

Schlussbericht vom 15.04.2025

zum IGF-Vorhaben 22180 N

Thema

Prädiktive Absatz- und Bedarfsplanung in der kundenorientierten Auftragsfertigung mittels Maschineller Lernverfahren (PrABCast)

Berichtszeitraum

01.01.2022 – 31.12.2024

Forschungsvereinigung

Bundesvereinigung Logistik (BVL) e.V.

Schlachte 31

28195 Bremen

Forschungseinrichtung(en)

RIF Institut für Forschung und Transfer e.V.

Joseph-von-Fraunhofer-Straße 20

44227 Dortmund

Autoren

Marius Syberg

Lucas Polley

David Lenze

Prof. Dr.-Ing. Jochen Deuse

Inhaltsverzeichnis

1 Einleitung	5
1.1 Forschungsziel	5
2 Stand der Technik und Wissenschaft	6
2.1 Absatz- und Bedarfsplanung im Kontext der Produktionsplanung und -steuerung	6
2.2 Bestehende Prognoseverfahren und ihre Grenzen.....	8
2.3 Softwarelösungen im Bereich der Absatz- und Bedarfsprognose für kundenauftragsorientiert fertigende Unternehmen	23
2.4 Forschungslücken aus den Erkenntnissen des Stands der Technik und Wissenschaft	24
3 Durchgeführte Arbeiten und Ergebnisse	26
3.1 Arbeitspaket 1: Erfassung und Bewertung organisatorischer Rahmenbedingungen für prädiktive AB-Planung	28
3.2 Arbeitspaket 2: Potentialanalyse zur Identifikation verfügbarer, ungenutzter Quellen für eine Datenanreicherung	41
3.3 Arbeitspaket 3: Methodik zur AB-Planung mit ML-Verfahren, Benchmarking und Pilotierende Umsetzung der AB-Prognose	49
3.4 Arbeitspaket 4: Übertragung und Generalisierung des entwickelten Modellierungsansatzes	62
3.5 Arbeitspaket 5: Begleitende Einführung und Optimierung der AB-Prognose in der praktischen Anwendung	67
3.6 Arbeitspaket 6: Überführung der Methodik in ein nutzerfreundliches IT-Werkzeug und begleitende Optimierung	68
3.7 Arbeitspaket 7: Projektmanagement, Öffentlichkeitsarbeit, Dokumentation und Ergebnistransfer	
	75
4 Verwendung der Zuwendung	76
5 Notwendigkeit und Angemessenheit der geleisteten Arbeit.....	76
6 Darstellung des wissenschaftlich-technischen und wirtschaftlichen Nutzens der erzielten Ergebnisse insbesondere für KMU sowie ihres innovativen Beitrags und ihrer industriellen Anwendungsmöglichkeiten.....	77
6.1 Wissenschaftlich-technische und wirtschaftlicher Nutzen	77
6.2 Wirtschaftliche Bedeutung der Forschungsergebnisse für KMU	78
7 Wissenstransfer in die Wirtschaft.....	79
8 Durchgeführte Transfermaßnahmen	80
9 Geplante spezifische Transfermaßnahmen nach der Projektlaufzeit	81
10 Zusammenfassung der Forschungsergebnisse und Ausblick.....	82

11	Literaturverzeichnis	84
12	Anhang.....	94

1 Einleitung

In einer zunehmend globalisierten und sich schnell verändernden Marktlandschaft stehen Unternehmen, die kundenindividuelle Produkte fertigen, vor der Herausforderung, flexibel zu bleiben und gleichzeitig stark auf individuelle Kundenwünsche einzugehen. Traditionelle Planungsmethoden, die vor allem auf standardisierte Lagerfertigung ausgerichtet sind, reichen hier oft nicht aus, weil sie die Vielfalt der Kundenbedürfnisse und die damit verbundene hohe Produktindividualisierung nicht ausreichend abbilden können (Wiendahl et al. 2006; Spitz 2018).

Die fortschreitende Digitalisierung ermöglicht es Unternehmen, heute auf umfangreiche Datenmengen aus ERP-Systemen, unterschiedlichen Vertriebskanälen sowie externen Quellen wie Social Media und Wirtschaftsdaten zuzugreifen. Diese Datenbestände eröffnen prinzipiell die Möglichkeit, individuelle Kundenaufträge mit höherer Genauigkeit zu prognostizieren. Erste Untersuchungen deuten jedoch darauf hin, dass konventionelle statistische Verfahren – die in der Regel lediglich einzelne Einflussfaktoren berücksichtigen – den komplexen Anforderungen datenintensiver Fragestellungen nicht hinreichend gerecht werden. (Akinc und Meredith 2015; Makridakis et al. 2018).

Das Forschungsprojekt PrABCast adressiert diese Lücke, indem es Methoden aus dem maschinellen Lernen (ML), einem Teilgebiet der Künstlichen Intelligenz (KI) mit einer gezielten Datenreicherung kombiniert, um die prädiktive Absatz- und Bedarfsplanung in der kundenorientierten Auftragsfertigung zu optimieren. Insbesondere sollen dadurch digitale Hemmnisse abgebaut und kleinen und mittleren Unternehmen (KMU) der Zugang zu fortschrittlichen Prognoseverfahren erleichtert werden (BMWi 2015; Lichtblau et al. 2018).

1.1 Forschungsziel

Das primäre Ziel des Vorhabens PrABCast besteht darin, eine innovative, datengetriebene Methodik für die Absatz- und Bedarfsprognose in der kundenauftragsspezifischen Fertigung zu entwickeln. Im Kern soll ein IT-Tool entstehen, das durch die Integration und Anreicherung unterschiedlicher Datenquellen – von klassischen unternehmensinternen Kennzahlen bis hin zu externen Indikatoren – eine präzisere, proaktive Produktionsplanung ermöglicht. Konkret werden dabei folgende Zielsetzungen verfolgt:

Erweiterung der Prognosegrundlage: Durch den Einsatz moderner ML-Verfahren und die Einbindung zusätzlicher qualitativer sowie quantitativer Datenquellen soll die Komplexität individueller Produktionsprozesse abgebildet werden, um die Prognosegenauigkeit signifikant zu steigern (Akinc und Meredith 2015)

Frühe Auftragsprognose und Entkopplung vom Kundenentkopplungspunkt (KEP): Ziel ist es, Fertigungsprozesse proaktiv anzustoßen – noch vor dem Eingang einer Auftragsbestätigung. Dadurch sollen Durchlaufzeiten verkürzt, Lagerbestände reduziert und die Ressourcennutzung optimiert werden (Thonemann 2010)

Flexibilität und Generalisierbarkeit der Modelle: Die entwickelten ML-Modelle sollen so gestaltet werden, dass sie sich an unterschiedliche Produktfamilien und Unternehmensgrößen anpassen lassen. Dies umfasst die Identifikation charakteristischer Produktmerkmale sowie die Bildung von Anwendergruppen, um mithilfe vortrainierter Modelle die Modellierungsdauer zu verkürzen und die Übertragbarkeit der Ergebnisse zu sichern.

Nutzerfreundliche Umsetzung und Abbau digitaler Barrieren: Ein intuitives IT-Tool wird entwickelt, das auch von Anwendern ohne tiefgehende IT-Kenntnisse bedient werden kann. Durch transparente, nachvollziehbare

Modellentscheidungen soll die Akzeptanz neuer, datenbasierter Prognoseverfahren insbesondere in KMU gesteigert werden (BMW 2015; Lichtblau et al. 2018).

Insgesamt zielt das Forschungsprojekt darauf ab, durch die Kombination von ML-Technologie und systematischer Datenanreicherung eine flexible, präzise und wirtschaftlich relevante Lösung zu realisieren, die nicht nur den wissenschaftlichen Diskurs vorantreibt, sondern auch einen direkten Transfer in die industrielle Praxis ermöglicht.

2 Stand der Technik und Wissenschaft

Die Absatz- und Bedarfsprognose spielt eine entscheidende Rolle in der Planung von Produktion und Lieferketten. Insbesondere in KMU werden seit vielen Jahren bewährte statistische und qualitative Verfahren eingesetzt. Im Gegensatz dazu stellt die kundenorientierte Auftragsfertigung mit ihrer hohen Variabilität besondere Anforderungen an die Prognosemodelle. Um die Ergebnisse des Forschungsprojekts PrABCast einzuordnen und eine Grundlage für die Recherchen in den Arbeitspaketen 1 und 2 zu legen, wird in Kapitel 2 ein kurzer Überblick über den Stand der Technik und Wissenschaft gegeben.

In diesem Kapitel wird zunächst ein Überblick über die Grundlagen der Absatz- und Bedarfsprognose gegeben (Abschnitt 2.1). Darauf folgt eine Analyse der bestehenden Prognosemethoden und deren Einschränkungen für die Auftragsfertigung, genauso wie aktuelle technologische Entwicklungen, insbesondere der Einsatz von ML-Verfahren im Kontext künstlicher Intelligenz (Abschnitt 2.2). Zum Schluss werden offene Forschungslücken identifiziert, die den Bedarf für die im Projekt entwickelte Methodik untermauern (Abschnitt 2.3).

2.1 Absatz- und Bedarfsplanung im Kontext der Produktionsplanung und -steuerung

Eine Absatzplanung dient der Erhöhung der Effizienz in der Produktion eines Unternehmens, indem die Ressourcen wie Mensch und Maschine optimal abgestimmt werden können. Eine zuverlässige Planung ist das Schlüsselement für die optimale Steuerung eines Unternehmens. (Tuomikangas und Kaipia 2014)

Absatzplanung als Teil der Produktionsplanung

Die Produktionsplanung und -steuerung (PPS) kann auf verschiedene Modelle und Vorgehensweisen zurückgreifen, um eine effiziente Ablaufgestaltung sicherzustellen. Das Verständnis im Forschungsprojekt PrABCast orientiert sich dabei am *Hannoveraner Lieferketten-Modell (HaLiMo)* nach Schmidt und Nyhuis sowie an den Ausführungen, die dem *Aachener PPS-Modell* nach Schuh zugrunde liegen. (u.a. Schuh und Stich 2012; Schuh und Schmidt 2014; Schuh et al. 2014b; Schmidt und Nyhuis 2021)

Die PPS plant und steuert Fertigungs- und Montageprozesse termin-, kapazitäts- und mengenbezogen. Diese Ansätze bieten eine strukturierte Grundlage für die Planung, Steuerung und Optimierung von Produktionsprozessen in variantenreichen und kundenorientierten Fertigungsumgebungen. Die PPS plant und steuert Fertigungs- und Montageprozesse termin-, kapazitäts- und mengenbezogen. Die Produktionsplanung gestaltet die Einzelprozesse, während die Produktionssteuerung den Ablauf der Tätigkeiten regelt. Ziel sind hohe Termintreue, gleichmäßige Auslastung, kurze Durchlaufzeiten, geringe Lager- und Werkbestände und eine hohe Flexibilität. (Schuh und Stich 2012)

Die Produktionsprogrammplanung, eine der Kernaufgaben der PPS, plant Art, Menge und Zeitpunkt der Fertigung verkaufsfähiger Endprodukte für einen definierten Planungszeitraum. Dieser Prozess nennt sich

Absatzplanung, das Endprodukt Primärbedarf. (Schuh und Stich 2012) Aus dem geplanten Absatz lässt sich der Sekundär- und Tertiärbedarf ableiten. Sekundärbedarf sind Komponenten, die zur Fertigung des Primärbedarfs benötigt werden. Der Tertiärbedarf wird für die Herstellung der Zwischenprodukte benötigt. Ein Bedarf wird in zwei Ausprägungen ausgelöst. Zum einen kann er auftragsorientiert für jeden eingegangenen Primärbedarfsauftrag ausgelöst werden. Zum anderen können Aufträge über ein bestimmtes Zeitintervall gesammelt und gemeinsam ausgelöst werden. (Schuh und Stich 2012; Schmidt und Nyhuis 2021)

Die Bedarfsplanung umfasst nicht allein die Ermittlung benötigter Primär-, Sekundär- und Tertiärbedarfe. Auch die Kapazitäten und der Einsatz von Personal, Maschinen, Werkzeugen, Lager und Transportmitteln werden geplant.

Bedeutung von Prognosen für Unternehmen mit Auftragsfertigung

Auf Basis dieser Planungen werden im Rahmen des Sales & Operations Planning Process viele Kernfunktionen einer Organisation im Rahmen der Produktion und darüber hinaus beispielsweise in der Koordination der Lieferketten, der Vertriebsaktivitäten oder dem Einkauf geplant (Tuomikangas und Kaipia 2014). Damit diese direkt mit der Absatzplanung verbundenen Planungs- und Steuerungsprozesse zuverlässig erfolgen können, ist eine präzise Absatzprognose erforderlich. Sie dient als Grundlage für die Planung der verkaufsfähigen Endprodukte und beeinflusst direkt die Ableitung von Sekundär- und Tertiärbedarfen. Ohne eine belastbare Prognose sind Unternehmen gezwungen, entweder mit hohen Sicherheitsbeständen zu arbeiten oder Produktionskapazitäten kurzfristig anzupassen, was zu ineffizienten Prozessen und erhöhten Kosten führen kann, manchmal sogar nicht möglich ist und damit die Marktposition verschlechtert. Die AB-Prognose ist daher ein essenzieller Bestandteil der PPS und bestimmt maßgeblich die Steuerung der gesamten Wertschöpfungskette. Je nach Zeithorizont und Detaillierungsgrad lassen sich Prognosen in strategische, taktische und operative Prognosen unterteilen, die unterschiedliche Anforderungen an Methoden und Daten stellen.

Prognosen sind Vorhersagen zukünftiger Entwicklungen auf Basis vergangener Beobachtungen und aktueller Zustände (Vogel 2015). Sie sind empirisch fundiert, indem sie nicht auf Zufälligkeiten beruhen, sondern auf beobachtbaren Gesetzmäßigkeiten, die sachlogisch nachvollziehbar sind (Draenert 2001). Damit eine Prognose sinnvoll durchgeführt werden kann, ist die Annahme einer gewissen Zeitstabilität erforderlich – das heißt, dass die für die Prognose relevanten Zusammenhänge in der Zukunft fortbestehen. Da diese Stabilität in der Realität nie vollkommen gewährleistet ist, sind Prognosen stets mit einer gewissen Unsicherheit behaftet (Hansmann 1983). Die zeitliche Perspektive einer Prognose beeinflusst ihre Funktion und Zielsetzung innerhalb der PPS. In der Praxis werden Prognosen daher in drei Kategorien unterteilt: *strategische, taktische und operative Prognosen*. Diese unterscheiden sich hinsichtlich ihres Planungshorizonts, ihrer Detaillierungstiefe und der Art der verwendeten Daten.

Strategische Prognosen: Strategische Prognosen haben den längsten Planungshorizont, typischerweise mehrere Jahre. Sie dienen der langfristigen Unternehmensausrichtung und beeinflussen grundlegende Investitions- und Kapazitätsentscheidungen, wie den Aufbau neuer Produktionsstätten oder die Entwicklung neuer Märkte. In der Auftragsfertigung sind strategische Prognosen essenziell, um Marktpotenziale zu erkennen und Fertigungskapazitäten frühzeitig zu skalieren. Dabei werden häufig makroökonomische Trends, Branchendaten und technologische Entwicklungen berücksichtigt. (Montgomery et al. 2015)

Taktische Prognosen: Taktische Prognosen umfassen mittelfristige Zeiträume von mehreren Monaten bis wenigen Jahren und bilden die Grundlage für die Produktions- und Materialbedarfsplanung. Sie beeinflussen Entscheidungen zur Kapazitätssteuerung, zur Beschaffung von Rohstoffen und zur

Produktionsprogrammplanung. In der Auftragsfertigung ermöglichen taktische Prognosen eine effizientere Ressourcenallokation. Diese Prognosen basieren oft auf Zeitreihenmodellen und kombinieren historische Verkaufsdaten mit erwarteten saisonalen oder marktbedingten Schwankungen. (Sagaert et al. 2018a)

Operative Prognosen: Operative Prognosen sind kurzfristige Vorhersagen, die sich über Stunden bis Wochen erstrecken (Schoene et al. 2024). Sie dienen der Steuerung der Produktion und der kurzfristigen Anpassung an Auftragsschwankungen. In der Auftragsfertigung sind operative Prognosen besonders wichtig, um Materialflüsse, Maschinenauslastung und Lieferzeiten dynamisch anzupassen. Diese Prognosen beruhen oft auf aktuellen Auftragsbüchern, Lagerbeständen und kurzfristigen Nachfrageschwankungen. (Toktay und Wein 2001)

Die Differenzierung in strategische, taktische und operative Prognosen zeigt, dass jede Ebene unterschiedliche Anforderungen an die Methoden und Datenquellen stellt. Während strategische Prognosen oft qualitative Analysen und makroökonomische Indikatoren einbeziehen, basieren operative Prognosen auf hochfrequenten, quantitativen Daten. In der Auftragsfertigung müssen diese Ebenen eng miteinander verzahnt sein, um sowohl langfristige Planungssicherheit als auch kurzfristige Flexibilität zu gewährleisten.

2.2 Bestehende Prognoseverfahren und ihre Grenzen

Nachdem in Kapitel 2.1 die grundlegende Bedeutung von Absatz- und Bedarfsprognosen im Rahmen der PPS herausgestellt wurde, befasst sich das folgende Kapitel mit den etablierten Methoden zur Prognoseerstellung. Unternehmen setzen dabei sowohl auf traditionelle statistische Ansätze als auch auf heuristische und qualitative Verfahren, um den vielfältigen Anforderungen der strategischen, taktischen und operativen Planung im Unternehmen gerecht zu werden. Allerdings stoßen klassische Methoden bei der Auftragsfertigung häufig an ihre Grenzen, etwa durch eine hohe Individualisierung der Produkte oder unregelmäßige Nachfragerverläufe.

In den kommenden Unterkapiteln werden deshalb zunächst absatzspezifische Grundlagen dargelegt danach wichtige, qualitative Methoden vorgestellt, daraufhin verbreitete quantitative, statistische Methoden erläutert sowie schließlich ML-Verfahren vorgestellt. Dabei wird auf eine tiefe, mathematische Herleitung und Erklärung verzichtet, der Fokus liegt stattdessen darauf, Verständnis für die jeweiligen Stärken und Schwächen zu vermitteln und damit den Ausgangspunkt für die nachfolgenden Betrachtungen zu modernen und datengetriebenen Lösungen zu schaffen.

Absatzspezifische Grundlagen

Bevor detaillierte Prognoseverfahren vorgestellt werden, ist es sinnvoll, die Grundprinzipien von Absatzdaten sowie ihrer Behandlung als Zeitreihen zu erläutern. Absatzdaten bilden für viele Unternehmen – vor allem in produzierenden Branchen – die zentrale Informationsquelle für die Bedarfs- und Kapazitätsplanung. Damit dienen sie als Basis, um zukünftig erwartete Verkaufs- oder Auftragsmengen (Absatzprognose) abzuleiten und in die Produktionsplanung zu überführen. Gerade in der Auftragsfertigung hängt die Abstimmung von Kapazitäten, Materialien und Lieferketten eng mit der Güte und Verlässlichkeit dieser Daten zusammen. (Kreuter et al. 2022)

Von Absatzdaten zur Zeitreihe

In ihrer Rohform sind Absatzdaten häufig lediglich in tabellarischer Form verfügbar, etwa als monatliche Stückzahlen pro Produkt oder Kundengruppe. Anders als bei statischen Datensätzen, in denen alle

Beobachtungen als voneinander unabhängige Stichproben gelten, besitzen Absatzdaten jedoch einen zeitlichen Bezug: Der Absatzwert zu einem bestimmten Zeitpunkt hängt oft mit dem Wert der vorausgehenden oder folgenden Periode zusammen. Werden diese zeitlich geordneten Werte als Zeitreihe betrachtet, ist die Prognoseaufgabe automatisch eine Zeitreihenprognose, die sich in ihrer Methodik von klassischen Regressions- oder Klassifikationsproblemen unterscheidet.

Bei Absatzdaten ist diese zeitliche Struktur essenziell, weil:

1. Vergangene Schwankungen (z. B. saisonale oder konjunkturelle Effekte) Hinweise auf zukünftige Verkaufsvolumina geben,
2. Kontinuierliche Trends – etwa ein genereller Anstieg im Absatz durch neue Produkteinführungen oder Wachstum in bestimmten Märkten – erkannt und in die Prognose eingearbeitet werden müssen,
3. Ein „Bruch“ in der Zeitreihe (z. B. durch interne Ereignisse wie Kapazitätsänderungen oder externe Krisen) die zukünftige Absatzentwicklung kurzfristig stark beeinflussen kann.

