsstrategie entlang von Wertschöpfungsketten. Hieraus folgern zudem Potenziale für eine anschließende Verwertung u. a. in wissenschaftlich-technischer Hinsicht. Anschlussfähigkeit als Verwertungsziel der Projektergebnisse steht dabei im Mittelpunkt.

## 2.8 TP VIII – Qualitätsgeführte Verarbeitungsprozesse für die Backwarenindustrie

Michael Metzenmacher

*Lehrstuhl für Brau- und Getränketechnologie, Technische Universität München, Freising*

Gerade im Bereich der Backwaren erfordert die fortschreitende Automatisierung die Bereitstellung schneller, flexibler und adaptiver Produktionsmethoden. Dabei müssen relevante Prozessparameter erfasst und flexibel und selbstständig durch die Anlagen angepasst werden. Von besonderer Bedeutung ist dies sowohl bei Produktwechseln innerhalb einer Anlage als auch bei der Anpassung von Produktionsprozessen aufgrund von Schwankungen der Rohstoffe. Um derzeit eine gleichbleibende Produktqualität sowie eine reibungslose Produktion innerhalb einer Produktionsanlage zu gewährleisten, müssen mangels übergeordneter und inlinefähiger Methoden, welche den aktuellen Prozess erfassen, hohe Anfahrzeiten und teils händische Optimierungen vorgenommen werden. Ein übergeordnetes System hingegen, gestützt auf sowohl inlinefähige Messmethoden als auch KI-basierte Regelungskonzepte, erlaubt eine gezielte, auf den Produktionsprozess angepasste Optimierung und ermöglicht somit gleichbleibende Qualitäten, kürzere Anfahrzeiten der Produktionsanlage und Ressourceneinsparungen.

In diesem Teilprojekt wurden daher Konzepte entwickelt, welche auf Grundlage vernetzter Sensoren die Herstellung von Backwaren qualitätsgeführt überwachen und adaptiv durch KI-gestützte Methoden optimieren. Durch den Einsatz geeigneter inlinefähiger Sensorsysteme kann der Mischprozess (Aufschäumen) detailliert überwacht werden. Die Optimierung des Aufschäumprozesses, gestützt auf physikalische (mechanische), informatische (KI-gestützte) und softwaretechnische Komponenten, erfolgt durch den Aufbau eines intelligenten Regelsystems, womit sich der Produktionsprozess flexibel an die jeweiligen Produktionserfordernisse anpassen kann. Der Vorteil dieser Methode ist dabei die Integration von vielen Prozessparametern und von Produkt- und Prozesswissen. Die Prozessparameter können dabei nicht nur direkt aus den in diesem Prozessschritt beteiligten Maschinen, sondern auch aus vorgelagerten und nachfolgenden Prozessschritten gewonnen werden.

### 3 Einsatz Künstlicher Intelligenz mittels innovativer Sensorkonzepte in der Backwarenindustrie

Michael Metzenmacher<sup>1</sup>, Maximilian Maier<sup>2</sup>, Eva Pfaller<sup>1</sup>, Dominik Geier<sup>1</sup>, Thomas Becker<sup>1</sup>

<sup>1</sup>Lehrstuhl für Brau- und Getränketechnologie, Technische Universität München, Freising

<sup>2</sup>Fraunhofer-Institut für Gießerei-, Composite- und Verarbeitungstechnik IGCV, Augsburg

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.

#### 3.1 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 [1–3]. Obwohl KMU 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 [4]. Der Aufbau einer IT-Schnittstelle für diese Geräte ist zeitaufwendig und stellt neue Anforderungen an die IT-Infrastruktur. KMU 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.

### **3.2 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 zugrundeliegenden 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 [5]. 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 [6]. Während auf CRISP-DM basierende Vorgehensmodelle wie „Data Mining Methodology for Engineering Applications“ (DMME) [7] die Methodik um produktionstechnisch relevante Aspekte erweitert, gilt ASUM-DM [8] 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 KMU, 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.