Zeitreihendaten

Eine Zeitreihe stellt eine Abfolge von Beobachtungen dar, deren Werte in einem Zusammenhang stehen und Veränderungen im Laufe der Zeit messen. Es handelt sich um geordnete Datensätze von Maßzahlen, die häufig Ergebnisse von sequentiellen Messungen und Beobachtungen sind. Im Gegensatz zu anderen Datenarten gibt der Zeitstempel bzw. die Zeitperiode dem Datensatz eine zeitliche Struktur, wobei er keine Variable an sich ist. Zeitreihen sind eine Realisierung von stochastischen Prozessen und stellen die Gesamtheit der Beobachtungen dar. Dabei wird jedem Messwert ein Zeitstempel zugeordnet, wodurch eine gesammelte Beobachtung über den vollständigen zeitlichen Verlauf ermöglicht wird. Die Messungen werden zum Zeitpunkt t_T durchgeführt. T ist hierbei der gesamte Beobachtungszeitraum. Die Messungen können in verschiedenen zeitlichen Intervallen erfasst werden, wie etwa in stündlichen, täglichen oder sogar jährlichen Messungen. Beispiele hierfür sind der Temperaturverlauf eines Ortes in stündlichen Abständen, die sekündliche Entwicklung von Aktienkursen an der Börse oder der Verlauf von monatlichen Absatzzahlen eines Produktes. (Chatfield 1982; Vogel 2015)

Univariante Zeitreihen werden als solche bezeichnet, da sie neben der Konstante Zeit nur eine Variable aufweisen. Alternativ existieren auch multivariate Zeitreihen, die verschiedene Variablen umfassen. Bei multivariaten Zeitreihen werden zu einem festen Zeitpunkt mehrere Messgrößen erfasst, wie beispielsweise bei der Aufzeichnung von Wetterdaten mit der gleichzeitigen Erfassung von Temperatur, Luftdruck und Luftfeuchtigkeit. An diesem Beispiel wird die Korrelation zwischen den erfassten Komponenten deutlich, welche für multivariate Zeitreihen von Bedeutung ist. (Hyndman und Athanasopoulos 2018)

Wesentliche Merkmale, die Zeitreihen (und damit Absatzdaten) typischerweise aufweisen, sind:

- **Trend:** Eine langfristige Auf- oder Abwärtsbewegung, (z.B. verursacht durch Marktwachstum, Preisanpassungen oder veränderte Kundenbedürfnisse)
- **Saisonalität:** Wiederkehrende Muster über feste Intervalle (z.B. Absatzspitzen bei saisonalen Produkten in bestimmten Monaten oder Feiertagen)

- **Zyklische Einflüsse:** Langfristige Wellenbewegungen, die nicht zwingend exakt periodisch sind (z. B. Konjunkturzyklen).
- **Restkomponente:** Fluktuationen, die weder durch Trend noch durch saisonale oder zyklische Einflüsse erklärt werden können. (z.B. kurzfristige Marktereignisse oder Spezialaufträge)

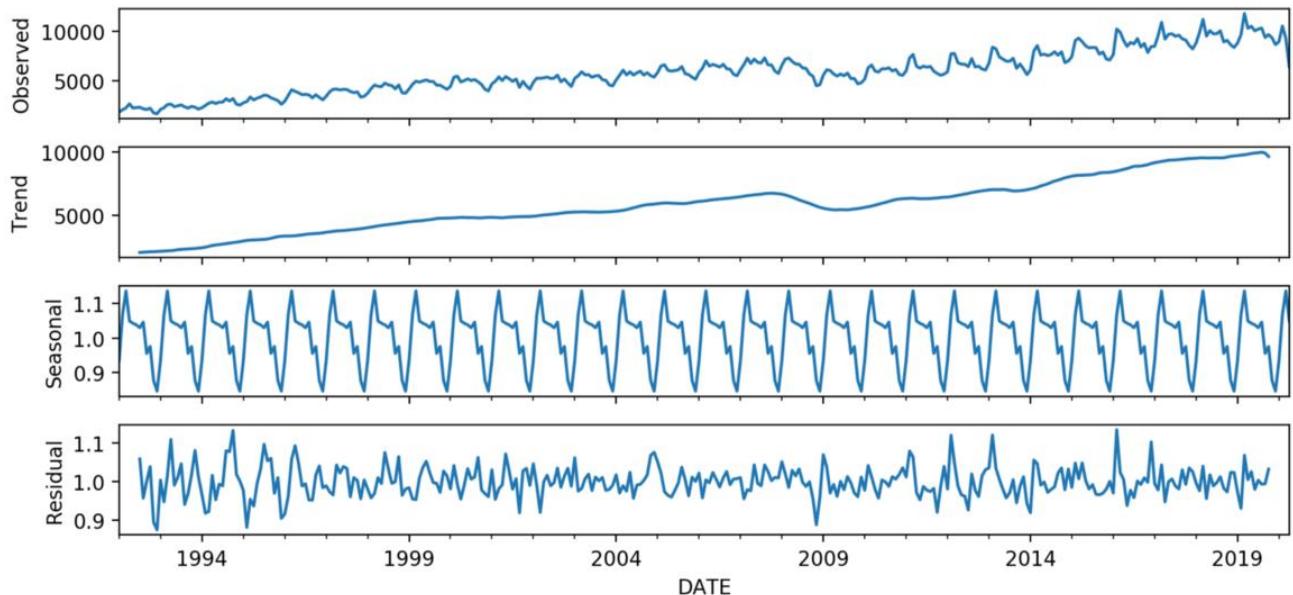


Abbildung 1: Zeitreihendekomposition einer Zeitreihe (Dey (2024); i.A.a. Cleveland et al. (1990))

Für die Prognose ist die Erkennung und Trennung dieser Komponenten entscheidend, um die künftige Absatzentwicklung präzise abzubilden. Mit der Zeitreihendekomposition ist es möglich, diese Komponenten aus Zeitreihen zu errechnen. Eine häufig genutzte Methode hierfür ist die STL-Dekomposition (Seasonal and Trend Decomposition using Loess), die auf Cleveland et al. (1990) zurückgeht. Dabei wird die Zeitreihe in mehreren iterativen Schritten untersucht: Zunächst wird die saisonale Komponente geschätzt und vom Gesamtsignal abgezogen. Anschließend erfolgt die Ermittlung des Trends, der sowohl längerfristige Auf- oder Abwärtsbewegungen als auch konjunkturelle Zyklen abbilden kann. Übrig bleibt schließlich die Residuenkomponente, die kurzzeitige und nicht erklärbare Schwankungen enthält. Der Vorteil der STL-Dekomposition liegt in ihrer Flexibilität: Sie kann sowohl additive als auch multiplikative Beziehungen berücksichtigen und passt sich durch ihre robuste, lokal-regressive Schätzung gut an verschiedene Zeitreihencharakteristika an. Damit liefert sie eine strukturierte Basis, um sowohl vorhersagbare als auch unvorhergesehene Einflüsse zu erkennen und in die weitere Prognose einzubeziehen (siehe Abbildung 1).

Die Absatzplanung in Unternehmen basiert in der Regel auf historischen Verkaufs- bzw. Auftragsdaten, die über verschiedene Zeiträume hinweg erfasst und aggregiert werden. Diese Absatzdaten können als Zeitreihen interpretiert werden, weil sie neben dem eigentlichen Messwert (z. B. Stückzahl pro Tag, Woche oder Monat) immer auch einen zeitlichen Bezug aufweisen (Armstrong 2008). Im Unterschied zu einfachen Regressionsproblemen, bei denen alle Beobachtungen als voneinander unabhängig angenommen werden, verläuft die Entwicklung der Absatzdaten oftmals nicht zufällig, sondern kann auf vergangene Perioden zurückwirken.

Zeitliche Abhängigkeiten und Autokorrelation

Die zeitliche Struktur der Absatzdaten zeigt sich besonders in der Autokorrelation: Frühere Absatzwerte beeinflussen häufig zukünftige Verkäufe. So kann ein deutlicher Einbruch oder ein sprunghafter Anstieg des Absatzes in einer Periode über mehrere Folgeperioden fortwirken (Ord et al. 2017b). Aufgrund dieser Abhängigkeit zwischen aufeinanderfolgenden Messpunkten ist die klassische, zufällige Aufteilung in Trainings- und Testdaten – wie sie aus dem überwachten Lernen bei anderen Prognoseaufgaben bekannt ist – bei Zeitreihendaten oft ungeeignet. Werden etwa vergangene und künftige Beobachtungen unkontrolliert durchmischt, überschätzt man schnell die tatsächliche Vorhersagequalität eines Modells (Parmezan et al. 2019). In der Praxis kommen deshalb spezielle Validierungsansätze zum Einsatz, beispielsweise die Walk-Forward- oder Rolling-Origin-Split-Methode, die bei der Modellentwicklung strikt zwischen „Vergangenheit“ und „Zukunft“ trennen und die zeitliche Struktur der Daten erhalten.

Nichtstationarität, Trends und Saisonalität

Ein weiteres zentrales Merkmal vieler Absatzzeitreihen ist ihre Nichtstationarität. Häufig liegen kurz- bis mittelfristige saisonale Schwankungen vor – etwa durch Feiertage oder jahreszeitabhängige Produktionsnachfragen – sowie langfristige Trends, die auf Wachstum oder Rückgang in bestimmten Märkten schließen lassen (Hasan 2024). Darüber hinaus beeinflussen konjunkturelle Zyklen, Branchenentwicklungen und Produktlebenszyklen den Verlauf der Absatzdaten. Solche systematischen Muster können mithilfe von Zeitreihenzerlegungen (etwa in Trend-, Saison- und Restkomponenten) identifiziert werden und liefern wichtige Anhaltspunkte für eine präzisere Prognose.

Heterogene Daten und Datenqualität

Gerade in produzierenden Unternehmen, insbesondere in KMU, sind Absatzdaten häufig heterogen und werden in unterschiedlicher Granularität erfasst. Unterschiedliche Reporting-Zyklen (z. B. wöchentliche vs. monatliche Aufzeichnungen), fehlende oder unvollständige Datensätze sowie manuelle Erfassungsmethoden erhöhen die Komplexität der Datenaufbereitung. Für eine belastbare Prognose ist daher eine sorgfältige Datenbereinigung und -harmonisierung unabdingbar.

Qualitative Verfahren und Heuristiken

In der betrieblichen Praxis ist festzustellen, dass in zahlreichen Unternehmen keine hinreichend umfassenden und konsistenten Daten vorliegen, die den Einsatz aufwendiger quantitativer Prognosemodelle rechtfertigen würden. Gleichzeitig sind sich insbesondere KMU dem Einsatz quantitativer Verfahren zur Prognose nicht bewusst. In solchen Fällen greifen Unternehmen häufig auf heuristische und qualitative Verfahren zurück, die sich stärker auf das Erfahrungswissen von Experten und Vertriebsmitarbeitern stützen. (Alvarado-Valencia et al. 2017; Soule et al. 2024)

Diese Methoden basieren auf Einschätzungen, Befragungen oder Workshops, in denen Wissen über Kundenbedürfnisse, Marktentwicklungen und betriebliche Kapazitäten zusammengetragen und strukturiert ausgewertet wird. Typische Beispiele hierfür sind Expertenschätzungen, die Delphi-Methode oder Vertriebsprognosen. Auch Marktbefragungen und die Analyse von Trendsignalen (z. B. aus dem Online-Verhalten potenzieller Kunden) können in diesen Bereich fallen.

Ziel dieser heuristischen und qualitativen Prognoseverfahren ist die Schließung von Lücken in der Datenverfügbarkeit sowie ein stärkerer Fokus auf das Know-how erfahrener Mitarbeiter oder externer Fachleute. Im Folgenden werden zentrale Ansätze kurz vorgestellt und hinsichtlich ihrer Vor- und Nachteile in der Absatzplanung beleuchtet.

Expertenbefragung

Bei der Expertenbefragung bzw. Experteneinschätzung kommen Personen mit besonderem Domänenwissen aus verschiedenen Abteilungen, wie Produktion, Vertrieb, Einkauf etc. zusammen. Sie bringen ihre Informationen in die Runde ein und diskutieren die möglichen Konsequenzen. Durch das Zusammentreffen können ähnlich dem Brainstorming weitere Ideen und Lösungsansätze entstehen. Besonders wenn keine langen Verlaufshistorien oder wenige Daten zur Verfügung stehen wird dieses Verfahren angewendet. (Vogel 2015; Mentzer und Moon 2005; Gansser und Krol 2015)

Delphi Methode

Die Delphi-Methode ist ebenfalls eine Runde mit Experten, die einem speziellen Schema folgt. Dabei gibt zunächst jede Person eine anonyme Schätzung mit Begründung ab. Die Ergebnisse der ersten Runde werden dann allen Mitgliedern präsentiert. Dann haben alle Teilnehmenden die Möglichkeit ihre Prognose und Begründungen zu überarbeiten. Das Ergebnis ist dann die Summe der Teilergebnisse. (Vogel 2015; Mentzer und Moon 2005; Gansser und Krol 2015)

Szenario-Analysen

Grundlage dieser Prognosemethode ist die Erstellung mehrerer Szenarien mit gewissen Narrativen. Alle Szenarien (worst, normal, best case) haben verschiedene Wahrscheinlichkeiten aufzutreten und ergeben ein unterschiedliches Verhalten in Bezug auf den Verlauf und die Menge des Absatzes. Ziel ist es, einen Mittelweg zu finden, um Maßnahmen abzuleiten, ohne Extrema aus dem Blick zu verlieren. (Gansser und Krol 2015; Zhang et al. 2021)

Qualitative und heuristische Prognoseverfahren wie Expertenbefragungen, die Delphi-Methode oder Szenario-Analysen erweisen sich vor allem dann als hilfreich, wenn statistische Verfahren nur eingeschränkt anwendbar sind – etwa aufgrund fehlender oder unzureichend strukturierter Daten. Sie ermöglichen eine schnelle Erfassung von Marktkenntnissen, Domänenwissen und impliziten Informationen aus verschiedenen Unternehmensbereichen. Ein Nachteil besteht jedoch in der subjektiven Verzerrung durch individuelle Einschätzungen, was die Prognosegüte beeinträchtigen kann. Zudem sind diese Methoden häufig zeitaufwendig und setzen eine sorgfältige Moderation bzw. Durchführung voraus, insbesondere bei wiederholten Befragungsrunden wie in der Delphi-Methode.

Praxisbeispiel

Ein mittelständischer Maschinenbauer plant die Einführung eines neuen Sondermaschinen-Typs, für den es noch keine verlässlichen Absatzdaten gibt. In einem Workshop mit Experten aus Vertrieb, Konstruktion und Einkauf werden aktuelle Markttrends, Kundenanfragen und Erfahrungswerte zusammengetragen, um den voraussichtlichen Absatz für das kommende Jahr abzuschätzen. Diese qualitative Prognose dient als Ausgangspunkt für die Grobplanung von Kapazitäten und Materialien. Sobald erste Bestellungen vorliegen, werden statistische Verfahren ergänzend eingesetzt, um eine präzisere Absatzprognose zu erstellen.

Qualitative Prognosemethoden bieten den Vorteil, dass praktisches Fachwissen und direkte Markterfahrungen in die Prognose einfließen können. Darüber hinaus sind sie insbesondere für Szenarien mit neuartigen Produkten oder geringer Datenhistorie geeignet und lassen sich flexibel an unterschiedliche Unternehmensstrukturen anpassen. Allerdings hängen die Ergebnisse stark von der Qualität und Motivation der beteiligten Experten ab und können durch gruppendiffusivische Einflüsse oder Voreingenommenheit wie

Hierarchieeffekte oder „Groupthink“ verzerrt werden. Zudem liefern diese Methoden meist keine präzisen quantitativen Aussagen, sondern eher Prognosekorridore und Einschätzungen, die einer weiteren Verfeinerung bedürfen.

Klassische statistische Prognoseverfahren

Im vorigen Kapitel wurde die Relevanz heuristischer und qualitativer Verfahren betont. Für genauere Prognosen, basierend auf vergangenen Zeitreihen verkaufter Produkte, werden klassische statistische Modelle verwendet, die seit vielen Jahren als Standardsätze für Zeitreihen- und Regressionsanalysen in der Absatzprognose gelten. Zu diesen Verfahren zählen unter anderem die exponentielle Glättung und ARIMA-Modelle. Im Vergleich zu moderneren ML-Methoden ist die mathematische Grundlage dieser Verfahren weniger komplex. Nichtsdestotrotz liefern sie in vielen Unternehmen praxisnahe und zuverlässige Vorhersagen, sofern bestimmte Voraussetzungen gegeben sind, die je nach Verfahren in diesem Kapitel erläutert werden.

Im Folgenden wird zunächst dargelegt, wie sich klassische statistische Verfahren grundsätzlich kategorisieren lassen (Zeitreihenmodelle vs. Regressionsmodelle), bevor zentrale Methoden wie die exponentielle Glättung und ARIMA vorgestellt werden. Im weiteren Verlauf werden regressionsbasierte Ansätze behandelt. Den Abschluss bildet eine Zusammenfassung, in der die jeweiligen Anwendungsbereiche der klassischen statistischen Methoden gegenübergestellt werden.

Kategorisierung statistischer Prognoseverfahren

Statistische Prognoseverfahren lassen sich in der Regel in zwei Hauptkategorien unterteilen:

1. *Zeitreihenmodelle*, die ausschließlich auf vergangenen Werten einer Variablen (z. B. Absatzdaten) beruhen und dabei zeitliche Abhängigkeiten modellieren,
2. *Regressionsmodelle*, die nicht nur historische Zeitreihen berücksichtigen, sondern auch exogene Variablen einbeziehen, um den Einfluss zusätzlicher Faktoren (z. B. Werbebudgets, Konjunkturindikatoren oder saisonale Dummy-Variablen) auf die Absatzentwicklung abzubilden.

Zeitreihenmodelle basieren auf der Annahme, dass sich zukünftige Werte weitgehend aus den Eigenschaften und Mustern vergangener Werte vorhersagen lassen (Box et al. 2008). Typische Vertreter dieser Modelle sind Verfahren wie die exponentielle Glättung oder ARIMA (AutoRegressive Integrated Moving Average), die jeweils unterschiedliche Annahmen über Trend-, Saison- und Restkomponenten treffen (Hyndman und Athanasopoulos 2018). Dabei steht die Modellierung autokorrelierter Struktur im Vordergrund, um Vorhersagen auf Basis der zeitlichen Datenstruktur zu ermöglichen.

Regressionsmodelle sind in der Lage, neben der Zeitvariablen auch externe Einflussgrößen, wie beispielsweise Preise, Werbeausgaben oder makroökonomische Kennzahlen, zu erfassen. Ihre Anwendung ist insbesondere dann zu empfehlen, wenn externe Faktoren als Erklärungsvariablen für den Absatz von Relevanz sind. (Gardner 2006) Beispiele stellen einfache lineare Modelle, multiple lineare Regressionen oder log-lineare Modelle dar. Diese Modelle bieten den Vorteil, dass sie Zusammenhänge zwischen mehreren Variablen berechnen können. Zugleich steigt jedoch die Anforderung an Datenqualität und -verfügbarkeit, da relevante Einflussgrößen in ausreichender Menge und Häufigkeit vorliegen müssen (Greene 2019).

Die Unterscheidung in Zeitreihen- und Regressionsmodelle ist für die methodische Auswahl von wesentlicher Bedeutung:

- Zeitreihenmodelle sind vor allem dann geeignet, wenn eine ausgeprägte zeitliche Struktur vorliegt und exogene Einflüsse entweder gering sind oder nicht vorliegen.
- Regressionsmodelle stellen eine Alternative dar, wenn umfangreiche Informationen über potenzielle Einflussfaktoren existieren und eine erweiterte Erklärungskraft angestrebt wird.

In der Praxis wird auch eine Kombination beider Ansätze verwendet, zum Beispiel durch ARIMAX-Modelle (eine ARIMA-Variante mit exogenen Regressoren), um sowohl die autoregressive Struktur als auch externe Einflussgrößen zu berücksichtigen (Mitra et al. 2024). Gerade in Unternehmen mit variantenreicher und kundenorientierter Fertigung kann diese Flexibilität von Vorteil sein, da sich sowohl rein historische Absatzmuster als auch Marktdaten oder interne Kapazitätsinformationen miteinander verknüpfen lassen.

In Folge werden einzelne Verfahren ihren grundlegenden funktionalen Prinzipien nach vorgestellt.

[Zeitreihenmodelle](#)

Zeitreihenmodelle konzentrieren sich ausschließlich auf vergangene Beobachtungen einer Variablen, um daraus zeitabhängige Muster wie Trend, Saisonalität und Autokorrelation abzuleiten. Sie kommen vor allem dann zum Einsatz, wenn externe Einflussfaktoren nicht oder nur schwer zu erfassen sind. Im Allgemeinen wird zwischen deskriptiven bzw. univariaten Verfahren und analytischen bzw. multivariaten Methoden unterschieden. Bei den univariaten Verfahren werden für eine Prognose nur die Vergangenheitswerte der zu prognostizierenden Größe genutzt. Bei den analytischen Verfahren werden weitere Zeitreihen möglicher Einflussfaktoren mit in die Prognose einbezogen. (Pepels 1995)

[Einfache und Naive Prognosemethoden](#)

Einfache oder naive Modelle stellen eine grundlegende Kategorie der quantitativen Prognosemethoden dar. Sie bieten insbesondere für Prognosen mit kurzer bis mittlerer Laufzeit oft einen unkomplizierten Ausgangspunkt. Diese Modelle basieren auf der Prämisse, dass zukünftige Werte in einer Zeitreihe im Wesentlichen den vergangenen Werten oder einer einfachen Funktion davon entsprechen. Die entsprechenden Funktionen können beispielsweise der zuletzt beobachtete Wert oder einen Durchschnitt der vergangenen Werte sein. (Meyer 2002) Bei der einfachen, naiven Prognose nimmt der prognostizierte Wert immer den Wert der letzten Beobachtung an. In Abhängigkeit des jeweiligen Anwendungsfalls werden in dieser Variante häufig Anpassungen vorgenommen. Dabei entspricht der Prognosewert entweder dem Ist-Wert der Vorperiode unter Berücksichtigung der letzten Veränderung oder dem Ist-Wert der gleichen Periode der letzten Saison. (Kühnapfel 2019) In der wissenschaftlichen Literatur wird betont, dass einfache und naheliegende Modelle in stabilen, nicht volatilen Märkten eine bemerkenswert hohe Prognosegenauigkeit aufweisen und daher in der Praxis eine bedeutsame Rolle spielen (Kühnapfel 2015). Goodwin und Wright (2010) betonen zudem, dass einfache Modelle in Kombination mit gutem Urteilsvermögen häufig komplexen, schwer interpretierbaren Verfahren überlegen sein können. In stabilen Märkten können einfache Modelle somit sowohl als Prognosetool als auch als Benchmark zur Beurteilung des Nutzens zusätzlicher Modellkomplexität dienen.

[Gleitender Durchschnitt](#)

Der gleitende Mittelwert dient als Werkzeug in der Analyse von Zeitreihen zur Reduzierung von Schwankungen. Dabei wird der Mittelwert nicht über die gesamte Beobachtungsdauer, sondern über eine Periode von N Werten bestimmt. Dadurch ergeben sich abschnittsweise Berechnungen, die bei Substitution der ursprünglichen Werte den Verlauf der Zeitreihe glätten. Ist der Verlauf der Zeitreihe hinreichend konstant kann der gleitende Durchschnitt auch für eine Prognose genutzt werden. (Mertens und Rässler 2012) In der Praxis sind

Weiterentwicklungen und Anpassungen an diese Methode gängig, da sie neben ihrer Erklärbarkeit einfach zu implementieren und weiterzudenken ist. (vgl. Johnston et al. 1999)

Exponentielle Glättung

Exponentielle Glättung ist ein einfaches, aber vielseitig anwendbares Verfahren, um Zeitreihenprognosen zu erstellen, bei denen frühere Werte mit einem exponentiell abnehmenden Gewicht in die Vorhersage eingehen (Gardner 2006). Grundidee ist die Annahme, dass jüngere Beobachtungen relevanter für die Zukunft sind als ältere. Je nach Komplexität der Zeitreihe unterscheidet man einfache exponentielle Glättung, doppelte exponentielle Glättung und dreifache exponentielle Glättung:

Die exponentielle Glättung erster Ordnung (Single Exponential Smoothing, SES) ist ein Verfahren, welches für konstante Zeitreihen ausgelegt ist. Daher können auch nur dort sinnvolle Prognosen erstellt werden. Im Gegensatz zum gleitenden Durchschnitt werden dabei nicht alle Werte einer Periode gleich betrachtet, sondern unterschiedlich gewichtet. Dabei wird neueren Werten etwa eine größere Bedeutung beigemessen als Werten aus der Vergangenheit. Dieser Korrekturfaktor α bestimmt, wie stark diese Verteilung ausfällt. (Hyndman und Athanasopoulos 2018) Bei trendbehafteten Funktionen muss zusätzlich die Änderung berücksichtigt werden. Das Modell fasst die Glättungswerte erster Ordnung als Beobachtungswerte auf und wendet dort eine weitere Glättung an.

Bei trendbehafteten Funktionen muss zusätzlich die Änderung berücksichtigt werden. Das Modell fasst die Glättungswerte erster Ordnung als Beobachtungswerte auf und wendet dort eine weitere Glättung an. Neben dem Glättungsparameter für das Niveau wird so ein zusätzlicher Parameter für die Trendkomponente geschätzt. Diese Variante wird als Holt-Methode oder exponentielle Glättung zweiter Ordnung bezeichnet. (Holt 2004)

Die dreifache exponentielle Glättung – häufig als Holt-Winters-Methode bezeichnet – erweitert die doppelte exponentielle Glättung um eine Saisonkomponente und verwendet dafür drei Glättungsparameter: für das Niveau (α), den Trend (β) und die Saison (γ). (Winters 1960; Shahin 2016)

Aufgrund ihrer einfachen Implementierung und geringen Rechenanforderungen ist die exponentielle Glättung in zahlreichen Branchen weit verbreitet und bildet in vielen Softwaretools den Standardansatz zur Zeitreihenprognose. (Enns et al. 1982) Gerade für Unternehmen mit kontinuierlichen Absatzdaten und überschaubaren saisonalen Mustern stellen diese Methoden eine robuste Grundlage für verlässliche Prognosen dar. (Bohlmann et al. 2024)

Weitere Verfahren, die speziell die Eigenschaften einer Zeitreihe zur Prognose verwenden, arbeiten häufig mit Autoregression. Die Grundidee eines autoregressiven Modells (AR) ist, dass der aktuelle Wert einer Zeitreihe von einer linearen Kombination seiner eigenen vergangenen Werte abhängt. AR-Modelle integrieren dabei die Vergangenheitswerte direkt in die Modellgleichung. Diese Herangehensweise empfiehlt sich insbesondere in Fällen, in denen der Verlauf einer Zeitreihe signifikant von den eigenen historischen Mustern beeinflusst ist und keine externen Einflüsse oder zusätzliche Variablen in das Modell einfließen sollen. (Hyndman und Athanasopoulos 2018)

Autoregressive Modelle (AR)

In der klassischen Anwendung ist das AR(p)-Modell die Autoregression über p zurückliegende Messpunkte, um den aktuellen Wert zu beschreiben.

$$y_t = c + \phi_1 y_{t-1} + \phi_2 y_{t-2} + \cdots + \phi_p y_{t-p} + u_t$$

Mit:

y_t : Absatz zum Zeitpunkt t

c : konstanter Term, der die Verschiebung der Zeitreihe repräsentiert

ϕ_p : Autoregressive Koeffizienten

y_{t-p} : Vergangene Werte der Zeitreihe (Lags) zum Zeitpunkt $t - p$

u_t : Störterm mit unabhängigem, zufälligem Störfaktor

In diesem Kontext erweisen sich die Autokorrelationsfunktion (ACF) und die partielle Autokorrelationsfunktion (PACF) als förderlich. Mittels dieser Funktionen besteht die Möglichkeit, die Abhängigkeiten zwischen Werten einer Zeitreihe über mehrere Lags hinweg zu untersuchen.

Autoregressive Moving Average Modell (ARMA)

ARMA-Modelle kombinieren die autoregressive Komponente mit einem Moving-Average-Teil und erlauben so die Einbeziehung zufälliger Effekte aus früheren Zeitpunkten. (Vogel 2015) Dabei wird AR(p) um den Term MA(q) ergänzt, der eine Gewichtung vergangener Störterme darstellt. ARMA-Modelle sind jedoch auf Zeitreihen angewiesen, die stationär sind und weder ausgedehnte Trends noch ausgeprägte Saisonalität enthalten (Makridakis und Hibon 1997).

Autoegressive Integrated Moving Average (ARIMA)

Sobald in einer Zeitreihe nichtstationäre Merkmale wie Trend oder veränderliche Varianzen auftreten, wird häufig das ARIMA-Modell herangezogen. Im Kern erweitert es den ARMA-Ansatz um eine Differenzierung, mit der eine nichtstationäre Zeitreihe in eine stationäre Form überführt werden kann (Box et al. 2008). Auf diese Weise entsteht das Kürzel ARIMA(p, d, q), wobei

- p für die Ordnung der autoregressiven Komponente steht,
- d den Grad der Differenzierung angibt, und
- q die Ordnung der Moving-Average-Komponente beschreibt.

Dieses Vorgehen ermöglicht es, Langzeittrends zu entfernen und statistische Eigenschaften wie Mittelwert und Varianz über die gesamte Zeitreihe hinweg stabil zu halten (Teixeira et al. 2024; Escudero et al. 2021) ARIMA gilt damit als verlässliche Option für nichtstationäre Reihen, die keine ausgeprägten saisonalen Strukturen aufweisen, und liefert gerade bei kurz- bis mittelfristigen Vorhersagen häufig überzeugende Ergebnisse. Allerdings stoßen klassische ARIMA-Modelle an ihre Grenzen, wenn starke saisonale Muster existieren oder externe Einflussgrößen eine wesentliche Rolle spielen. In solchen Fällen kommen erweiterte Varianten wie SARIMA (Seasonal ARIMA) oder ARIMAX (ARIMA mit exogenen Variablen) zum Einsatz. (Cools et al. 2009; Szostek et al. 2024) SARIMA integriert saisonale Differenzierungen sowie zusätzliche Parameter für saisonale Autoregression bzw. Moving-Average-Komponenten, um periodische Schwankungen, wie beispielsweise Feierzeiten oder saisonal bedingte Nachfragespitzen, abzubilden. ARIMAX hingegen erweitert die Zeitreihenstruktur um regressive Elemente, sodass exogene Variablen, wie makroökonomische Indikatoren, Marketing-budgets oder Wetterdaten, in das Modell integriert werden können. Die regressiven Ansätze dienen dazu, Zusammenhänge zwischen externen Faktoren und dem Absatzverhalten offenzulegen, wie im folgenden Kapitel noch einmal vertieft betrachtet wird.

Regressionsmodelle

Regressive Modelle bilden neben glättenden Ansätzen eine weitere wichtige Kategorie statistischer Prognoseverfahren. Anstatt lediglich eine Zeitreihe zu glätten, betrachten sie die Zielgröße y (z. B. Absatz) als Funktion mehrerer Einflussgrößen, darunter sowohl endogene (z. B. historische Absatzwerte) als auch exogene Variablen (z. B. Preisänderungen, Marketingausgaben). (Jadon et al. 2024; Scheer 1983) Damit lassen sich statistische Korrelationen nutzen und komplexe Abhängigkeiten modellieren (Wooldridge 2020). Als klassisches Grundgerüst dient dabei die lineare Regression, bei der ein linearer Zusammenhang zwischen einer oder mehreren unabhängigen Variablen und dem Absatz angenommen wird (Kuhne 2015).

Einfache Lineare Regression

Regressive Modelle gehen davon aus, dass eine Zielgröße durch eine oder mehrere Einflussvariablen beschrieben werden kann. In der einfachen linearen Regression existiert dabei nur eine solche Einflussvariable (Frost 2018). Man nimmt an, dass der Absatz über eine Gerade in Abhängigkeit von der Zeit oder einer anderen Variablen dargestellt werden kann, während alle nicht erklärbaren Effekte in einem Störterm zusammengefasst sind. (Gansser und Krol 2015) Damit das Modell verlässliche Ergebnisse liefert, sollte dieser Störterm weder systematisch verzerrt sein noch eine uneinheitliche Streuung aufweisen. (Frost 2018) Zudem eignet sich die einfache lineare Regression vor allem für Fälle, in denen keine komplexen Muster wie saisonale Peaks oder starke Nichtlinearitäten auftreten. (Holmes und Rinaman 2014)

Multiple Lineare Regression

Erfordert die Realität mehr als nur einen Einflussfaktor – zum Beispiel Preis, Werbebudget und Trendindikatoren –, kommt die multiple lineare Regression ins Spiel. Hier wird die Regressionsgerade um zusätzliche erklärende Variablen erweitert (Marill 2004). Dabei gilt: Jede neue Variable hat einen eigenen Koeffizienten, der ihren Einfluss auf den Absatz abbildet (Rivera 2020). Ein zentrales Problem kann jedoch auftreten, wenn mehrere Einflussvariablen stark untereinander korrelieren (Shrestha 2020). Dies erschwert eine saubere Schätzung der einzelnen Effekte. Dennoch ist die multiple Regression eine bewährte Methode, wenn man mehrere potenzielle Einflussgrößen berücksichtigen muss, um den Absatz verlässlich zu prognostizieren (Holmes und Rinaman 2014).

Regression mit Regularisierung

In vielen Fällen ergänzen moderne Verfahren die klassische Regression um Regularisierungskonzepte, bei denen hohe oder übermäßig komplexe Schätzwerte für die Koeffizienten „bestraft“ werden (Konzen und Ziegelmann 2016; Hoerl und Kennard 2000). Dazu zählen:

- Ridge-Regression, in der alle Koeffizienten gleichmäßig verringert werden (Hastie et al. 2009)
- LASSO (Least Absolute Shrinkage and Selection Operator), wobei manche Koeffizienten auf Null reduziert werden und dadurch eine automatische Variablenauswahl ermöglicht wird (Tibshirani 1996)

Diese Techniken beugen Überanpassung (Overfitting) vor, indem sie die Flexibilität des Modells begrenzen und nur die wirklich relevanten Einflussgrößen behalten (Tibshirani 1996). Das ist besonders wertvoll, wenn viele potenzielle Variablen vorliegen, aber unklar ist, welche tatsächlich relevant sind.

Regressive Verfahren erlauben es, sowohl historische Daten (endogen) als auch externe Faktoren (exogen) in die Prognose einzubeziehen. Einfachere Varianten wie die lineare Regression eignen sich für eher stabile Datenlagen, während multiple oder regularisierte Modelle sinnvoll sind, wenn viele potenzielle

Einflussvariablen oder komplexe Zusammenhänge bestehen. So lassen sich robuste, anwendungsorientierte Vorhersagen erstellen, die über rein glättende oder univariate Zeitreihenansätze hinausgehen.

Maschinelle Lernverfahren zur Absatz- und Bedarfsprognose

Zur Umsetzung der AB-Prognose wird im Forschungsvorhaben eine Kombination aus qualitativen und quantitativen Prognoseverfahren angestrebt, die unter Einsatz von ML-Verfahren durchgeführt werden sollen. Die oft guten Datengrundlagen in Logistikketten (Quante 2009) werden dabei mit zusätzlich nutzbaren Datenquellen qualitativer und quantitativer Art kombiniert. Die im Forschungsvorhaben verfolgte Entwicklung und Nutzen von Verfahren zur Absatz- und Bedarfsprognose basiert auf dieser Erweiterung verfügbarer Datenquellen. Da die anfallenden Datenmengen aufgrund von Umfang und inhärenter Komplexität in der Regel manuell nicht wirtschaftlich auswertbar sind, wird der Einsatz von ML-Verfahren zur effizienten Auswertung und Nutzung des impliziert vorhandenen Wissens angestrebt (Eickelmann et al. 2015). Der Terminus "Wissensentdeckung in Datenbanken" (engl. Knowledge Discovery in Databases, KDD) bezeichnet den Prozess der Analyse und Auswertung umfangreicher Datenbestände (Fayyad et al. 1996). KDD umfasst alle nicht-trivialen Maßnahmen zur Identifikation validier, neuartiger, potenziell nützlicher und schlussendlich verständlicher Muster in vorhandenen Daten und greift dabei auf Verfahren aus verschiedenen wissenschaftlichen Disziplinen zurück, wobei ML und Statistik zu den wichtigsten Vertretern zählen (Hand 2003). ML ist demnach eine Teildisziplin der sogenannten Künstlichen Intelligenz. Im Folgenden werden einige Verfahren kurz vorgestellt.

Neuronale Netze im Kontext Deep Learning

Ein zunehmend vielversprechender Ansatz zur Prognose von Zeitreihen sind neuronale Netze im Rahmen des Deep Learning, welche über die letzten Jahrzehnte hinweg in Bereichen wie Bild- und Spracherkennung, selbstfahrenden Systemen oder der Computerspielindustrie maßgebliche Fortschritte erzielt haben (Makridakis et al. 2018). Der entscheidende Vorteil liegt in der Fähigkeit dieser lernenden Algorithmen, auch nicht-lineare und komplexe Datenmuster zu erfassen, ohne dabei stark auf vorgegebene Modellannahmen angewiesen zu sein. Auf diese Weise können neuronale Netze verdeckte Abhängigkeiten in umfangreichen Datensätzen identifizieren, was gerade für Prognosen mit hochgradig variablen oder schwer einschätzbareren Absatzverläufen von großem Nutzen ist (Smyl 2020).

Innerhalb des Deep Learning gelten insbesondere Recurrent Neural Networks (RNN) als leistungsstarke Modellarchitekturen, sobald es um zeitliche Abhängigkeiten geht. Ein RNN ist ein neuronales Netzwerk, das Ausgaben eines Zeitschritts in den darauffolgenden Schritt zurückführt, um kontextuelle Informationen über die Zeit hinweg zu speichern (Goodfellow et al. 2016) (siehe Abbildung 2). Dadurch können RNNs Muster in sequentiellen Daten erkennen und Abhängigkeiten in zeitlich angeordneten Eingaben modellieren.

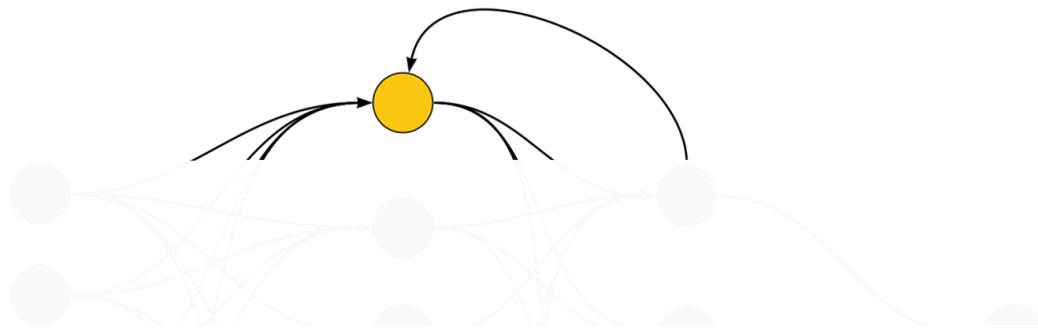


Abbildung 2: Grundaufbau eines RNN (Das 2024)

Unter ihnen haben sich die Long Short-Term Memory (LSTM)-Netzwerke etabliert, bei denen rückgekoppelte Schichten ein internes Gedächtnis implementieren (Hochreiter und Schmidhuber 1997b; Kruse et al. 2015). Dieses Gedächtnis erlaubt den Modellen, Informationen über längere Sequenzen hinweg zu erhalten und dadurch wiederkehrende Muster oder saisonale Effekte in den Daten präziser abzubilden (Salehinejad et al. 2018). Ein konkretes Fallbeispiel liefert eine Kooperation mit Walmart, in der LSTM-Netze genutzt wurden, um nichtlineare Interdependenzen zwischen Produktsortimenten auf unterschiedlichen Hierarchieebenen zu erfassen. Die LSTM-Ansätze erzielten dort höhere Prognosegüten als klassische Verfahren wie ARIMA (Bandara et al. 2019).

Neben LSTM sind Gated Recurrent Units (GRU) ein weiterer wichtiger Vertreter rekurrenter Netze. GRU verzichten auf den aufwendigen internen Speicher von LSTM und kommen daher mit einem geringeren Ressourcenbedarf sowie einer geringeren Anzahl zu erlernender Parameter aus (Cho et al. 2014). Gerade in Umgebungen mit begrenzter Rechenkapazität oder bei sehr großen Datensätzen kann dies ein wesentlicher Vorteil sein. Empirische Studien bestätigen die Eignung von GRU-Netzen für Absatzprognosen, beispielsweise im Supply Chain Management: In einer Studie weisen GRU-Modelle im Vergleich zu LSTM rund 2,36 % geringere mittlere quadratische Fehler auf und übertreffen ARIMA sogar um 15,70 % (Noh et al. 2020).

Diese Erkenntnisse verdeutlichen, dass tiefe rekurrente Netze – sei es in Form von LSTM oder GRU – gegenüber traditionellen statistischen Zeitreihenverfahren in zahlreichen Fällen signifikante Verbesserungen in der Prognosegüte erreichen können. Dies gilt besonders dann, wenn Datensätze ausgeprägte Nichtlinearitäten, langanhaltende Abhängigkeiten oder saisonal stark schwankende Strukturen aufweisen. Gleichzeitig ist zu beachten, dass diese Modelle einen ausreichend großen Datenumfang und eine adäquate hyperparametrische Abstimmung erfordern, um ihr volles Potenzial in der Absatzprognose zu entfalten.

Baumbasierte Verfahren

Baumbasierte Verfahren gewinnen in der Prognosepraxis zunehmend an Bedeutung, da sie starke nichtlineare Zusammenhänge und komplexe Interaktionen in Daten erfassen können, ohne auf formale Verteilungsannahmen angewiesen zu sein. Anders als klassische Regressions- oder Zeitreihenmodelle, bei denen die Beziehung zwischen Eingangs- und Zielvariablen häufig linear oder zumindest vorab hypothesengeleitet ist, zerlegen baumbasierte Methoden wie etwa Random Forest (Breiman 2001), Gradient Boosting (Friedman 2001) oder die darauf aufbauenden Algorithmen XGBoost (Chen und Guestrin 2016) und LightGBM (Ke et al. 2017) die Daten schrittweise in Entscheidungsknoten (Blätter). So entstehen immer homogener werdende Teilräume, innerhalb derer eine Vorhersage – z. B. ein Durchschnittswert – getroffen wird (Breiman et al. 1984). Das macht diese Ansätze robust gegenüber Ausreißern und extrem anpassungsfähig an verschiedenste Datenarten.

Ein Random Forest besteht aus einer Vielzahl unabhängig trainierter Entscheidungsbäume, deren Prognosen anschließend gemittelt werden (Breiman 2001) (siehe Abbildung 3). Da jeder Baum nur auf einer zufälligen Stichprobe von Daten und Variablen trainiert wird, entstehen individuell unterschiedliche Strukturierungen. Dieser sogenannte Bagging-Ansatz (Bootstrap Aggregating) verringert das Risiko des Overfitting, das bei einem einzelnen, sehr tiefen Entscheidungsbau häufig auftritt. Vor allem in heterogenen Datensätzen mit vielen potenziellen Einflussgrößen zeigt sich dadurch eine hohe Prognosegüte. (vgl. Probst et al. 2019)

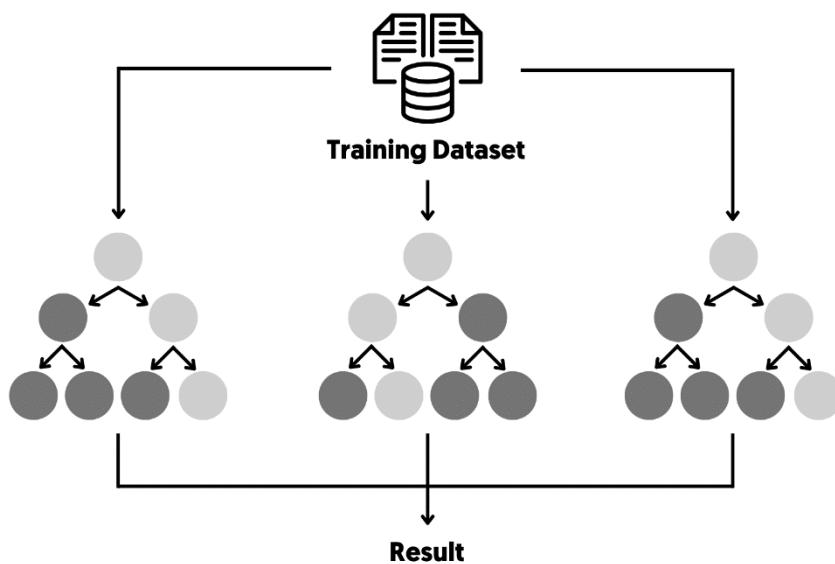


Abbildung 3: Grundidee des Random Forest (dida.do 2024)

Im Gegensatz zum Random-Forest-Verfahren gehen Gradient-Boosting-Methoden (z. B. Gradient Boosted Regression Trees) schrittweise vor, um den Fehler von zuvor erstellten Bäumen weiter zu minimieren (Friedman 2001). Dabei werden jeweils die Residuen aus dem letzten Modell durch einen zusätzlichen Baum vorhergesagt, was die Genauigkeit iterativ steigert. Eine beliebte Implementierung ist XGBoost (Chen und Guestrin 2016) das besonders auf große Datensätze und verteilte Rechenumgebungen ausgelegt ist und dank diverser Hyperparametermöglichkeiten (etwa die Lernrate oder Tiefe der Bäume) in vielen Benchmark-Tests hervorragende Ergebnisse erzielt (Makridakis et al. 2022, 2020).