### 3.3 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 [9].

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-Prozessen & Parametern
- 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 2 dargestellt:

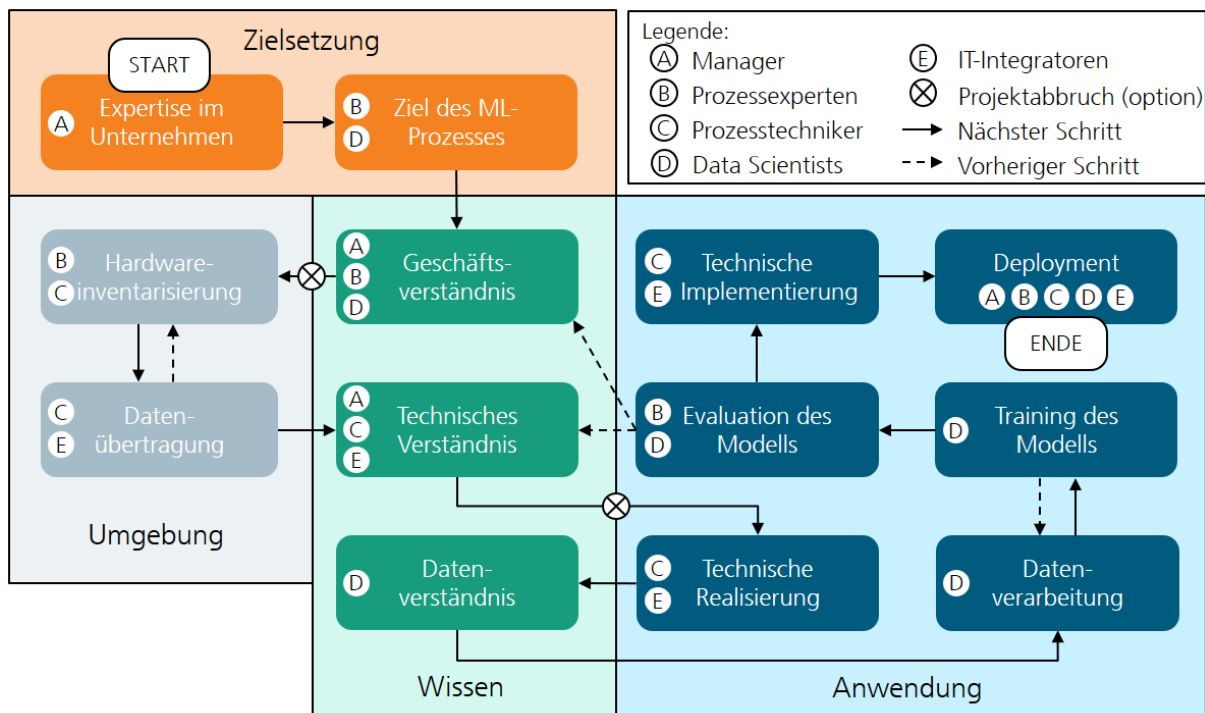


Abbildung 2: Schematische Darstellung der MANU-ML

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 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 prozesstechnischen Fachkräfte 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 prüfen, 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.

### **3.4 Innovative Sensortechnik 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 Lufteinschlüssen 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 festgestellt und es kann korrigierend eingegriffen werden.