LightGBM (Ke et al. 2017; Weng et al. 2020) verfolgt dasselbe Grundprinzip des Boostings, optimiert jedoch das Split-Verfahren der Entscheidungsbäume mithilfe spezieller Techniken wie Gradient-based One-Side Sampling (GOSS) und Exclusive Feature Bundling (EFB). Dies reduziert den Rechen- und Speicherbedarf signifikant und ermöglicht den Einsatz von Gradient Boosting auch in Umgebungen, in denen Rechenressourcen begrenzt sind. LightGBM zeichnet sich durch hohe Trainingsgeschwindigkeit, gute Skalierbarkeit und vergleichsweise geringes Overfitting aus.

Zusammenfassung und Bewertung

Die klassischen statistischen Prognoseverfahren – von exponentiellen Glättungsmethoden über ARIMA-Modelle bis hin zu linearen Regressionsansätzen – bilden nach wie vor ein tragfähiges Fundament für die Modellierung unterschiedlicher Absatzdaten. Zeitreihenmodelle (z. B. exponentielle Glättung, ARIMA) fokussieren sich dabei auf interne Muster wie Autokorrelation und Saisonalität, wohingegen Regressionsmodelle (z. B. einfache oder multiple lineare Regression) über exogene Einflussgrößen hinausgehen und damit breitere Informationsquellen nutzen können.

In vielen Anwendungsszenarien stoßen diese klassischen Methoden allerdings an ihre Grenzen – etwa bei stark nichtlinearen Zusammenhängen, sehr großen Datenmengen oder hochvolatilen Nachfrageverläufen. Hier können künstlich-intelligente (KI) Ansätze und moderne ML-Verfahren wie neuronale Netze (z. B. LSTM, GRU) sowie baum-basierte Modelle (z. B. Random Forest, Gradient Boosting) deutliche Vorteile bieten. Diese Methoden sind in der Lage, komplexe Beziehungen – einschließlich versteckter Wechselwirkungen oder saisonal mehrfach verschachtelter Strukturen – abzubilden, ohne strikt auf klassische Modellannahmen (z. B. Stationarität, Linearität) angewiesen zu sein. Eine Übersicht der vorgestellten Verfahren ist in Abbildung 4 zu finden.

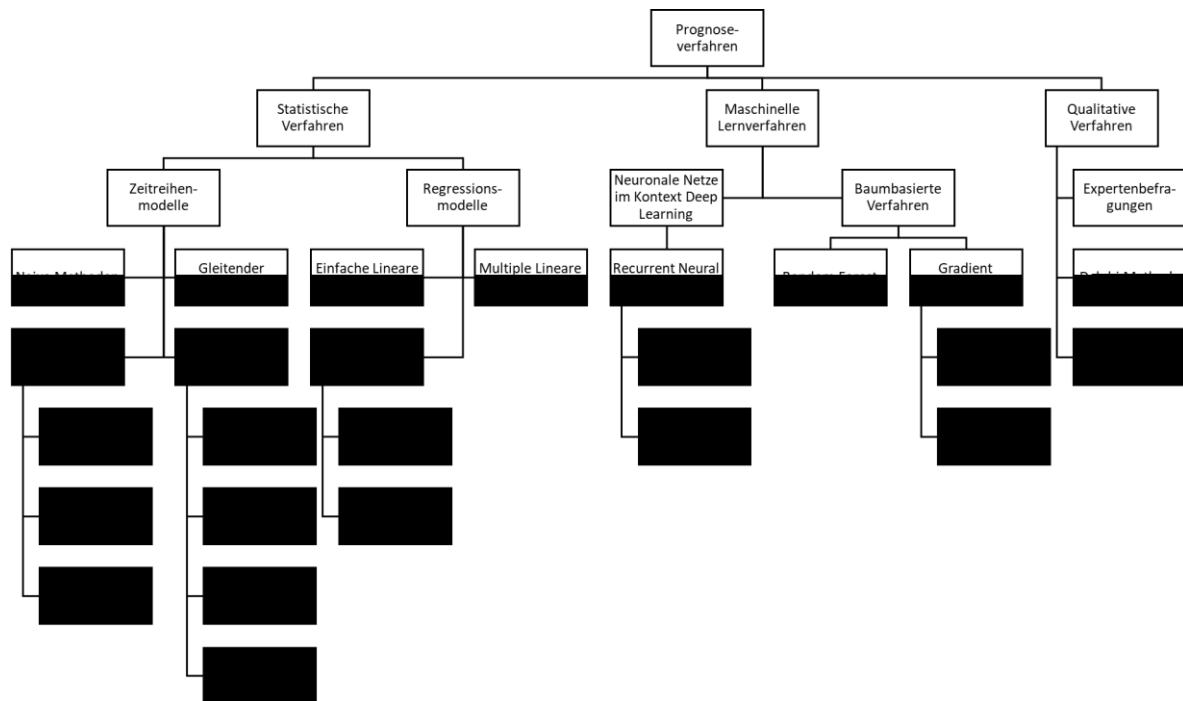


Abbildung 4: Übersicht möglicher Absatzprognoseverfahren

Gleichzeitig steigt mit KI-Verfahren der Bedarf an umfangreichen Datensätzen, hoher Rechenleistung und einem gut durchdachten Hyperparametertuning, um Überanpassungen (Overfitting) zu vermeiden. Überdies

sind die Modelle oft weniger transparent, weshalb in der Praxis Aspekte wie Erklärbarkeit und Akzeptanz besonders wichtig werden. Die Entscheidung für ein bestimmtes Prognosemodell hängt daher maßgeblich von Datenverfügbarkeit, Komplexität der Nachfrage und betrieblichem Ressourcenrahmen ab. Die Vielfalt der vorhandenen Methoden erlaubt es Unternehmen jedoch, eine bedarfsgerechte Kombination auszuwählen, die von einfachen, robusten statistischen Ansätzen bis zu hochflexiblen KI-Verfahren reicht. In der betriebswirtschaftlichen Praxis entscheidet häufig die Datenlage (z. B. Verfügbarkeit externer Einflussgrößen oder Vorhandensein saisonaler Effekte), welche Modellfamilie den größten Nutzen verspricht (Hyndman und Athanasopoulos 2018).

Um die Qualität der erstellten Vorhersagen zu beurteilen, kommen in der Regel Fehlermaße zum Einsatz, die den Unterschied zwischen tatsächlichem und prognostiziertem Wert quantifizieren (Hyndman und Koehler 2006). Drei verbreitete Metriken sind beispielsweise:

1. Mean Absolute Error (MAE)

$$\text{MAE} = \frac{1}{n} \sum_{t=1}^n |y_t - \hat{y}_t|$$

Diese Metrik misst die durchschnittliche absolute Abweichung und ist leicht interpretierbar, da sie in derselben Einheit wie die Absatzdaten angegeben wird. Ein geringer MAE deutet darauf hin, dass die Prognosen dem tatsächlichen Verlauf im Schnitt recht nahekommen.

2. Root Mean Square Error (RMSE)

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{t=1}^n (y_t - \hat{y}_t)^2}$$

Indem große Fehler durch das Quadrieren stärker gewichtet werden, zeigt die RMSE besonders empfindlich auf, wenn ein Modell gelegentlich stark daneben liegt. In Szenarien, bei denen Ausreißer große Kosten verursachen, ist dies ein sinnvoller Indikator (Hyndman und Athanasopoulos 2018)

3. Symmetric Mean Absolute Percentage Error (sMAPE)

$$\text{sMAPE} = \frac{100\%}{n} \sum_{t=1}^n \frac{|y_t - \hat{y}_t|}{\frac{|y_t| + |\hat{y}_t|}{2}}$$

Anders als das klassische MAPE gewichtet sMAPE Über- und Unterschätzungen symmetrisch, sodass die Metrik auch bei stark schwankenden Absatzwerten oder Werten nahe null besser einsetzbar ist. (Kreinovich et al. 2014)

Der Einsatz dieser Kennzahlen ermöglicht es, verschiedene Prognoseansätze systematisch zu vergleichen und deren Stärken bzw. Grenzen zu erkennen. Modelle mit gutem MAE oder RMSE schneiden nicht zwangsläufig

beim sMAPE ähnlich gut ab, sodass Unternehmen je nach Zielsetzung (z. B. Minimierung großer Ausreißer vs. zuverlässige Vorhersagen im Mittel) unterschiedliche Metriken priorisieren sollten. (vgl. Chai und Draxler 2014) Insgesamt zeigt sich, dass jede Modellfamilie – ob klassische Zeitreihen- oder Regressionsverfahren – einen bestimmten Anwendungsrahmen aufweist. Werden die Prognosefehler mithilfe der genannten Gütekriterien transparent gemacht, können Unternehmen fundiert entscheiden, welches Verfahren ihre Anforderungen am besten erfüllt.

2.3 Softwarelösungen im Bereich der Absatz- und Bedarfsprognose für kundenauftragsorientiert fertigende Unternehmen

Neben den in Kapitel 2.2 beschriebenen Verfahren und generischen Prognosemethoden existieren am Markt bereits diverse Softwarelösungen, die Unternehmen bei der Erstellung von Absatz- und Bedarfsprognosen unterstützen. Allerdings zeigt sich bei näherer Betrachtung, dass die meisten dieser Angebote eher auf lagerorientierte Produktionsstrategien – wie Make-to-Stock (MTS) – zugeschnitten sind und selten explizit die Bedürfnisse der kundenorientierten Auftragsfertigung adressieren. So lassen sich individualisierte Produkte oder stark schwankende Bedarfsverläufe mit Standardsoftware häufig nur durch teils aufwendige Beratungsprojekte oder Customizing abbilden.

Tabelle 1: Softwareanbieter für Absatz- und Bedarfsprognosen (initiale Recherche)

System	Domäne	Datenquellen	Prognoseverfahren
Westphalia Forecast, Westphalia Datalab	Produktion, Handel, Mode, Supermarkt	u.a. Produktions-, Umwelt-, Bestands-, Kunden-, Betriebs-, Verkaufs-, Auftragsdaten	Nicht näher spezifizierte ML-Verfahren
Relex, Living Retail Plattform	Handel, Pharma, Convenience	u.a. interne Handelsdaten, Wetter, Events, Feiertage, Lieferantendaten	Kombination aus ML-Algorithmen und statistischen Verfahren (unspezifiziert)
Datasolut	Marketing/CRM: Mobilfunk, Digital	Absatz, Lagerbestand, Umsatz, Ferien, Preise, Wetter, Marketingaktionsdaten	u.a. Exponentielle Glättung, ARIMA, Zeitreihenregression, Deep Learning
Smartcorp, smart ip&o	Industrie, Food, Pharma	sozialökonomisch, Wetter, Absatzdaten, speziell e-Commerce	>25 ML-Verfahren sowie über 50 statistische Verfahren,
Intuendi	Produktion, E-Commerce, Mode	u.a. Produktdaten, Absatzzahlen, Werbedaten, Bestelldaten	Proprietäre Algorithmen und statistische Methoden
sedapta	divers	allg. Nennung von Produktionsdaten, SC-Daten, Absatzzahlen, etc.	Bibliothek an Algorithmen, automatischer Best-Fit-Ansatz für passende Methode
Quantum	Drogerie, Nahrung, Konsumgüter	u.a. SAP, DATEV, MS Navision	Keine spezifischen Angaben
Lokad	divers	U. a. ERP; MRP, WMS	u.a. Deep Learning, Probabilistische Prognosen, Quantitabellen & -prognosen

Tabelle 1 bietet eine erste Übersicht zu etablierten Anbietern von Prognosesoftware. Sie illustriert, in welchen Domänen die Lösungen vorzugsweise eingesetzt werden, welche Datenquellen typischerweise berücksichtigt werden und welche Prognoseverfahren zum Einsatz kommen.

Darüber hinaus gibt es weitere Lösungen, die in großen Konzernen oder im Bereich Serienfertigung weit verbreitet sind und teils Elemente enthalten, die sich an Auftragsfertiger anpassen lassen:

SAP IBP (Integrated Business Planning): Umfasst Module für Demand Planning, Supply Planning und S&OP. Stützt sich auf statistische Verfahren und ML-Algorithmen, verlangt aber oft eine sehr umfangreiche Systemintegration, die sich bei KMU mit rein kundenindividuellen Produkten nicht immer rechnet.

Oracle Demand Management: Bietet eine breite Palette an Forecasting-Methoden (einschließlich ML) und eine starke Einbindung in das ERP-Ökosystem. Vor allem in Serienfertigungen mit gut strukturierten Stücklisten zeigt das System Stärken, während spontane Kundenaufträge mit hoher Varianz zusätzliche Konfiguration verlangen.

Kinaxis RapidResponse: Fokussiert auf komplexe Supply-Chain-Szenarien und S&OP-Prozesse. Dank einer leistungsstarken In-Memory-Technologie können Prognosen sehr schnell aktualisiert werden. Allerdings sind Lizenzen und Implementierungskosten oft hoch, was den Einsatz bei kleineren Auftragsfertigern erschwert.

ToolsGroup SO99+: Legt den Schwerpunkt auf Demand & Supply Planning und integriert ML-Verfahren für Bestandsoptimierung und Absatzprognose. Auch hier ist die Kernzielgruppe eher im größeren Mittelstand bzw. Konzernumfeld angesiedelt, während reine Auftragsfertiger zusätzliche Anpassungen vornehmen müssen.

Forecast Pro (Business Forecast Systems): Ein auf Zeitreihenverfahren spezialisiertes Tool mit Schwerpunkt auf statistischen Standardmodellen und umfassenden Automatisierungsfeatures. Insbesondere für KMU kann es eine Einstiegslösung sein, um Prognosen zu erstellen, sobald die Daten relativ stabil vorliegen.

Die Analyse dieser Softwareangebote verdeutlicht, dass typische Prognoseszenarien - wie die in Abschnitt 2.1 dargestellten stationären, trendartigen, saisonalen oder sporadischen Bedarfsprofile - grundsätzlich beherrscht werden. Für kundenauftragsorientierte Produktionen (Make-to-Order, Configure-to-Order) hingegen gibt es meist keine explizite Standardfunktionalität, stattdessen müssen Unternehmen auf Beratungsleistungen und Anpassungen zurückgreifen. Während Anbieter wie Westphalia Forecast auch im Bereich variantenreicher Fertigung beratend tätig sind, fehlt hier oft eine durchgängige Standardlösung, die z. B. die sporadische, kundenindividuelle Nachfrage regelbasiert integriert.

2.4 Forschungslücken aus den Erkenntnissen des Stands der Technik und Wissenschaft

Aus der Darstellung der bestehenden Verfahren in den vorangegangenen Kapiteln wird deutlich, dass Absatz- und Bedarfsprognosen für die kundenorientierte Auftragsfertigung bislang nur unzureichend adressiert werden. Obwohl Unternehmen bereits eine Vielzahl statistischer, heuristischer und ML-basierter Methoden einsetzen, lassen sich mehrere Forschungslücken identifizieren, die den Bedarf an erweiterten Konzepten und Werkzeugen unterstreichen. Diese beziehen sich unmittelbar auf die zum Start von PrABCast formulierten Arbeitshypothesen:

1. Eignung klassischer Prognosemodelle für variantenreiche Auftragsfertigung fraglich

Die meisten traditionellen Methoden (z. B. exponentielle Glättung, ARIMA) sind primär auf homogene oder kontinuierliche Daten zugeschnitten und stoßen bei hochgradig individualisierten Produkten, unregelmäßigen Nachfragespitzen oder sporadischen Bestellungen an ihre Grenzen (vgl. Stärk 2011; vgl. Schuh et al. 2014a). Gerade kleine Losgrößen und eine hohe Produktvielfalt, wie sie für die Auftragsfertigung typisch sind, erfordern flexiblere und robustere Prognosemodelle. (*AH3: Durch die Adaption verfügbarer ML-Verfahren und einer Anreicherung um qualitative und quantitative Datenquellen können zuverlässige Absatz- und Bedarfsprognosen in kundenorientierten Auftragsfertigung getroffen werden*)

2. Unzureichende Nutzung zusätzlicher Datenquellen

In vielen Unternehmen bleiben potenzielle Datenquellen – etwa Lieferantendaten, Kundenportale, externe Marktdaten oder qualitative Einschätzungen aus dem Vertrieb – weitgehend ungenutzt (Buchholz et al. 2017). Dadurch gehen wertvolle Informationen für die Prognose verloren, zumal moderne ML-Verfahren durchaus in der Lage sind, heterogene und hochdimensionale Daten zu verarbeiten. (*AH 1: Neben einsatzbereiten Quellen existieren unerschlossene (Daten-)Potentiale für Absatz- und Bedarfsprognosen.; AH 2: Durch eine Bewertung und Kombination aller möglichen Datenquellen werden neue Einsatzbereiche erschlossen.*)

3. Mangelnde Passgenauigkeit kommerzieller Tools für kundenindividuelle Produktionen

Während es für lagerfertigende Branchen zahlreiche Softwarelösungen gibt (z. B. für den Handel oder die Fashion-Industrie), fehlen in der kundenorientierten Auftragsfertigung vergleichbar spezialisierte Softwarelösungen. Stattdessen werden häufig generische Module angeboten, die sich zwar anpassen lassen, aber nicht explizit auf sporadische oder hoch variable Bedarfsstrukturen zugeschnitten sind. (Meredith und Akinc 2007; Akinc und Meredith 2015) (*AH3: Durch die Adaption verfügbarer ML-Verfahren und einer Anreicherung um qualitative und quantitative Datenquellen können zuverlässige Absatz- und Bedarfsprognosen in kundenorientierten Auftragsfertigung getroffen werden*)

4. Fehlender Fokus auf Erklärbarkeit (Explainable AI)

KI-Verfahren, insbesondere tiefe neuronale Netze (LSTM, GRU) oder baum-basierte Modelle (Random Forest, Gradient Boosting), erzielen teils höhere Prognosegüten als klassische Ansätze (Bandara et al. 2019; Noh et al. 2020). Allerdings sind sie oft nur schwer interpretierbar. In der Praxis – insbesondere in KMU – führt diese Intransparenz zu Akzeptanzproblemen, da Anwender die Resultate nicht nachvollziehen können (Bathaee 2018; WIK 2019). Ein Mangel an erklärenden Werkzeugen und Schnittstellen erschwert daher den breiten Einsatz. (*AH 5: Durch hohe Nachvollziehbarkeit und Transparenz von Modellaussagen wird die Nutzungsreichweite gesteigert.*)

5. Hoher Implementierungsaufwand für KMU

Viele KMU verfügen weder über ausreichende IT-Ressourcen noch über das nötige Datenanalyse-Know-how, um aufwendige Prognoseverfahren (z. B. Deep Learning oder komplexe Ensemble-Verfahren) im eigenen Betrieb zu implementieren (BMWi 2015). Fehlende Einsteigerfreundlichkeit und mangelnde automatisierte Unterstützung bei Datenerfassung, -aufbereitung und Modellwahl hemmen den Technologieeinsatz. (*AH 6: Durch die Umsetzung der Methodik in einem IT-Werkzeug können KMU ML-Verfahren ohne Vorkenntnisse anwenden, wodurch Vorbehalte und Barrieren zu Datengenerierung, -aufbereitung und -verarbeitung abgebaut werden.*)

6. Fehlende Generalisierungskonzepte

Gerade in variantenreichen Umgebungen existiert eine Vielfalt an Produkten und Bedarfsprofilen. Zwar finden sich erste ML-Lösungen für eng definierte Teilbereiche, jedoch fehlen generalisierte Modellierungsansätze, die sich auf ähnliche Produktgruppen oder andere Branchen mit vergleichbaren Datenstrukturen übertragen lassen, ohne jedes Mal den kompletten Trainings- und Anpassungsprozess von Grund auf durchlaufen zu müssen (Akinc und Meredith 2015). (AH 4: *Eine Generalisierung durch charakteristische Produktmerkmale kann den Verlauf der Modellbildung unterstützen.*)

Diese Lücken bekräftigen den Forschungsbedarf, die in Kap. 2.2 beschriebenen klassischen und KI-basierten Prognoseansätze zu erweitern, anzureichern und an die Auftragsfertigung anzupassen. Im Forschungsprojekt PrABCast wurden diese Forschungslücken und Arbeitshypothesen adressiert und eine Lösung entwickelt, die Absatzdaten kundenauftragsorientiert fertigender Unternehmen effizient prognostiziert, während zugleich Erklärbarkeit und Benutzerfreundlichkeit gewährleistet sind.

3 Durchgeführte Arbeiten und Ergebnisse

Im folgenden Kapitel werden die methodische Vorgehensweise und die durchgeführten Arbeiten im Projekt beschrieben. Nach einer kurzen Einleitung (Abschnitt 3.1) werden die einzelnen Arbeitspakete (AP) im Detail vorgestellt, um den Leserinnen und Lesern einen strukturierten Einblick in Planung, Durchführung und Ergebnisse zu geben. Das Vorgehen orientiert sich dabei eng an den Forschungszielen und greift den Stand der Technik aus Kapitel 2 auf. Zunächst wird ein Überblick über das methodische Vorgehen und die zeitliche Abfolge der Arbeitspakete gegeben. Anschließend folgen die Kapitel zu den einzelnen AP, jeweils mit klarer Trennung von Zielen, methodischer Umsetzung und erzielten Resultaten.

Überblick über das methodische Vorgehen im Forschungsprojekt

Die im Vorhaben verfolgte Methodik zur prädiktiven Absatz- und Bedarfsplanung ist eng an das branchenübergreifende CRISP-DM-Prozessmodell (Cross Industry Standard Process for Data Mining) (siehe Abbildung 5) angelehnt und in mehrere aufeinanderfolgenden Arbeitsschritte unterteilt.



Abbildung 5: Prozessablauf im CRISP-DM (Chapman et al. 1999)

Zu Beginn stand das gemeinsame Geschäftsverständnis im Fokus, bei dem alle relevanten organisatorischen Bedingungen, Anforderungen und Zielsetzungen der beteiligten Unternehmen sowie die übergeordnete Zielstellung des Forschungsvorhabens präzisiert wurden. Dies erfolgte im intensiven Austausch mit dem projektbegleitenden Ausschuss (PA), um Anwenderbedarfe frühzeitig zu erfassen. Anschließend wurden in einer systematischen Potentialanalyse sämtliche Datenquellen identifiziert, die mittel- oder unmittelbar Rückschlüsse auf die künftige Absatz- und Bedarfsentwicklung zulassen.

Aufbauend darauf erfolgte die eigentliche datenanalytische Vorgehensweise: Zunächst wurden die vorhandenen Datenbestände für die Vorhersagemodellierung aufbereitet (z. B. durch Bereinigung, Vereinheitlichung, Feature-Engineering). Im nächsten Schritt wurden die Prognose- und ML-Verfahren konfiguriert, um zunächst einfache Referenzprognosen zu erzeugen (z. B. auf Basis klassischer Regressionsmodelle oder univariater Zeitreihenverfahren). Diese Referenzanalysen dienten als Benchmark, an der anschließend das erweiterte Verfahren mit zusätzlichen, zuvor erschlossenen Datenquellen gemessen werden konnte.

Um unterschiedliche Ausprägungen und Einsatzfelder in der kundenauftragsorientierten Fertigung zu erfassen, wurden parallel mehrere Pilotanwendungen mit Daten von Industriebetrieben aus dem PA durchgeführt. Die Erkenntnisse aus diesen Anwendungsfällen flossen iterativ in die Optimierung der Methoden und der Modellarchitekturen (z. B. durch Anpassen von Netzwerkstrukturen bei tiefen Lernverfahren oder durch Verfeinern der Modell-Features) zurück.

Im vorletzten Arbeitsschritt konzentrierte man sich auf die Übertragbarkeit und Verallgemeinerung der entwickelten Prognosemodelle, indem charakteristische Produkt- oder Kundenmerkmale analysiert und Gruppenbildungen vorgenommen wurden. Darüber hinaus erfolgte eine systematische Einbettung von Maßnahmen zur Steigerung der Modelltransparenz und Erklärbarkeit, um Anwendern den Umgang mit teils komplexen „Black-Box“-Modellen zu erleichtern. Abschließend wurden die gewonnenen Erkenntnisse sowie die entwickelten Verfahren in ein benutzerfreundliches IT-Werkzeug überführt. Dieses Werkzeug soll Unternehmen bei der eigenständigen Anwendung der erarbeiteten Prognosemethodik unterstützen und den Transfer der Projektergebnisse in die betriebliche Praxis sicherstellen.

Dadurch deckt das methodische Vorgehen alle wesentlichen Schritte ab - von der Definition und Priorisierung der Anforderungen über die Auswahl und das Training geeigneter ML-Verfahren bis hin zur Einbettung in die unternehmerischen Abläufe. Dabei stand stets das Ziel im Vordergrund, eine robuste, in mittelständischen Betrieben anwendbare Lösung zu erarbeiten, die einerseits hinreichend genaue Vorhersagen erzeugt und andererseits die Hemmschwelle für die Nutzung datengetriebener KI-Ansätze senkt.

Gleichzeitig wurde im gesamten Projekt explizit Praxisrelevanz über eine *durchgängige, semi-strukturierte Studie* gewährleistet. Durch regelmäßige Workshops und Expertengespräche mit den beteiligten Partnern, bei denen Zwischenergebnisse vorgestellt, bewertet und in den Gesamtzusammenhang eingeordnet wurden, konnte dies sichergestellt werden. Begonnen mit der ersten Sitzung des PA (Phase 1 der Studie) zur Erhebung erster Anforderungen, weitergeführt mit (Phase 2) Expertendiskussionen mit Entwicklungspartnern und Anwenderunternehmen, diente die (3) Umfragestudie (siehe Kapitel 5.2) der detaillierten Aufnahme aller Kriterien und Anforderungen, die in der Praxis bestehen, sowie der Erhebung der Einschätzung der Praxis zum Potential möglicher Datenanreicherungen. Die Ergebnisse aus (1,2,3) wurden in der (4) zweiten Sitzung des PA diskutiert und um wertvolle Beiträge ergänzt (siehe Ergebnis 5.2.2). Danach wurde über mehrere Austauschtermine (5) gemeinsam mit der mosaiic GmbH an einem UX/UI-Konzept gearbeitet, welches in der dritten PA-Sitzung (6) mit den Anwendern im Rahmen eines Designworkshops per Pen & Paper-Methode

detailliert wurde. Die vierte Sitzung des PA (7) diente der Vorstellung des finalen IT-Werkzeuges und der letzten Diskussion zum Feinschliff zur Integration der Lösung in den Betrieben.

3.1 Arbeitspaket 1: Erfassung und Bewertung organisatorischer Rahmenbedingungen für prädiktive AB-Planung

In der ersten Phase im CRISP-DM, dem Geschäftsverständnis, wurden die organisatorischen Rahmenbedingungen abgesprochen, Ziele und Anforderungen festgelegt und die Aufgabenstellung präzisiert. Dies wird in AP 1 durch die praxisbezogenen Interessen aus dem PA und die technischen Rahmenbedingungen der ML-Verfahren sichergestellt.

In Teilarbeitspaket (TAP) 1.1 wurden in einem Kickoff-Workshop gemeinsam mit den Projektpartnern die systemischen Anforderungen der Auftragsfertigung sowie potenzielle Prognoseverfahren aus der Literatur erfasst und diskutiert. Dabei lag der Fokus darauf, die praxisorientierten Bedarfe in konkrete, datenanalytische Aufgabenstellungen zu übersetzen und diese durch Gewichtung und Priorisierung – etwa in Form von Muss- und Soll-Forderungen – für die weitere Projektarbeit aufzubereiten.

Im folgenden TAP 1.2 wurde aufbauend auf den zuvor identifizierten Anforderungen (TAP 1.1) eine detaillierte Bewertung und Gewichtung der für die AB-Planung relevanten Kriterien vorgenommen. Darüber hinaus erfolgte eine Klassifizierung potenzieller Anwendergruppen, um die Einsatzmöglichkeiten verschiedener Prognoseverfahren zielgerichtet zu bestimmen. Insbesondere wurden Kriterien wie Datenverfügbarkeit, Komplexität der Bedarfsstruktur sowie erforderliche Prognosegenauigkeit herangezogen, um geeignete Methoden – unter anderem ARIMA, neuronale Netze und hybride Verfahren – differenziert zu bewerten und zu priorisieren. Die Ergebnisse dienten als Grundlage für die weitere Auswahl und Anpassung der Verfahren an unterschiedliche Anwendungsfälle in der kundenorientierten Auftragsfertigung.

Die Aufteilung der Teilergebnisse der TAP erfolgt strukturiert nach zu Beginn des Projekts formulierten **Zielen, dem Vorgehen und den Ergebnissen**.

Teilergebnisse im Rahmen des Arbeitspaketes 1

Recherche & Auflistung der Prognoseverfahren sowie deren Gewichtung

Ziel: Recherche & Auflistung der Prognoseverfahren, Gewichtung

Vorgehen: Die Recherche der Prognoseverfahren ist durch eine detaillierte Übersicht der Verfahren umgesetzt (siehe Anhang 1). Diese Übersicht ist Ergebnis einer fundierten Literaturrecherche. Die Basis bildeten dabei zwei Sammelpublikationen im Themenbereich:

Cadavid et al. (2018) bieten in ihrer Übersicht einen umfassenden Überblick über moderne Ansätze im ML-Bereich für Demand- und Sales Forecasting. Ingle et al. (2021) erarbeiteten einen umfassenden Überblick zur Nachfrageprognose, indem sie systematisch klassische statistische Modelle, ML- sowie hybride Ansätze zur Nachfrageprognose darstellen. Ausgehend von diesen Übersichtsarbeiten wurden Grundlagen- und Anwenderpublikationen zur Recherche herangezogen. Die zentralen Ansätze wurden im Stand der Technik dieses Berichts aufgeführt (siehe Kapitel 2.1).

Ergebnisse: Die tabellarische Übersicht bietet eine strukturierte Übersicht zu den gängigen Prognoseverfahren und fasst deren zentrale Eigenschaften in mehreren Attributen zusammen. Neben dem **Namen** und bekannten **Kürzel des Verfahrens** wird die **Kategorie, Art, Klassifizierung und Detailkategorisierung** der

Modelle genannt, die **Art und Anzahl der genutzten Datenquellen** beschreiben, eine kurze Beschreibung des Verfahrens angeführt sowie wesentliche **Formeln** und **Quellen** dargestellt.

Während Name und Kürzel vor allem der klaren Bezeichnung der Verfahren dient, sind die anderen Kategorien unterschiedlich ausgeprägt und dienen unterschiedlichem Zweck.

Kategorie: Dieses Attribut unterscheidet grob zwischen *qualitativen* und *quantitativen* Verfahren. Die Unterscheidung ermöglicht eine erste, grundlegende Einordnung, ob das Verfahren eher auf Expertenwissen, subjektiven Einschätzungen und Workshops beruht (qualitativ) oder auf messbaren, meist numerischen Daten (quantitativ).

Art: Hier wird die Kategorie spezifiziert und definiert, ob es sich beispielsweise um ein *statistisches Verfahren*, ein *Machine-Learning-Verfahren* oder ein *Deep-Learning-Modell* handelt. Diese Feingliederung macht deutlich, aus welchem methodischen „Werkzeugkasten“ das Prognoseverfahren stammt und welche theoretischen Grundlagen (z. B. klassische Statistik vs. neuronale Netze) dem Modell zugrunde liegen.

Klassifizierung: Die Klassifizierung vertieft die Art-Einteilung, indem sie präzisiert, ob das Verfahren etwa zeitreihenbasiert, regressiv, baumbasiert, ensemblebasiert, iterativ, etc. ist. Dadurch wird klar, wie das Verfahren arbeitet (z. B. Regressionsmodelle, Entscheidungsbäume, Glättungsverfahren), was bei der Auswahl des geeigneten Prognoseverfahrens hilft.

Detailkategorisierung: Diese erweiterte Einordnung ermöglicht eine noch gezieltere Auswahl und Kombination von Verfahren, da zu erkennen ist, auf welche Besonderheiten das jeweilige Modell ausgelegt ist (z. B. Saison-Effekte, Volatilitätsmodelle, Rekurrenz).

Art der Datenquellen: Diese Spalte gibt an, ob ein Verfahren univariate oder multivariate Daten benötigt, ob es qualitativ-subjektive Einschätzungen einbezieht oder ob exogene Faktoren berücksichtigt werden können. Auf diese Weise wird transparent, welche Datenbasis vorausgesetzt wird (z. B. nur historische Absatzdaten oder auch Wetterinformationen, Preisentwicklungen etc.). Das erleichtert die Einschätzung, ob das Verfahren für die jeweils vorliegende Datenlage geeignet ist.

Anzahl der Datenquellen: Hier wird konkretisiert, wie viele verschiedene Datenströme bzw. Variablen ein Verfahren typischerweise verarbeiten kann oder sollte (z. B. „1 (Zeitreihe)“ oder „Mehrere Zeitreihen“). Diese Angabe schafft Klarheit darüber, ob ein Modell lediglich mit einer einzelnen Zeitreihe (univariat) oder mit mehreren parallelen Datenquellen (multivariat) umgehen kann – ein wichtiger Aspekt bei komplexen Prognoseaufgaben mit vielen Einflussfaktoren.

Beschreibung des Verfahrens: In dieser Spalte findet sich eine knappe, aber prägnante Erläuterung des jeweiligen Verfahrens, inklusive typischer Einsatzgebiete und zentraler Annahmen. Die Kurzbeschreibung dient dazu, die wesentliche Funktionsweise verständlich zu machen, ohne dass eine unmittelbare Einarbeitung in die vollständige Fachliteratur nötig ist.

Formel: Diese Spalte enthält die maßgebliche mathematische Formel (oder eine vereinfachte Variante), die das Verfahren charakterisiert. Bei qualitativen Methoden kann sie entfallen. Die Formel zeigt den theoretischen Kern des Verfahrens auf, was insbesondere für statistische oder ML-Ansätze hilfreich ist, um das Modell besser nachvollziehen zu können.

Quellen: Aufgeführt sind wichtige Publikationen und Autoren, die das jeweilige Verfahren theoretisch fundieren oder in Fallstudien empirisch angewandt haben. Durch die Quellenangaben wird die wissenschaftliche Grundlage belegt. Außerdem besteht so die Möglichkeit, sich bei Bedarf direkt auf die Originalarbeiten zu beziehen, um vertiefte Informationen zu erhalten.

Die Tabelle strukturiert eine Vielzahl an Prognoseverfahren, indem sie diese in den oben genannten Spalten charakterisiert. Damit entsteht ein kompaktes, übersichtliches Nachschlagewerk, das sowohl die grundsätzliche Einteilung (qualitativ vs. quantitativ, statistisch vs. ML usw.) als auch spezielle Eigenschaften (z. B. Formeln, Datenanforderungen) sichtbar macht. Diese Übersicht erleichtert es, je nach Anwendungsfall oder Datenlage rasch zu identifizieren, welche Verfahren in Frage kommen und welche eher ungeeignet sind. Die tabellarische Übersicht ist außerdem in das finale IT-Tool eingebunden und schafft so Transparenz für den Anwender.

Im Rahmen der Prognoseverfahren wurde eine systematische Gewichtung vorgenommen, die zwei Analysen umfasste:

Literaturrecherche und Vergleich von Case Studies: Basierend auf der Literaturrecherche der Verfahren wurden zunächst theoretische Bewertungskriterien identifiziert, die in der Fachliteratur für Prognoseverfahren als zentral gelten. Ergänzt wurde diese qualitative Analyse durch den Vergleich mehrerer Case Studies, in denen praxisrelevante Kennzahlen (wie MAPE, MSE) sowie qualitative Aspekte (z. B. Interpretierbarkeit, Rechenaufwand) dokumentiert wurden. Dieser Teil der Untersuchung ermöglichte es, die Stärken und Schwächen klassischer Modelle (etwa ARIMA, exponentielle Glättung, Holt-Winters) und moderner Ansätze (z. B. SVR, Random Forest, XGBoost) differenziert zu betrachten und erste Gewichtungen auf theoretischer und praxisnaher Basis abzuleiten. (siehe Anhang 2)

Eigene empirische Evaluation auf Basis univariater Beispieldaten: Ergänzend zur Literaturrecherche wurde eine eigenständige empirische Untersuchung durchgeführt, bei der verschiedene Prognoseverfahren auf univariaten, historischen Einzelhandelsdaten getestet wurden. Hierbei wurden die Modelle hinsichtlich ihrer Prognosegenauigkeit, Robustheit und Effizienz anhand standardisierter Fehlermaße bei verschiedenen Absatzverläufen bewertet. Eine hohe Bewertung bedeutete dabei eine vergleichsweise geringe Abweichung von den Testdaten. Gleichzeitig wurde der Implementierungsaufwand aus Sicht eines Anwenders in KMU definiert, ein hoher Wert steht hierbei für einen hohen Aufwand. Die gewonnenen Ergebnisse lieferten eine Validierung der in der Literatur und den Fallstudien abgeleiteten Gewichtungen und ermöglichen eine Feinjustierung des Bewertungsansatzes. (siehe Anhang 3)

Die Ergebnisse der systematischen Gewichtung zeigen, dass sich kein generelles Leistungsranking der betrachteten Prognoseverfahren ableiten lässt. Zwar konnten in einzelnen Kategorien wie Prognosegüte, Robustheit, Rechenaufwand oder Implementierungskomplexität unterschiedliche Stärken und Schwächen identifiziert werden, jedoch variiert die Eignung eines Verfahrens signifikant in Abhängigkeit von den Eigenschaften der zugrunde liegenden Zeitreihen sowie den spezifischen Anforderungen des Anwendungskontexts.

Diese Erkenntnis bestätigt die in der Fachliteratur wiederholt formulierte Annahme, dass es kein universell überlegenes Prognoseverfahren gibt („No-Free-Lunch-Theorem“ in der Prognostik) (Wolpert und Macready 1997). Vielmehr ist die Auswahl eines geeigneten Modells kontextabhängig und sollte datenbasiert sowie zielorientiert erfolgen. In der Praxis bedeutet dies, dass die Bewertung und Auswahl von Prognoseverfahren stets anwendungs- und datenspezifisch erfolgen muss – unter Berücksichtigung der jeweiligen Anforderungen an Prognosegenauigkeit, Interpretierbarkeit, Verfügbarkeit von Datenquellen und Ressourceneinsatz. Die im Rahmen dieses Projekts erstellte systematische Übersicht und Gewichtung kann hierbei als unterstützendes Entscheidungstool dienen, ersetzt jedoch keine anwendungsindividuelle Validierung der Modelle.

Die umfassende Bewertung der Prognoseverfahren führte dennoch zu zentralen Erkenntnissen, die in die IT-gestützte Lösung integriert wurden:

Integrierte Ergebnisdokumentation: Die umfangreiche Literaturrecherche sowie der Vergleich zahlreicher Case Studies und die eigene empirische Evaluation univariater Modelle haben eine detaillierte Ergebnissammlung ermöglicht. Diese Ergebnisse wurden systematisch in die IT-Anwendung eingebettet, sodass alle bewerteten Verfahren hinsichtlich ihrer Prognosegenauigkeit, Anwendbarkeit und Implementierungskomplexität transparent dokumentiert sind.

Diversität der Verfahren: Die Untersuchungen zeigten, dass die in der Literatur und Praxis identifizierten Prognoseverfahren ein sehr heterogenes Spektrum abbilden. Es ergab sich, dass nahezu alle Ansätze – von klassischen statistischen Modellen (z. B. ARIMA, exponentielle Glättung, Holt-Winters) bis hin zu modernen Machine-Learning- und Deep-Learning-Verfahren – in bestimmten Anwendungsszenarien überzeugende Ergebnisse liefern können. Nur in Fällen, in denen Verfahren lediglich marginale Erweiterungen zu grundlegenden Methoden darstellen oder deren Implementierung mit unverhältnismäßig hohem Aufwand verbunden ist, empfiehlt sich eine systematische Ausschließung, um die Komplexität der Anwendung gering zu halten.

Limitationen univariater Analysen: Die empirischen Tests auf Basis univariater Einzelhandelsdaten lieferten wertvolle Einblicke in die Modellgüte, berücksichtigen jedoch nicht die multivariate Prognoseleistung komplexer Systeme. Da aber in vielen Praxisanwendungen häufig nur eine einzelne Zeitreihe verfügbar ist, müssen statistische Verfahren, die robuste univariate Prognosen ermöglichen, integraler Bestandteil der Lösung bleiben. Gleichzeitig unterstreicht die Analyse, dass eine vollständige Bewertung der Prognoseverfahren auch die multivariate Dimension berücksichtigen sollte, um eine ganzheitliche Systemperformance sicherzustellen.

Kriterienkatalog zur Bewertung einer AB-Planung

Ziel: Kriterienkatalog zur Bewertung einer AB-Planung

Vorgehen: Die Anforderungen in Form des Kriterienkatalogs wurden unter Berücksichtigung des Design Science Research (DSR) nach Hevner et al. (2004) ermittelt. DSR ist als wissenschaftliche Methodik zur Entwicklung und Evaluation innovativer Artefakte zu verstehen, die zur Lösung relevanter Probleme aus der Praxis beitragen. DSR damit Forschung (Rigor) mit praktischer Relevanz und folgt einem strukturierten Rahmen, die sowohl Gestaltungslogik als auch wissenschaftliche Qualität absichern. Im Rahmen des Projektes galt es zunächst, unter Berücksichtigung der Ideen auf Basis früher Gespräche mit Unternehmen des PA und gemeinsamer Workshops (DSR: Relevanz) sowie eine Literaturrecherche (DSR: Rigor) Anforderungen zu erfassen und

zu systematisieren, die Anwender an eine KI-gestützte Absatzprognoselösung stellen. Zur Identifikation dieser Anforderungen wurden zwei zentrale Methoden angewandt: eine umfassende Literaturrecherche und eine semi-strukturierte Umfrage unter potenziellen Anwendern aus der Industrie, Entwicklern von Software im Industriebereich und Experten im Bereich Datenanalyse, beginnend mit einem Workshop während der ersten Sitzung des PA. Die Literaturrecherche diente dazu, bestehende Anforderungen und aktuelle Herausforderungen im Bereich der Absatzprognose zu beleuchten. Die Umfrageergebnisse lieferten ergänzend dazu praxisnahe Einblicke und spezifische Erwartungen von Anwendern bezüglich Funktionalität, Performance und Benutzerfreundlichkeit von KI-Lösungen für Absatzprognosen.