Die Grundlage der ultraschallbasierten Messung beruht auf dem Einsatz von mechanischen Wellen mit Frequenzen oberhalb von etwa 20 kHz [10]. 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 Signalauflösung 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 (siehe Abbildung 3). 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  $R$  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

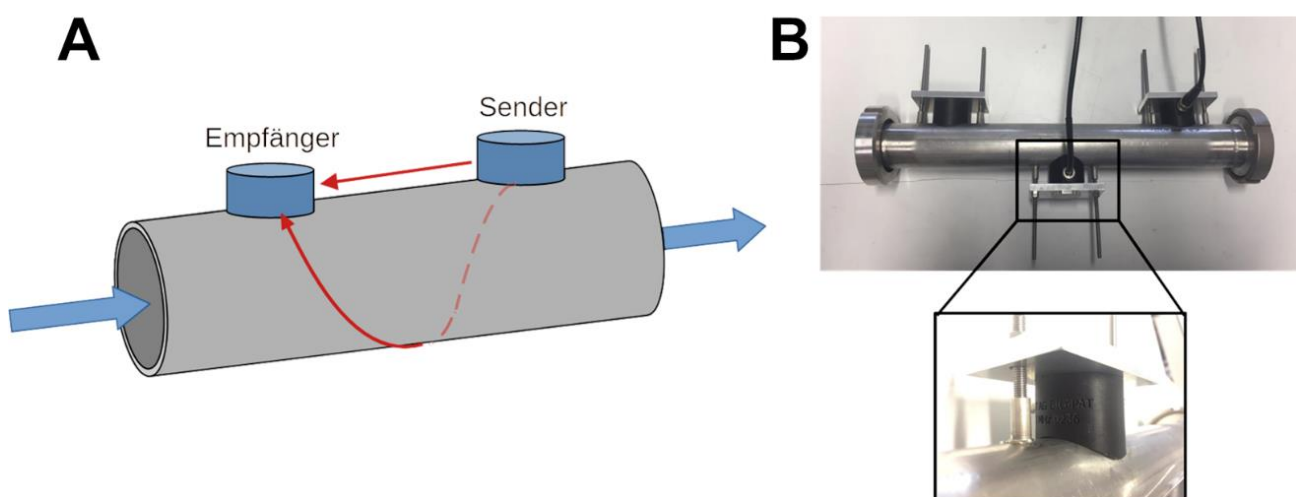


Abbildung 3: A) Schematische Darstellung der Pitch-Catch Methode, B) Ultraschall-Sensoranordnung am Messrohr zur Inline-Bestimmung der Strukturparameter in Biskuitmassen

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 [11]. Damit können wichtige Prozessparameter, wie beispielsweise die Dichte, online während der Aufschäumung überwacht werden (siehe Abbildung 4).

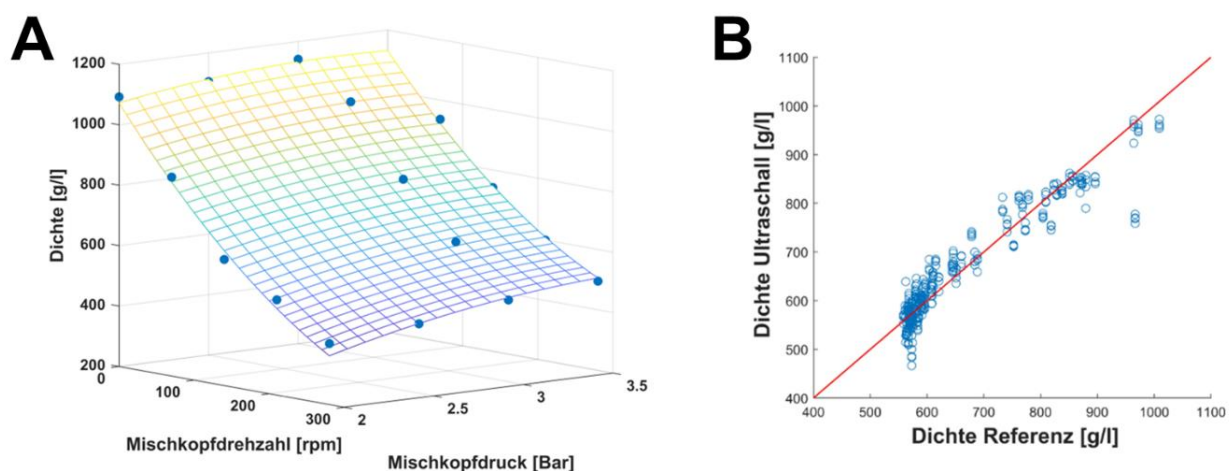


Abbildung 4: A) Zusammenhang zwischen Mischkopfdrehzahl, Mischkopfdruck und Dichte beim Aufschlagen von Biskuitmassen mittels Rotor-Stator-Mischeinheit. B) Gegenüberstellung der vorhergesagten Dichte per Ultraschall und Referenzmessungen (gravimetrische Bestimmung),  $R^2 > 0,9$

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.