Die gewonnenen Anforderungen wurden zu einer strukturierten Liste von Bewertungskriterien verdichtet. Diese Kriterien decken verschiedene Dimensionen ab. Durch die Systematisierung dieser Kriterien soll eine fundierte Bewertungsgrundlage geschaffen werden, anhand derer im Rahmen des Forschungsprojekts entwickelt wird. Dabei sind die Kriterien in zwei Kategorien unterteilt. Im Kern steht am Ende des Projektes ein IT-Tool als **Werkzeug**, das die Anwender nutzen. Dieses Werkzeug muss bestimmte Kriterien erfüllen. Dieses IT-Tool ist dabei aber vielmehr die technische Umsetzung der **Prognose** selbst, für die ebenfalls Kriterien gelten müssen. Der Aufbau des Katalogs umfasst zusätzlich für jedes Kriterium eine Unterkategorie, die FURPS-Kategorie, die Priorität und die Funktionalitätsklasse.

Ergebnisse: Die Unterkategorien orientieren sich an der autonomieorientierten Betriebsanalyse nach Strohm und Ullrich (1997), da die Anwendung von prädiktiven Prognosemethoden im betrieblichen Umfeld im Mittelpunkt dieses Forschungsprojektes steht. Demnach muss die Lösung unter Einbindung des Menschen, der Organisation und Technik entwickelt werden. Darüber hinaus wurden die Unterkategorien *Daten*, *Applikation* und *Sonstiges* ergänzt. *Daten* stehen im Zentrum für eine gute Prognose, die *Applikation* ist Kern einer nachhaltigen Anwendung in den Betrieben. *Sonstiges* betrifft Aspekte, die über die anderen Kategorien hervorgehen. Die Anforderungen des Werkzeugs werden demnach in Mensch, Organisation, Technik, Daten, Applikation und Sonstiges unterteilt.

Um den Anforderungen an eine Softwarelösung, die das IT-Tool am Ende darstellt, gerecht zu werden, wurde bei der Erstellung des Kriterienkatalogs das FURPS-Modell herangezogen. Das FURPS-Modell wurde von Hewlett-Packard (HP) entwickelt und ist ein Klassifikationsschema zur strukturierten Erfassung und Beschreibung von Anforderungen an Softwarelösungen. FURPS steht für *Functionality*, *Usability*, *Reliability*, *Performance* und *Supportability*. Diese fünf Kategorien decken die wesentlichen Dimensionen ab, die bei der Anforderungsanalyse einer Softwarelösung berücksichtigt werden sollten:

Functionality: Beinhaltet die Funktionsanforderungen, also was das System leisten soll.

Usability: Umfasst die Benutzerfreundlichkeit und Benutzererfahrung.

Reliability: Bezieht sich auf die Zuverlässigkeit, einschließlich Fehlertoleranz und Stabilität.

Performance: Beschreibt die Leistungsfähigkeit, wie Geschwindigkeit und Effizienz.

Supportability: Deckt Wartbarkeit, Erweiterbarkeit und Anpassungsfähigkeit der Software ab.

Dieses Modell hilft, Anforderungen an eine Software systematisch zu kategorisieren und sicherzustellen, dass alle relevanten Aspekte bei der Entwicklung und Bewertung einer Lösung berücksichtigt werden.

Um den Projektumfang klar zu definieren und eine gezielte Umsetzung zu gewährleisten, wurde eine Priorisierung der Anforderungen nach dem Requirement Engineering vorgenommen - insbesondere auf dem

MoSCoW-Prinzip (Must, Should, Could, Won't) (Cohn 2005). In PrABCast wurde eine vereinfachte Variante verwendet, bei der Anforderungen in zwingend notwendige und optionale Anforderungen unterteilt werden. Hierbei werden obligatorische Anforderungen („Muss“-Kriterien) identifiziert, die für die grundlegende Funktionalität und Zielerreichung unerlässlich sind. Darüber hinaus wurden optionale Anforderungen („Kann“-Kriterien) bestimmt, die zwar die Funktionalität verbessern, jedoch für die Kernaufgaben nicht zwingend notwendig sind. Diese Priorisierung dient der Ressourcenfokussierung und gewährleistet, dass die wesentlichen Ziele innerhalb des vorgegebenen Zeit- und Budgetrahmens des Forschungsprojekts erreicht werden können. Dabei werden im Folgenden die Anforderungen beschrieben, dabei zuerst Werkzeug und innerhalb dieser Kategorie nach den FURPS-Kategorien (Functionality, Usability, Reliability, Performance, Supportability) sowie nach Muss-/Kann-Priorität unterteilt, danach Prognose, wobei die Kriterien im Bereich Prognose alle unter „Funktionalität“ fallen. Der Kriterienkatalog stellt ein systematisches Evaluationsinstrument dar, das die Anforderungen an eine KI-gestützte Absatzprognoselösung erfasst. Er integriert zentrale Dimensionen des FURPS-Modells – Functionality, Usability, Reliability, Performance und Supportability – und erweitert diese um fachspezifische Aspekte wie Datenintegration, Modellpräzision und organisatorische Rahmenbedingungen. Durch die differenzierte Erfassung von Muss- und Kann-Kriterien wird es ermöglicht, essentielle Anforderungen von optionalen Erweiterungen zu trennen und deren Relevanz transparent zu priorisieren. Dieser strukturierte Ansatz sorgt dafür, dass der Kriterienkatalog eine fundierte Basis für die Auswahl, Bewertung und Weiterentwicklung von IT-Werkzeugen für die Absatzplanung in der Auftragsfertigung im industriellen Kontext bildet, sodass die entwickelte Lösung sowohl technisch robust als auch praxisrelevant ist (siehe Abbildung 6):

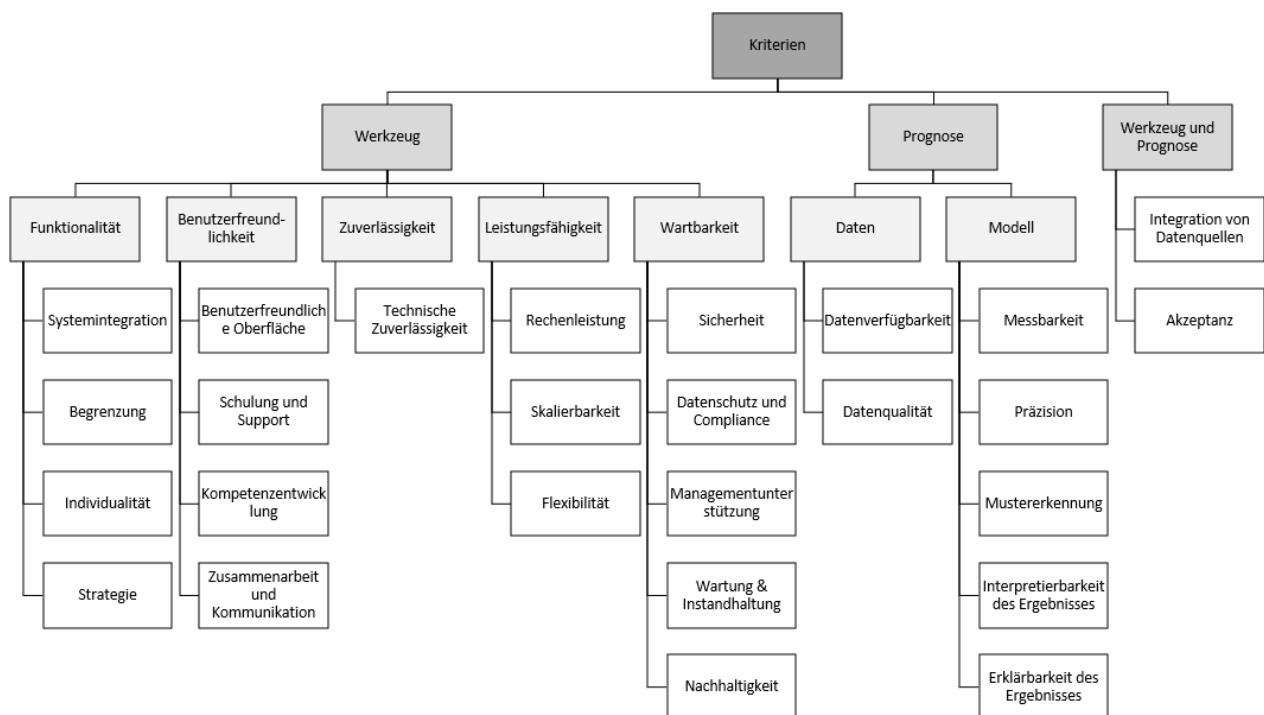


Abbildung 6: Übersicht der Kriterien

Werkzeug

1. Funktionalität (Functionality)

a. Systemintegration

Die entwickelten Prognoseverfahren müssen nahtlos in bestehende IT-Infrastrukturen und Geschäftsprozesse integriert werden können. Dies beinhaltet die Kompatibilität mit bestehenden ERP- und CRM-Systemen sowie die Fähigkeit, Prognosedaten effektiv in Entscheidungsprozesse einzuspeisen. Eine flexible API-Gestaltung und die Unterstützung von Standarddatenformaten sind hierfür essenziell. (Technologie, „Muss“)

b. Begrenzung

Eine klare Definition und Abgrenzung des Produktportfolios, das durch die Prognoselösung abgedeckt wird, ist essentiell. Dies hilft, den Fokus auf die Kernbereiche zu legen, die den größten Einfluss auf die Geschäftsziele haben, und vermeidet eine Überkomplexität des Systems. Die Auswahl der zu berücksichtigenden Produkte muss strategisch erfolgen und regelmäßig überprüft werden. (Organisation, „Muss“)

c. Individualität

Die Prognoselösung muss in der Lage sein, individuelle Anforderungen und Besonderheiten der kundenauftragsorientierten Fertigung zu berücksichtigen. Dies umfasst die Entwicklung von Modellen, die flexibel anpassbar sind und spezifische Produktionsprozesse, Kundenanforderungen und Marktbedingungen einbeziehen können. Individuelle Anpassungen sollen ohne großen Aufwand möglich sein. (Organisation, „Kann“)

d. Strategie, strukturiertes Vorgehen

Die Planungsaufgabe, die mithilfe der Absatzprognose zu verbessern ist, ist entscheidend für die Ausrichtung des gesamten Systems. Diese Entscheidung muss auf einer tiefgehenden Analyse der Geschäftsziele und -bedürfnisse basieren und kann Umsatz, Lagerbestände, Lieferzeiten oder andere kritische Erfolgsfaktoren umfassen. Die Festlegung der Zielvariable leitet die Modellauswahl und -anpassung. (Organisation, „Kann“)

2. Benutzerfreundlichkeit (Usability)

a. Benutzerfreundliche Oberfläche

Die Gestaltung einer intuitiven und benutzerfreundlichen Schnittstelle ist entscheidend, um die Akzeptanz und effektive Nutzung des Systems zu fördern. Dies umfasst die klare Visualisierung von Prognoseergebnissen, die einfache Navigation durch das System und die Bereitstellung von Hilfefunktionen. Die Benutzeroberfläche sollte auf die Bedürfnisse der Endnutzer abgestimmt sein und regelmäßiges Feedback einholen. (Applikation, „Muss“)

b. Schulung und Support

Die Bereitstellung von umfassenden Schulungs- und Supportangeboten ist notwendig, um sicherzustellen, dass die Benutzer das System effektiv nutzen können. Dies schließt die Einführung in die Grundlagen der Datenanalyse, die Handhabung der Software und die Interpretation der Prognoseergebnisse ein. Ein

kontinuierlicher Support hilft bei der Behebung von Problemen und fördert die kontinuierliche Verbesserung des Systems. (Applikation, „Kann“)

c. Kompetenzentwicklung

Die Entwicklung von Kompetenzen ist notwendig, um sicherzustellen, dass Mitarbeiter die Prognoseergebnisse interpretieren und darauf basierende Entscheidungen treffen können. Dies beinhaltet die Bereitstellung zielgerichteter Weiterbildungsangebote, die Förderung von Datenkompetenz und die Unterstützung beim Aufbau von Verständnis für ML und dessen Anwendung im betrieblichen Kontext. (Mensch, „Kann“)

d. Zusammenarbeit und Kommunikation

Die Förderung der Zusammenarbeit und Kommunikation zwischen den verschiedenen Abteilungen und Teams, die in den Prognoseprozess involviert sind, ist essentiell für eine effiziente Nutzung der Ergebnisse. Dies umfasst die Schaffung von Plattformen für den Austausch von Informationen, die Einrichtung interdisziplinärer Teams und die regelmäßige Durchführung von Meetings, um die Integration der Prognosen in die Geschäftsprozesse zu diskutieren. (Organisation, „Kann“)

3. Zuverlässigkeit (Reliability)

a. Technische Zuverlässigkeit

Die technische Zuverlässigkeit einer Absatzprognoselösung bezieht sich auf die Stabilität und Ausfallsicherheit des Systems im laufenden Betrieb. Eine zuverlässige Lösung minimiert Unterbrechungen und stellt sicher, dass Prognosen kontinuierlich und ohne technische Störungen bereitgestellt werden. Diese Anforderung ist besonders wichtig, um das Vertrauen der Anwender zu gewinnen und die Effizienz im Prognoseprozess zu gewährleisten. (Technologie, „Kann“)

4. Leistungsfähigkeit (Performance)

a. Rechenleistung

Angemessene Rechenleistung ist für die Verarbeitung großer Datenmengen und die Ausführung komplexer Modelle unerlässlich. Es muss eine Evaluation der benötigten Hardware-Ressourcen erfolgen, um eine schnelle Verarbeitung und Analyse der Daten zu gewährleisten. Dies kann den Einsatz spezialisierter Hardware oder Cloud-Lösungen umfassen, um Flexibilität und Skalierbarkeit zu gewährleisten. (Technologie, „Muss“)

b. Skalierbarkeit

Das System muss in der Lage sein, mit verschiedenen Zeitreihen und der Zunahme der Datenmengen zu skalieren. Dies erfordert eine Architektur, die eine einfache Erweiterung der Hardware- und Softwarekomponenten ermöglicht, ohne dass es zu Leistungseinbußen kommt. Die Planung für zukünftiges Wachstum muss bereits in der Entwicklungsphase berücksichtigt werden. (Technologie, „Muss“)

c. Flexibilität

Die Prognoselösung muss flexibel genug sein, um sich an Veränderungen in der Produktionsumgebung, den Geschäftsmodellen und den Marktbedingungen anzupassen. Dies beinhaltet die Möglichkeit zur schnellen Anpassung der Modelle und Algorithmen sowie die Integration neuer Datenquellen. Eine modulare Systemgestaltung unterstützt diese Anforderung und ermöglicht eine agile Reaktion auf neue Herausforderungen. (Technologie, „Muss“)

5. Wartbarkeit (Supportability)

a. Sicherheit

Sicherheitsmaßnahmen zum Schutz sensibler Daten und Prognoseergebnisse vor unbefugtem Zugriff und Datenlecks sind von höchster Priorität. Dabei steht im Zentrum, dass die sensiblen Absatzdaten die gesteckten Systemgrenzen des Unternehmens nicht verlassen. Dies umfasst ferner die Implementierung von Verschlüsselungstechniken, Zugriffskontrollen und regelmäßigen Sicherheitsaudits. Die Sicherheitsstrategie muss sowohl physische als auch digitale Bedrohungen berücksichtigen und regelmäßig aktualisiert werden. (Technologie, „Muss“)

b. Datenschutz und Compliance

Die Einhaltung gesetzlicher Datenschutzvorschriften und unternehmensinterner Richtlinien ist bei der Verarbeitung und Analyse von Daten unerlässlich. Dies erfordert die Implementierung von Maßnahmen zur Datensicherheit, die Dokumentation von Datenflüssen und die Schulung der Mitarbeiter in Bezug auf Datenschutzbestimmungen. Die Compliance muss regelmäßig überprüft und angepasst werden. (Daten, „Muss“)

c. Managementunterstützung

Die Unterstützung durch das Management ist grundlegend für die erfolgreiche Implementierung und Nutzung der Prognoselösung. Dies beinhaltet die Bereitstellung von Ressourcen, die Förderung einer datenge triebenen Kultur und die aktive Beteiligung an der Überwachung und Bewertung der Prognoseergebnisse. Eine klare Kommunikation der strategischen Bedeutung des Projekts ist hierfür unerlässlich. (Organisation, „Kann“)

d. Wartung und Instandhaltung

Das System muss so gestaltet sein, dass es einfach zu warten und zu aktualisieren ist. Dies umfasst die Möglichkeit, Software-Updates einzuspielen, die Hardware bei Bedarf zu erweitern und Anpassungen an den Modellen und Algorithmen vorzunehmen. Eine klare Dokumentation der Systemarchitektur und der Komponenten erleichtert die Wartung und sichert die langfristige Nutzbarkeit. (Technologie/Applikation, „Kann“)

e. Umweltaspekte und Nachhaltigkeit

Bei der Entwicklung und Implementierung des Systems müssen Umweltaspekte und Nachhaltigkeitsprinzipien berücksichtigt werden. Dies beinhaltet die Auswahl energieeffizienter Hardware, die Minimierung des Ressourcenverbrauchs und die Berücksichtigung der Lebenszykluskosten. Die Förderung einer nachhaltigen Nutzung der Technologie trägt zur Reduzierung des ökologischen Fußabdrucks bei. (Sonstiges, „Kann“)

Prognose:

1. Daten

a. Datenverfügbarkeit

Die Verfügbarkeit von qualitativ hochwertigen und relevanten Daten ist entscheidend für das Training und die Validierung der ML-Modelle. Es muss ein systematischer Ansatz entwickelt werden, um Daten aus internen und externen Quellen zu sammeln, zu speichern und zugänglich zu machen. Besonderes Augenmerk liegt auf der Digitalisierung von Datenströmen, die bisher nicht digital erfasst wurden. („Muss“)

b. Datenqualität

Die Qualität der verwendeten Daten muss durch Verfahren zur Datenbereinigung, -validierung und -normalisierung sichergestellt werden. Es ist notwendig, Richtlinien zu definieren, die festlegen, was unter "guter Datenqualität" zu verstehen ist, einschließlich der Vollständigkeit, Genauigkeit, Konsistenz und Aktualität der Daten. Diese Standards müssen an die spezifischen Anforderungen des Unternehmens angepasst sein. („Muss“)

2. Modell

a. Messbarkeit

Die Messbarkeit ist ein essenzielles Kriterium, das sicherstellt, dass die Qualität der Prognoseergebnisse objektiv bewertet werden kann. Durch definierte Metriken und Kennzahlen lassen sich die Genauigkeit und Verlässlichkeit der Vorhersagen regelmäßig überwachen und verbessern. Messbarkeit schafft Transparenz und ist grundlegend, um die Wirksamkeit des Modells langfristig sicherzustellen. („Muss“)

b. Präzision

Die Präzision des Modells ist entscheidend für die Nützlichkeit der Prognosen. Sie beschreibt die Fähigkeit, Absatzmengen mit möglichst minimalen Abweichungen vorherzusagen. Ein präzises Modell liefert verlässliche Ergebnisse, die als Grundlage für wichtige Geschäftsentscheidungen genutzt werden können, und reduziert gleichzeitig die Risiken von Fehlplanungen. („Muss“)

c. Mustererkennung:

Die Fähigkeit zur Mustererkennung ermöglicht es dem Modell, Trends und wiederkehrende Muster in den historischen Absatzdaten zu identifizieren. Dadurch können Prognosen basierend auf saisonalen oder zyklischen Veränderungen im Absatzverhalten erstellt werden. Die Mustererkennung unterstützt eine fundierte Vorhersage und hilft, auf Marktveränderungen rechtzeitig zu reagieren. („Muss“)

d. Interpretierbarkeit des Ergebnisses

Die Interpretierbarkeit ist wichtig, um sicherzustellen, dass die Prognoseergebnisse für die Anwender nachvollziehbar und verständlich sind. Ein interpretierbares Modell hilft den Nutzern, die Vorhersagen zu verstehen und mögliche Anpassungen oder Entscheidungen darauf basierend fundiert zu treffen. Es erhöht die Akzeptanz und das Vertrauen in die Lösung. („Muss“)

e. Erklärbarkeit des Ergebnisses

Die Erklärbarkeit bezieht sich darauf, dass die Prognoseergebnisse so aufbereitet werden, dass die zugrunde liegenden Gründe und Einflussfaktoren für die Vorhersagen verständlich dargestellt werden können. Dies ermöglicht den Nutzern, die Mechanismen des Modells nachzuvollziehen und gibt ihnen eine zusätzliche Sicherheit über die Verlässlichkeit und Validität der Prognosen. („Kann“)

Werkzeug und Prognose:

a. Integration von Datenquellen

Dieses Kriterium beschreibt die Möglichkeit des Werkzeuges als auch die Fähigkeit der integrierten Modelle, Daten aus unterschiedlichen internen und externen Quellen zu verarbeiten und in die Prognose einzubeziehen. Die Integration externer Daten wie Marktdaten oder Konjunkturindikatoren ermöglicht eine umfassendere und fundiertere Prognose, die über interne Absatzdaten allein hinausgeht. (Technologie/Daten, „Muss“)

b. Akzeptanz

Die Akzeptanz der Endnutzer gegenüber dem Prognosesystem ist entscheidend für dessen Erfolg. Es müssen Maßnahmen ergriffen werden, um Vertrauen und Verständnis für die Funktionsweise und den Nutzen sowohl des Tools als auch der ML-Verfahren zu fördern. (Mensch, „Kann“)

Klassifizierung potentieller Anwender

Ziel: Klassifizierung von Anwendergruppen für eine potentielle Teilefamilienbildung

Vorgehen: Ein wesentlicher Erfolgsfaktor für die Ausarbeitung eines generalisierten ML-Modells zur Absatz- und Bedarfsplanung ist die Identifikation geeigneter Datenquellen und die korrekte Klassifizierung der Anwender und ihrer Produktstrukturen. Dazu wurden im Rahmen des Projektes im Rahmen einer umfassenden Recherche, einer Abschlussarbeit und in Experteninterviews mit Anwendern verschiedene Kategorien zur Gruppierung der Anwender ermittelt.

Ergebnis: Die Kategorisierung wird dabei in die Ebenen „Erzeugung“, „Markt“ und „Interne Daten und weitere Einflüsse“ aufgeteilt. Dabei bildet die Ebene „Erzeugung“ den Produzenten selbst ab, die Ebene „Markt“ den etwaigen Kunden sowie weiterer Stufen lieferkettenabwärts sowie die Ebene „interne Daten und weitere Einflüsse“ diejenigen Kategorien, die nicht eindeutig Erzeuger oder Markt zuzuordnen sind oder darüber hinaus gehen (siehe Abbildung 7)

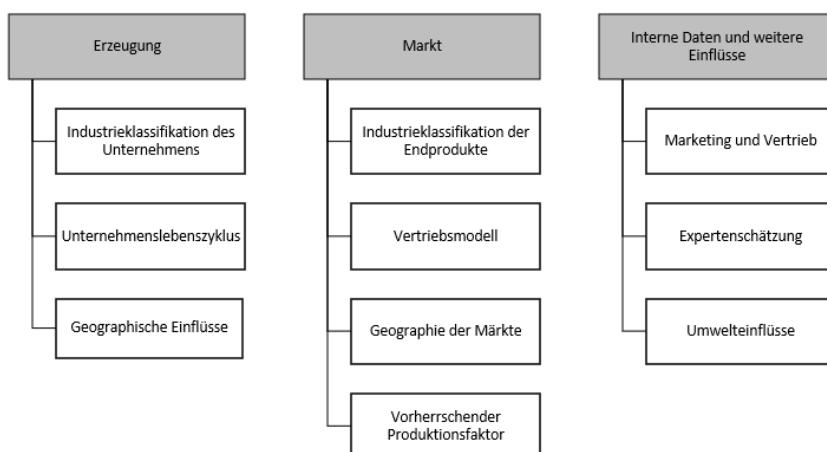


Abbildung 7: Übersicht der Klassifikationskategorien

Klassifikation auf der Ebene der Erzeugung:

Die erste Ebene der Klassifikation bezieht sich auf den Produzenten oder das Unternehmen selbst. Hier werden mehrere Faktoren berücksichtigt:

Industrieklassifikation: Die Industrieklassifikation hilft dabei, Unternehmen hinsichtlich ihrer Branchen und Subbranchen zu unterscheiden (Weiner 2005, 3 ff.). Die Unternehmen können dabei bspw. gemäß des *Global Industry Classification Standard (GICS)* klassifiziert werden. Der *Global Industry Classification Standard (GICS)* ist ein international anerkanntes System zur Klassifizierung von Unternehmen und ihren Geschäftstätigkeiten in verschiedene Branchen und Sektoren. Es wurde 1999 von MSCI und S&P Dow Jones Indices entwickelt, um Investoren eine einheitliche, standardisierte Struktur zur Analyse und Vergleichbarkeit von Unternehmen weltweit zu bieten. Der GICS unterteilt Unternehmen in 11 Sektoren, 24 Branchen, 69 Industrien und 158 Unterindustrien, um eine differenzierte Branchenanalyse zu ermöglichen. (MSCI und S&P Global Market Intelligence 2018) Dies ermöglicht eine standardisierte Einteilung der Unternehmen in Branchen, die das Potential haben oft ähnliche Absatzmuster aufweisen können. Laut MSCI (2024) können solche Standardisierungen dazu beitragen, spezifische Merkmale einer Branche besser zu verstehen, was die Algorithmen unterstützen kann, branchenspezifische Verkaufsdynamiken zu erkennen.

Unternehmenslebenszyklus: Dieser Punkt teilt Unternehmen in *Start-up-Unternehmen*, *Wachstumsunternehmen* und *etablierte Unternehmen* ein. Nach der Lebenszyklustheorie von Adizes (1989) befinden sich Unternehmen in unterschiedlichen Phasen und zeigen daher differenzierte Wachstums- und Absatzmuster. Diese Einteilung ist entscheidend, um sicherzustellen, dass ML-Modelle diese unterschiedlichen Dynamiken in den Vorhersagen berücksichtigen.

Geographische Einflüsse: Die Geographie der Unternehmen und ihrer Produktionsstätten wird ebenfalls in die Klassifizierung einbezogen. Regionale Unterschiede in Konjunkturdaten und wirtschaftlichen Rahmenbedingungen können erhebliche Auswirkungen auf den Absatz haben. So zeigt Miller (1998), dass regionale Aggregationen in Prognosefragen zu besseren Ergebnissen führen können. Außerdem besteht durch eine Datenanreicherung durch entsprechende geographisch passende Datenquellen aus unterschiedlichen Bereichen ein Potential zum zielgerichteten Modelltraining.

Vorherrschender Produktionsfaktor: Unternehmen können je nach Branche auf bestimmte Produktionsfaktoren wie Personal, Material oder Energie angewiesen sein (Case et al. 2020). Okpighe (2015) führt aus, dass diese Faktoren wesentliche Auswirkungen auf die Kostenstruktur und die Produktion als solche haben können. Ein auf Personal basierendes Unternehmen kann z.B. anders auf Nachfrageänderungen reagieren als ein materiallastiges Unternehmen, was in die Prognosen einfließen muss.

Klassifikation auf Marktebene:

Die zweite Ebene der Klassifikation betrifft die Märkte, die das Produkt durchschreitet. Dabei ist nicht nur der direkte Abnahmemarkt entscheidend, auch die weiteren Verarbeitungsstufen eines Produktes bis hin zu einem Endprodukt der Wertschöpfungskette sind zu berücksichtigen.

Industrieklassifikation des Endprodukts: Ähnlich wie bei den produzierenden Unternehmen können auch die Endprodukte Branchen nach dem GICS-System zugeordnet werden (MSCI 2024). Die Klassifikation auf Produktebene unterstützt ML-Verfahren dabei, Absatzmuster zu erkennen, die spezifisch für Produktfamilien sind, wie dies auch in der Theorie der Produktgruppenbildung beschrieben wird (Burbidge 1975).

Vertriebsmodell: Unternehmen lassen sich entsprechend ihres Vertriebsmodells unterschieden. Diese Einteilung basiert darauf, wer der Hauptabnehmer der Produkte oder Dienstleistungen eines Unternehmens ist:

andere Unternehmen (B2B) oder Endverbraucher (B2C). Diese Differenzierung ist essentiell, da sich die Absatzmuster für Unternehmen, die ihre Produkte direkt an Verbraucher verkaufen (B2C), oft stark von denen unterscheiden, die im Business-to-Business-Bereich tätig sind (B2B). Wie Kotler et al. (2017) darstellen haben B2B-Unternehmen in der Regel weniger, aber größere Transaktionen, während B2C-Unternehmen eine größere Anzahl kleinerer Transaktionen verzeichnen. Diese Unterschiede beeinflussen die Nachfragevolatilität und sollten in den Vorhersagemodellen berücksichtigt werden.

Geographie: Auch auf Marktebene spielt die regionale Segmentierung eine Rolle. Verschiedene Absatzmärkte zeigen unterschiedliche Nachfragemuster, die durch geographische Cluster und regionale Wettbewerbsvorteile bedingt sein können. (Formánek und Sokol 2022) Das ML-Modell sollte daher die Region als wichtigen Inputfaktor berücksichtigen.

[Interne Daten und weitere Einflüsse:](#)

In der dritten Kategorie werden unternehmensspezifische Daten und externe Einflüsse analysiert, die weder Erzeuger noch Markt eindeutig zugeordnet werden können. Dabei geht es vor allem in Bezug auf die Vorbereitung von AP3 und die Ermittlung nutzbarer interner Datenquellen bei den Unternehmen. So können entsprechend der vorhandenen Daten Modelle zur Prognose ausgewählt werden.

Marketingdaten: O’Leary-Kelly und Flores (2002) beschreiben in ihrer Abhandlung über die Integration von Produktions- und Marketingentscheidung, dass Marketing- und einen signifikanten Einfluss auf den Absatz und damit die Unternehmensleistung haben können. Das Vorhandensein solcher Daten ist entscheidend für die Genauigkeit der Prognosemodelle, da sie eine direkte Verbindung zwischen Werbemaßnahmen und Verkaufszahlen herstellen können.

Expertenschätzung: Expertenschätzungen können wertvolle qualitative Informationen liefern, die ML-Verfahren ergänzen (Armstrong und Brodie 1999). Diese Ansätze werden oft in hybriden Modellen genutzt, wie etwa durch Kuo et al. (2016), die qualitative und quantitative Methoden kombinieren, um Prognosegenauigkeiten zu erhöhen.

Vertriebsdaten: CRM-Daten spielen eine entscheidende Rolle bei der Prognose von Absatzentwicklungen, da sie einen umfassenden Überblick über das Kundenverhalten, die Verkaufszyklen und die Interaktionen eines Unternehmens mit seinen Kunden bieten. CRM-Systeme erfassen Kundendaten wie Kaufhistorien, Kundenpräferenzen, demografische Informationen und Feedback (Buttle und Maklan 2019). Durch die Integration von CRM-Daten in ML-Modelle können wertvolle Einblicke gewonnen werden, die zu genaueren Vorhersagen und besserer Segmentierung der Zielgruppen führen können. Insbesondere im B2B-Bereich sind Vertriebsprozesse durch stärkere Beziehungen zum Kunden gekennzeichnet. Die Verfügbarkeit und Qualität von CRM-Daten kann die Effektivität von Vorhersagemodellen erheblich steigern, indem sie den Modellen helfen, auf wiederkehrende Kundeninteraktionen und -muster zu reagieren. (Smith 2024)

Umwelteinflüsse: Faktoren wie Umweltbedingungen und regulatorische Anforderungen können laut Babongo et al. (2019) erhebliche Auswirkungen auf den Markt und damit auch auf die Verkaufsprognosen haben. Einbeziehung dieser Faktoren kann dazu beitragen, das Modell robuster zu gestalten und besser auf unerwartete Ereignisse zu reagieren.

Die vorgestellte Klassifikationsmethodik bietet eine robuste Grundlage für die Modellierung von Absatzprognosen. Durch die dreifache Gruppierung nach *Erzeugung*, *Markt* und *Interne Daten und Einflüsse* werden die wichtigsten Einflussfaktoren abgedeckt, die die Absatzentwicklung eines Unternehmens beeinflussen. Das Modell wird durch die GICS-Klassifikation, die Berücksichtigung des Unternehmenslebenszyklus und die

Segmentierung nach Geschäftsmodellen hinreichend differenziert, um branchenspezifische Unterschiede korrekt abzubilden.

Zusammenfassung und Erkenntnisse aus AP1

Im Rahmen von Arbeitspaket 1 wurden drei zentrale Ergebnisse erarbeitet: (1) eine systematische Klassifikation und Bewertung verschiedener Prognoseverfahren, (2) ein Kriterienkatalog zur strukturierten Evaluierung von Verfahren anhand technischer und anwenderbezogener Anforderungen, und (3) eine Einteilung potenzieller Anwendergruppen anhand von Datenverfügbarkeit, Bedarfsstruktur und Unternehmenscharakteristika.

Die im Rahmen des ersten Arbeitspakets durchgeführte Analyse zur systematischen Bewertung und Klassifikation von Prognoseverfahren hat verdeutlicht, dass es kein universell überlegenes Modell gibt, das in allen Anwendungsszenarien der kundenauftragsorientierten Fertigung gleichermaßen optimal funktioniert. Vielmehr zeigt sich, dass die Wahl des geeigneten Verfahrens maßgeblich von drei zentralen Einflussfaktoren abhängt: dem individuellen Absatzverlauf, der Datenqualität sowie den spezifischen Anforderungen der Anwenderunternehmen.

Die durchgeführte Gewichtung der Prognoseverfahren nach quantitativen und qualitativen Kriterien ergab, dass klassische statistische Methoden (z. B. exponentielle Glättung, ARIMA) insbesondere bei stabilen Zeitreihen mit geringen Störgrößen und ausreichender Datenhistorie leistungsfähig sind. Gleichzeitig weisen moderne Machine-Learning-Ansätze (z. B. Gradient Boosting, neuronale Netze) deutliche Vorteile bei hochvola-tilen und nichtlinearen Verläufen auf, setzen jedoch eine ausreichende Datenbasis voraus. Die Untersuchungen haben zudem gezeigt, dass nicht nur die Prognosegüte, sondern auch Erklärbarkeit, Implementierungsaufwand und Integration in bestehende Systeme für die Praxisanwendung eine entscheidende Rolle spielen. In diesem Zusammenhang wurde deutlich, dass rein datengetriebene Verfahren oft schwerer nachzuvollziehen sind, während erklärbare Modelle von Anwendern besser akzeptiert werden.

Daher kann keine allgemeingültige Ausschlussentscheidung getroffen werden - vielmehr muss die Wahl des geeigneten Prognoseverfahrens fallabhängig erfolgen. Die Ergebnisse unterstreichen die Notwendigkeit eines anpassungsfähigen, modularen Ansatzes, bei dem Prognosemodelle flexibel auf die jeweilige Datenlage und die Anforderungen der Nutzer abgestimmt werden können. Mögliche Datenquellen zur Nutzung sowie genauere Anforderungen der Nutzer wurden im folgenden Arbeitspaket detailliert erforscht.

Auf Basis der durchgeführten Befragungen und Recherchen wurde außerdem schnell deutlich, dass im industriellen Umfeld – selbst bei KMU – bereits automatisierte Prozesse für die Produktions- und Bedarfsplanung etabliert sind (etwa im Rahmen von SIOP-Prozessen oder bei Dispositionsläufen). Daraus ergibt sich eine klare Fokussierung auf präzise Absatzprognosen als zentrales Element der KI-gestützten Lösung. Von Projektbeginn an wurde daher priorisiert, die im Projekt entwickelte Methodik und Softwarelösung speziell auf die Anforderungen und Besonderheiten von Absatzprognosen auszurichten, um eine möglichst hohe Praxisrelevanz zu gewährleisten.

3.2 Arbeitspaket 2: Potentialanalyse zur Identifikation verfügbarer, ungenutzter Quellen für eine Datenanreicherung

Anknüpfend an die Erhebung der Anforderungen der Industrie sowie der Recherche der Verfahren erfüllte die Potentialanalyse zur Identifikation verfügbarer, ungenutzter Quellen für eine Datenanreicherung das

Datenverständnis, analog zur zweiten Phase im CRISP-DM. Im Zentrum stehen dabei die Ermittlung verfügbarer Datenquellen und die Bewertung ihrer Auswirkung auf die Prognosegüte sowie die Sammlung aussichtsreicher Anreicherungsmöglichkeiten durch eine Literaturrecherche und Umfragestudie.

Teilergebnisse im Rahmen des Arbeitspaket 2

Auflistung verfügbarer Datenquellen mit quantitativer Bewertung ihrer Relevanz für AB-Prognosen

Ziel: Auflistung verfügbarer Datenquellen mit quantitativer Bewertung ihrer Relevanz für AB-Prognosen

Vorgehen: Aufbauend auf den in TAP 1.2 bewerteten Prognoseverfahren wurden zunächst alle potenziell verfügbaren Datenquellen identifiziert. Dies wurde mit einer umfassenden Literaturrecherche realisiert. Daraufhin wurde eine explorative Analyse am Beispieldatensatz eines PA-Teilnehmers durchgeführt, um potenzielle Zusammenhänge zwischen konjunkturellen Kennzahlen und den Absatzdaten zu untersuchen. Hierbei kam zunächst die Korrelationsanalyse zum Einsatz, bei der mittels Pearson-Korrelation der lineare Zusammenhang zwischen den Variablen geprüft wurde (Pearson 1895). Diese Methode lieferte so erste Hinweise auf mögliche Wechselwirkungen, erlaubt jedoch keine Aussage über kausale Zusammenhänge. Ergänzend wurde der Granger-Causality-Test angewendet, der prüft, ob vergangene Werte einer Zeitreihe (z. B. konjunkturelle Kennzahlen) signifikant zur Vorhersage zukünftiger Werte einer anderen Zeitreihe (hier: Absatzdaten) beitragen kann. Das Verfahren basiert auf dem Konzept der Kausalität im Sinne Grangers (Granger 1969) und ermöglicht so, erste kausale Beziehungen zu identifizieren. Trotz des methodischen Ansatzes ergab sich in der praktischen Anwendung eine enorme Herausforderung: Die Analyse erfolgte in einer Matrix, die sich aus den Absatzdaten in Kombination mit einer Vielzahl möglicher Anreicherungsdaten zusammensetzt. Die resultierende hohe Dimensionalität und Komplexität führte dazu, dass sich keine verallgemeinerbaren, unternehmensübergreifenden Aussagen ableiten ließen, da die Ergebnisse zu stark von den spezifischen Merkmalen des jeweiligen Datensatzes abhingen. Bei einzelnen Produkten waren für einzelne Datenquellen Zusammenhänge erkennbar, diese waren jedoch nicht zu systematisieren.

Aus diesem Grund wurde beschlossen, die Bewertung der Datenanreicherungsquellen direkt in das Prognosetool zu integrieren. Dieser Ansatz ermöglicht es, bei jedem Analysedurchlauf individuell und bedarfsgerecht die Relevanz der genutzten Datenquellen zu bestimmen und so flexibel auf die spezifischen Gegebenheiten der untersuchten Unternehmen zu reagieren.

Ergebnis: Für die Datenanreicherung werden in der Literatur eine Vielzahl an möglichen Quellen genannt. Ein erster Überblick zum möglichen Vorgehen und potenziellen Datenquellen ist in der Veröffentlichung zur 56. CIRP zu finden (Syberg et al. 2023). Im weiteren Projektverlauf konnten zusätzliche Anreicherungsmöglichkeiten in der Literatur identifiziert werden. Daraus ergeben sich folgende Kategorien, denen die Quellen zugeordnet werden können: Absatzdaten, Marktdaten, Konjunkturdaten, Expertenwissen, Marketing, Kundenmeinung, Kundenverhalten, Umwelt.

Es ergibt sich, dass bestimmte Kategorien bzw. Quellen für einzelne Unternehmen besonders relevant sind. Daher sollten diese mit der Gruppierung der Projektnutzer verknüpft werden. Zunächst werden die relevantesten Teilkategorien und Quellen näher erläutert. Die vollständige Auflistung ist im Anhang 4 zu finden. Neben der Quelle und Kategorie besteht die Tabelle aus fünf weiteren Spalten. Die Datenherkunft gibt an, ob die Daten intern verfügbar sind oder extern beschafft werden müssen. Die Datenart hat die Ausprägungen quantitativ, qualitativ und bei Mischformen hybrid. In der Geographie ist das räumliche Aggregationslevel vermerkt und die minimale Häufigkeit gibt die mögliche Frequenz der Datenpunkte an, welche von täglich bei Absatzdaten bis quartalsweise bei Konjunkturdaten reicht. In der letzten Spalte sind zudem

Literaturhinweise aufgeführt, wo eine Verwendung empfohlen wird oder stattfindet. Eine Übersicht ist in Tabelle 2 zu finden.

Absatzdaten: Sowohl der zeitliche Absatzverlauf des betrachteten Produkts (Schuh und Stich 2012; Tarallo et al. 2019), als auch ähnlicher Produkte (Verstraete et al. 2020) stellen eine entscheidende quantitative Datenquelle dar. Aus den Zeitreihenanalyse können beispielsweise aus saisonalen Mustern oder Trends, Rückschlüsse auf den zukünftigen Verlauf getroffen werden. Weiterhin ist es sinnvoll, den Auftragsfortschritt respektive die offenen Aufträge zu betrachten (Kim 2023). Das ist zum Beispiel bei Rahmenverträgen sinnvoll, um mögliche Abrufe zu prognostizieren.

Marktdaten: In der Gruppe der Marktdaten werden alle Quellen zusammengefasst, welche einen bestehenden Markt abbilden oder durch einen solchen Mechanismus beeinflusst werden. Es handelt sich um quantitative, externe Quellen, die jedoch leicht zugänglich sind. Besonders hervorzuheben sind dabei Börsen- und Branchenindizes. Dazu zählen etwa die bekannten Indizes des Unternehmens MSCI als Weltindex, Landes- oder Regionalindizes. Eine sinnvolle Einteilung nach Branchen liefert der GICS (s.o.) Bei der Betrachtung der Entwicklung im eigenen oder dem Zielmarkt ist mit hoher Wahrscheinlichkeit eine Abhängigkeit des Produkts zu erwarten. Da die Börse zudem Erwartungen an die Zukunft einpreist ist eine vorlaufende Indikation wahrscheinlich, die für die Prognose hilfreich ist (Weichel und Herrmann 2016; Hellmers López et al. 2023; Kim 2023; Sagaert et al. 2018b; Qu et al. 2017). Ein weiterer Indikator sind Währungskurse. Dazu zählt zum einen der Wechselkurs zum jeweiligen Absatzmarkt, als auch der Dollarkurs als weltweit wichtigste Handelswährung. Kursschwankungen können zum Beispiel die Kaufkraft beeinflussen oder im Dollar gehandelte Rohstoffpreise beeinflussen (Kim 2023; Shiha et al. 2022; Sagaert et al. 2018b). Neben dem Wechselkurs, werden Rohstoffpreise etwa für Beton, Gas, Öl, Metalle oder Hölzer maßgeblich von den Erzeugerpreisen bestimmt. Daher finden auch diese Verwendung in der Zeitreihenprognose von Absätzen und Materialpreisen (Weichel und Herrmann 2016; Shiha et al. 2022; Mir et al. 2021).