### **3.5 Weitere Anwendung im Kontext von REIF**

Die hier vorgestellten innovativen Sensorkonzepte und Strategien zur erleichterten Anwendung von Künstlicher Intelligenz in der Backwarenproduktion können auch genutzt werden, um neue KPIs (Key Product/Process Indicators) zu definieren. Damit können auch konsekutiv ablaufende Prozessschritte der Backwarenherstellung durch neuartige Steuerstrategien zugänglich gemacht werden. Der Einsatz der innovativen onlinefähigen Sensorkonzepte erlaubt dabei auch komplexere, übergreifende Steuerungskonzepte, die sowohl qualitätsgeführte Prozesse ermöglichen als auch Lebensmittelverschwendung minimieren können.

### 3.6 Literatur

- [1] *Shang, C.; You, F.:* Data Analytics and Machine Learning for Smart Process Manufacturing: Recent Advances and Perspectives in the Big Data Era. *In: Engineering 5* (2019), Heft 6, S. 1010-1016. <https://doi.org/10.1016/j.eng.2019.01.019>.
- [2] *Sisinni, E.; Saifullah, A.; Han, S. et al.:* Industrial Internet of Things: Challenges, Opportunities, and Directions. *In: IEEE Transactions on Industrial Informatics 14* (2018), Heft 11, S. 4724-4734. <https://doi.org/10.1109/TII.2018.2852491>.
- [3] *Weichert, D.; Link, P.; Stoll, A. et al.:* A review of machine learning for the optimization of production processes, 2019.
- [4] *Garimella, P.K.:* IT-OT Integration Challenges in Utilities. *In: 2018 IEEE 3rd International Conference on Computing, Communication and Security (ICCCS)*. IEEE, 2018.
- [5] *Fayyad, U.; Piatetsky-Shapiro, G.; Smyth, P.:* From Data Mining to Knowledge Discovery in Databases. *In: AI Magazine*, Vol. 17 (1996), Iss. 3, p. 37. <https://doi.org/10.1609/aimag.v17i3.1230>.
- [6] *Shearer, P.M.:* Introduction to Seismology. Cambridge University Press, Cambridge, 2009.
- [7] *Huber, S.; Wiemer, H.; Schneider, D. et al.:* DMME: Data mining methodology for engineering applications – a holistic extension to the CRISP-DM model. *In: Procedia CIRP*, Vol. 79 (2019), S. 403-408. <https://doi.org/10.1016/j.procir.2019.02.106>.
- [8] *IBM:* Analytics Solutions Unified Method, 2023, <ftp://ftp.software.ibm.com/software/data/sw-library/services/ASUM.pdf>.
- [9] *Maier, S.; Zimmermann, P.; Berger, J.:* MANU-ML: Methodology for the application of machine learning in manufacturing processes. *In: Procedia CIRP 107* (2022), S. 798-803. <https://doi.org/10.1016/j.procir.2022.05.065>.
- [10] *Dubbel, H.; Feldhusen, J.; Grote, K.-H. (Hrsg.):* Dubbel – Taschenbuch für den Maschinenbau. Springer, Berlin, 2014.
- [11] *Metzenmacher M.; Geier D.; Becker T.:* Getreidebasierte Schäume – Lufteintrag per Ultraschall messen. *In: brot+backwaren* (2018), Heft 6, S. 50-53.