Konjunkturdaten: Die Konjunkturdaten spiegeln im Vergleich zu den Marktdaten eher die wirtschaftliche Lage wider. Sie haben ein hohes Abstraktionslevel, weshalb sie nur in größeren Abständen aktualisiert werden, stehen allerdings etwa durch das statistische Bundesamt frei zur Verfügung. Sowohl Weichel und Herrmann (2016) als auch Hellmers López et al. (2023) heben ihren Nutzen heraus. Ein Beispiel wäre ein steigender Geschäftsklima- bzw. Geschäftserwartungsindex (Verstraete et al. 2020), was auf eine Zunahme der Personaleinstellungen schließen lässt, wovon wiederum Büroausstatter und der (Ord et al. 2017a) Elektronikhandel profitieren könnten. Viele Prognoseansätze nutzen daher Informationen zur Gesamtwirtschaft, was sich in der Übersichtsarbeit von Sagaert et al. (2018a) oder in der Materialpreisprognose von Mir et al. (2021) zeigt. Weitere relevante Konjunkturindikatoren sind beispielsweise der Auftragseingangsindex, die erteilten Baugenehmigungen, die Leitzinsen der Zentralbanken oder das der Einkaufsmanagerindex. Insbesondere im Bereich der Endkunden oder in Konsum orientierten Märkten wird auf den Konsumklimaindex geachtet (Wang und Gu 2022).

Expertenwissen: Expertenwissen vermag ebenfalls die Prognose zu verbessern. Die Einschätzungen in qualitativer Form enthalten Wissen über die Marktentwicklungen, Kundeneinschätzungen und angewendete Unternehmensstrategien. So können Informationen eingeordnet und zukünftige Entwicklungen abgeleitet werden. Das zeigt sich ebenfalls in den häufig genutzten Expertenrunden zu Absatzplanung (Osadchiy et al. 2013; Ord et al. 2017a).

Marketing: Bereits 1984 stellten Assmus et al. die Bedeutung von Marketing auf den Absatz heraus. Zu der gleichen Erkenntnis gelangten auch Saura et al. in einer späteren Übersichtsstudie (2017). Durch gezieltes werben kann laut ihnen die Zahl der verkauften Produkte gesteigert werden. Somit ist der Einfluss des Marketings als signifikant anzusehen. Weichel und Herrmann (2016) nennen Werbung daher auch als mögliche Anreicherungsquelle für die Absatzprognose. Mögliche Leistungsindikatoren sind etwa die generierten Leads, die Returns on Investment oder die gesammelten Impressionen. Zudem sind die Art und der Umfang des Marketings insbesondere über die Werbeausgaben, die gewählte Strategie und den Preis definiert und werden bereits in der Literatur angewendet (Fildes et al. 2022; Kim 2023; Hellmers López et al. 2023; Qu et al. 2017). Diese Daten stehen intern zur Verfügung, müssen allerdings erhoben werden, wobei die Datenaufnahme unterschiedlich aufwendig ist und die Datenarten quantitativ und qualitativ sind.

Kundenmeinungen: Ein wichtiger Indikator, um wiederkehrende Verkäufe oder Neukunden zu vorherzusehen ist die Kundenmeinung. Diese kann einen durch eine Marktumfrage des Unternehmens oder einen Partner erfolgen. So sollen über gezielte Fragen Änderungen am Produkt erfolgen, die Kundenbindung gestärkt, die Empfehlungsrate verbessert oder der Vertrieb optimiert werden. Eine andere Möglichkeit sind Sentimentanalysen, wobei ein Meinungsbild aus Kundenrezessionen zum Beispiel mithilfe von Crawling des Onlineshops oder gängiger Bewertungsplattformen generiert wird (Weichel und Herrmann 2016; Kim 2023). Die Daten sind dabei primär qualitativ, was die Auswahl der verwendbaren Modelle einschränkt.

Kundenverhalten: Neben der Kundenmeinung ist auch das Verhalten für die Prognose relevant. So kann aus den Suchabfragen nach dem Unternehmen, dem Produkt oder auch den Funktionen das Interesse von Kunden abgeleitet werden. Im Optimalfall konvertieren diese Anfragen nach gewisser Zeit auch in einen Absatz (Fritzs et al. 2017). Ein ähnlicher Indikator ist die Besucherzahl der Internetseite (Choi und Varian 2012; Saura et al. 2017). Eine andere Größe das Verhalten zu charakterisieren ist der Clickstream bzw. der Flow-of-Users, wo die einzelnen Unterseiten verfolgt werden, um das Verhalten auf der Seite und die Herkunft der potenziellen Kunden zu analysieren (Huang und van Mieghem 2014).

Umwelt: Einen besonderen Einfluss auf die Absatzverteilung hat der Kalender. Schließungen durch Feiertage, Ferien oder Großereignisse können einen Einfluss auf den Absatz ausüben. Daher existieren viele Modelle, wie Prophet, welche solche Ereignisse miteinbeziehen (Fildes et al. 2022; Kim 2023). Einige Produkte haben zudem eine gewisse Wetterabhängigkeit. So wird Sommerkleidung meist dann gekauft, wenn das Wetter gut ist und sie entsprechend benötigt wird. Daher werden auch Wetterdaten wie Temperatur oder Niederschlag bei Prognosen genutzt (Weichel und Herrmann 2016; Fildes et al. 2022).

Tabelle 2: Nutzung verschiedener Datenquellen in der Literatur

	Assmus et al. 1984	Choi und Varian 2012	Schuh und Stich 2012	Osadchy et al. 2013	Huang und van Mieghem 2014	Weichel und Hermann 2016	Fritzschi et al. 2017	Ort et al. 2017	Qu et al. 2017	Saura et al. 2018	Sagaert et al. 2018a	Sagaert et al. 2018b	Tarallo et al. 2019	Verstraete et al. 2019	Mir et al. 2020	Fildes et al. 2021	Shiha et al. 2022	Wang und Gu 2022	Hellmers López et al. 2023	Kim 2023
Absatzdaten	○	○	○	●	●	○	○	●	○	○	●	●	○	●	●	●	○	●	●	
Experteninformationen	●	○	○	●	●	○	○	○	●	○	○	●	○	●	●	●	○	●	●	
Konjunkturdaten	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	
Kundenmeinung	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	
Kundenverhalten	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	
Marketing	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	
Marktdaten	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	
Umweltinformationen	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	

- Nicht verwendet
- Erwähnt als mögliche Quelle
- Erwähnt, dass andere Autoren dies gemacht haben ODER in anderem Bereich (z.B. Price prediction) angewendet
- Verwendung der Autoren

Interviewstudie

Zusätzlich zur Recherche wurde eine Interviewstudie durchgeführt, in deren Rahmen die Potentiale der einzelnen Datenquellen abgefragt wurden. Gleichzeitig wurde der Forschungsgegenstand weiter spezifiziert, in dem einzelne Anforderungen aus dem Kriterienkatalog zusätzlich überprüft wurden. Die Gewichtung ist bereits in der Beschreibung des Kriterienkatalogs implementiert (s.o.), dient aber als Grundlage für die Umsetzung des IT-Tools.

Ziel: Potential der Datenquellen und Gewichtung der Anwenderanforderungen

Vorgehen: Die Umfrage wurde intern im PA sowie mit extern interessierten Unternehmen durchgeführt. Die Befragung gliederte sich in drei thematische Bereiche:

- **Allgemeine Unternehmensinformationen:** Hierbei wurden Angaben zur Unternehmensgröße, Branchezugehörigkeit und zum Digitalisierungsgrad erhoben, um die Ergebnisse in einen betrieblichen Kontext einordnen zu können.
- **Anforderungen an die Absatzprognose:** Die Unternehmen wurden hinsichtlich verschiedener Kriterien wie Prognosegenauigkeit, Vorhersagehorizont, Mustererkennung, Prognosegeschwindigkeit sowie dem Aufwand der Datenbeschaffung befragt.
- **Einschätzungen zur Datenanreicherung:** Es erfolgte eine Bewertung verschiedener Datenquellen (s.o.) anhand einer fünfstufigen Skala.

Für die Berechnung der arithmetischen Mittelwerte wurden Enthaltungen aus der Stichprobe systematisch ausgeschlossen, um repräsentative Durchschnittswerte zu erzielen.

Ergebnis: Die Erhebung von Unternehmensgröße, Branche und Digitalisierungsgrad ermöglichte eine kontextuelle Einordnung der Ergebnisse. Es zeigte sich, dass 61,5 % der Teilnehmer Kleinunternehmen (1–50 Mitarbeiter) repräsentieren, 7,7 % mittelständische Unternehmen und 30,8 % Großunternehmen (über 250 Mitarbeiter). Darüber hinaus deutet die Branchenzuordnung – mit einem hohen Anteil an Unternehmen aus der Fertigungs- und Dienstleistungsindustrie – auf ein breites Spektrum betrieblicher Anforderungen hin. Die Selbsteinschätzung des Digitalisierungsgrads (überwiegend als fortgeschritten bis Expertenstatus) untermauert die fachliche Relevanz der erhobenen Daten.

Anforderungen an die Absatzprognose: Die befragten Unternehmen wurden hinsichtlich der benötigten Prognosegenauigkeit, des Vorhersagehorizonts, der Erkennung von Mustern und der notwendigen Geschwindigkeit bei der Prognoseerstellung befragt.

- *Prognosegenauigkeit:* Es wurde zwischen einer Mindestgenauigkeit für eine erste Nutzung und einem Zielwert für den dauerhaften Einsatz differenziert. Die meisten Unternehmen favorisieren in beiden Fällen Werte im Bereich von 90–95 %, was auf einen hohen Qualitätsanspruch an die Prognoseergebnisse schließen lässt.
- *Vorhersagehorizont:* Die Antworten zeigten eine hohe Heterogenität. Während einzelne Unternehmen Tages- oder Wochenhorizonte präferierten, setzen andere auf monatliche, quartalsweise oder jahresbezogene Prognosen. Diese Vielfalt reflektiert die unterschiedlichen Anforderungen je nach Branchenfokus und unternehmerischem Bedarf, vor allem aber in Bezug auf die mit der Absatzprognose zu lösenden Aufgaben.
- *Mustererkennung:* Die Relevanz der Erkennung langfristiger Trends, Saisonalitäten und weiterer spezifischer Absatzmuster wurde durchgehend mit hohen Mittelwerten (zwischen 4,20 und 4,33 auf einer Skala von 1 bis 5) bewertet. Diese Ergebnisse belegen, dass das Erfassen von Mustern als Schlüsselfaktor zur Verbesserung der Prognosegüte angesehen wird.
- *Prognosegeschwindigkeit:* Obwohl keines der befragten Unternehmen eine Echtzeitprognose fordert, zeigt sich, dass 39 % eine Vorhersage innerhalb von Minuten und 46 % innerhalb von Stunden als ausreichend erachten. Dies deutet darauf hin, dass ein Trade-off zwischen Modellkomplexität und Verarbeitungszeit akzeptiert wird, solange die Vorhersagezeiten innerhalb eines wirtschaftlich relevanten Rahmens liegen.
- *Aufwand der Datenbeschaffung:* Mit einem arithmetischen Mittel von 3,8 wurde ein moderater Aufwand bewertet. Interessanterweise steht dieser Befund in einem gewissen Spannungsverhältnis zu den hohen Anforderungen an die Prognosegenauigkeit, was auf ein mögliches Optimierungspotential hinsichtlich der Effizienz der Datenintegration hinweist.

Bewertung der Datenanreicherung: Die Studie untersuchte das Potential verschiedener Datenquellen zur Verbesserung der Absatzprognose. Dabei wurden die Datenquellen auf einer Skala von 1 (niedrig) bis 5 (hoch) bewertet:

- *Niedriges Potential:* Wetterdaten erreichten mit einem Mittelwert von 1,92 lediglich ein geringes Potential.
- *Mittel bis hohes Potential:* Social-Media-Daten (Mittelwert: 3,00), CRM-Daten (3,50), Kalenderdaten (3,54) und Wirtschaftsindikatoren (3,62) werden als nützlich eingeschätzt, jedoch mit moderater Relevanz.
- *Hohes Potential:* Kundenfeedback und Bewertungen (3,77), branchenspezifische Indikatoren (4,00), historische Absatzdaten von Vergleichsprodukten (4,00), Lieferketteninformationen (4,08) und Marktinformationen (4,25) erzielen hohe Mittelwerte. Diese Datenquellen werden als besonders aussagekräftig für die Verbesserung der Prognosemodelle bewertet, da sie wesentliche unternehmens- und branchenspezifische Kontextinformationen liefern.

Die Ergebnisse der Interviewstudie liefern mehrere wichtige Erkenntnisse, die für die Weiterentwicklung des IT-Tools und die strategische Ausrichtung der Absatzprognose von zentraler Bedeutung sind:

Hohe Anforderungen an Prognosequalität und Datenintegration: Die überwiegend sehr hohen Erwartungen an die Prognosegenauigkeit (90–95 %) unterstreichen den Bedarf an robusten und präzisen Modellen. Gleichzeitig weist der moderate Aufwand für die Datenbeschaffung auf eine Diskrepanz hin: Unternehmen erwarten exzellente Prognoseergebnisse, sind jedoch nicht bereit, einen überproportional hohen Ressourceneinsatz zu betreiben.

Heterogenität der Vorhersagehorizonte: Die Vielfalt in den Anforderungen an den Vorhersagehorizont signalisiert, dass ein flexibles und anpassbares Prognosesystem notwendig ist. Ein modularer Aufbau des IT-Tools muss es ermöglichen, unterschiedliche Zeithorizonte zu berücksichtigen, ohne dass Kompromisse bei der Prognosegenauigkeit oder -geschwindigkeit eingegangen werden müssen.

Relevanz der Mustererkennung: Die hohen Bewertungen im Bereich der Mustererkennung unterstreichen die Bedeutung, langfristige Trends, Saisonalitäten und weitere Absatzmuster in die Modellierung zu integrieren. Diese Erkenntnis ist insbesondere vor dem Hintergrund der dynamischen Marktentwicklungen von hoher Relevanz und unterstützt die Forderung nach fortgeschrittenen Analysemethoden, etwa unter Einsatz von Machine-Learning-Algorithmen.

Priorisierung der Datenquellen für die Anreicherung: Die differenzierte Bewertung der Datenquellen legt nahe, dass nicht alle verfügbaren Daten gleichermaßen in die Prognosemodelle einfließen sollten. Datenquellen wie Marktinformationen, Lieferketteninformationen, historische Absatzdaten und branchenspezifische Indikatoren besitzen ein sehr hohes Verbesserungspotential und sollten daher priorisiert werden. Die geringen Bewertungen von Wetterdaten deuten darauf hin, dass deren Beitrag zur Absatzprognose begrenzt ist oder mit einem hohen Aufwand verbunden ist, der nicht im Verhältnis zum erzielten Mehrwert steht.

Die Interviewstudie zeigt, dass Unternehmen sehr hohe Ansprüche an die Qualität ihrer Absatzprognosen stellen, jedoch zugleich Wert auf Effizienz und moderate Aufwände bei der Datenbeschaffung legen. Besonders hervorzuheben ist das hohe Potential von Datenquellen, die tiefgreifende branchenspezifische und

historische Informationen liefern. Diese Erkenntnisse sind essenziell für die zielgerichtete Entwicklung eines IT-Tools und der potentiellen Generalisierung eines Modells, das nicht nur den technischen Anforderungen gerecht wird, sondern auch die betrieblichen Gegebenheiten und Ressourcenvorgaben der Unternehmen berücksichtigt. Die Studienergebnisse bieten somit eine differenzierte Entscheidungsgrundlage für die Priorisierung von Funktionen und Datenquellen in der weiteren Projektentwicklung und unterstreichen die Bedeutung einer integrierten, flexiblen Systemarchitektur.

Zusammenfassung und Erkenntnisse aus AP 2

Die durchgeführte Potentialanalyse ergab, dass eine Vielzahl an potenziell nutzbaren Datenquellen zur Verbesserung der Absatzprognose identifiziert werden konnte. Dabei erstreckte sich das Spektrum von internen Absatz- und CRM-Daten bis hin zu externen Marktdaten, Konjunkturindikatoren und Experteneinschätzungen. Die Potentialbewertung der einzelnen Quellen durch die Umfrage zeigte, dass insbesondere branchen-spezifische Indikatoren, historische Absatzdaten, Lieferketten- sowie Marktinformationen ein hohes Potential für die Absatzprognose bieten, während andere Daten – wie beispielsweise Wetterdaten – nur einen geringen Mehrwert liefern zu scheinen. Die quantitative Analyse mit Pearson-Korrelation und Granger-Kausalität ergab keine allgemeingültigen Aussagen.

Im Rahmen der zweiten PA-Sitzung, in der die Ergebnisse der Umfrage eingehend diskutiert wurden, kristallisierten sich darüber hinaus zentrale Themen heraus, die für die zukünftige IT-Tool-Entwicklung von besonderer Relevanz sind. Neben den rein prognosetechnischen Aspekten rückten insbesondere Datensicherheit und Erklärbarkeit (Explainable AI) in den Vordergrund. Die Diskussion und die Bewertung des Kriterienkatalogs – ergänzt durch das aus der CIRP CMS resultierende Paper – verdeutlichten, dass für die Anwender eine individuelle, nachvollziehbare Lösung wesentlich wichtiger ist als ein generalisiertes Modell, dessen Entscheidungsgrundlagen und interne Logik nicht transparent dargestellt werden.

Die empirisch gestützten Erkenntnisse aus der Interviewstudie und der anschließenden PA-Sitzung liefern eine solide Basis für die Weiterentwicklung des IT-Tools. Dabei ergeben sich folgende wesentliche Implikationen:

Balance zwischen Prognosegenauigkeit und Ressourceneinsatz: Die hohen Erwartungen an die Genauigkeit der Absatzprognosen müssen mit einem pragmatischen Einsatz der verfügbaren Ressourcen in Einklang gebracht werden. Ein flexibles Systemdesign, das unterschiedliche Vorhersagehorizonte und variable Datenanreicherungsoptionen integriert, kann den heterogenen Anforderungen der Unternehmen gerecht werden.

Individualisierung und Erklärbarkeit: Die Ergebnisse unterstreichen die Notwendigkeit, individuelle Lösungen zu entwickeln, die den spezifischen Bedürfnissen der Anwender entsprechen. Dabei ist es entscheidend, dass die Modelle nicht als „Black Box“ agieren, sondern durch Erklärbarkeitsmechanismen (Explainable AI) nachvollziehbar gemacht werden. Dies fördert die Akzeptanz der Prognoseergebnisse und ermöglicht den Entscheidungsträgern, die Herkunft und Logik der Vorhersagen besser zu verstehen.

Sensitivität und Schutz kritischer Daten: Wissenschaftlich fundierte Normen, wie die DIN EN ISO/IEC 27001:2024-01, belegen die Sensitivität von Absatz- und CRM-Daten, da diese als schützenswerte Unternehmensressourcen klassifiziert sind. Absatzdaten liefern kritische Informationen zur Marktpositionierung und Wettbewerbsfähigkeit, während CRM-Daten detaillierte Einblicke in Verkaufsstrategien und Kundenbeziehungen bieten. Darüber hinaus hebt das IT-Grundschutz-Kompendium (BSI - Bundesamt für Sicherheit in der Informationstechnik 2018) hervor, dass der Schutz wettbewerbsrelevanter Informationen unabdingbar ist,

da deren Verlust oder unautorisierte Offenlegung erhebliche Nachteile für das Unternehmen mit sich bringen kann.

Zusammenfassend zeigt die Potentialanalyse, dass neben der reinen Erfassung und quantitativen Bewertung verfügbarer Datenquellen insbesondere die Aspekte der Datensicherheit und Erklärbarkeit eine zentrale Rolle einnehmen müssen. Diese Erkenntnisse legen nahe, dass zukünftige IT-Tool-Entwicklungen nicht nur auf eine hohe Prognosegenauigkeit und flexible Datenintegration abzielen sollten, sondern auch die individuellen Anforderungen und Sicherheitsaspekte der Unternehmen umfassend berücksichtigen müssen. Die Kombination dieser Faktoren stellt sicher, dass das entwickelte System einerseits technisch robust und ressourceneffizient ist und andererseits in der Praxis von den Anwendern als nachvollziehbar und vertrauenswürdig akzeptiert wird. All dies wurde nachträglich im Kriterienkatalog ergänzt, der in Kapitel 5.1 aufgeführte Katalog ist final.

3.3 Arbeitspaket 3: Methodik zur AB-Planung mit ML-Verfahren, Benchmarking und Pilotierende Umsetzung der AB-Prognose

Die pilotierende Umsetzung der AB-Prognose baut auf den in AP 2 gewonnenen Erkenntnissen zur Identifikation und Gewichtung potenzieller Datenquellen auf und integriert diese in einen iterativen, datenanalytischen Entwicklungsprozess gemäß dem CRISP-DM-Framework. Im Fokus stehen dabei die Datenvorbereitung, Modellierung und Evaluation, um mit den in AP 2 ermittelten Anreicherungsdaten neue Anwendungsgebiete zu erschließen und den Mehrwert der zusätzlichen Datenintegration empirisch zu belegen.

Teilergebnisse im Rahmen des Arbeitspaket 3

Erstellung von zeitreihenbasierten Referenzprognosen als Vergleichsmaßstab ohne Datenanreicherung

Ziel: Auswahl eines geeigneten Pilotdatensatzes und Benchmarking von Prognosemodellen der einsatzbereiten Ansätze

Vorgehen: Der verwendete Datensatz umfasst Absatzdaten eines Anwenderunternehmens über den täglichen Verkauf von Produkten über einen Zeitraum von zehn Jahren (2014-2023). Dabei verkauft das Anwenderunternehmen ihre Produkte in einer Variantenanzahl im vierstelligen Bereich. Die Auswahl einer passenden Aggregationsebene erwies sich als problematisch, da für verschiedene Aufgabenstellungen unterschiedliche Aggregationsansätze erforderlich sind. Während für Einkaufsprozesse oft eine gröbere Aggregation auf Basis von Materialien und Halbzeugen der Produkte aus den Stücklisten ausreichend ist, benötigt beispielsweise die Maschinenbelegungsplanung eine detailliertere Betrachtung der Produktvarianten. Aus praktischer Sicht führte die Betrachtung der Einzelproduktbene häufig zu einer extrem hohen Anzahl von Varianten - wie in diesem Fall im Tausenderbereich -, was die Modellierung und Evaluierung zusätzlich erschwert.

Um diesen Herausforderungen zu begegnen, wurde ein sehr granularer Datensatz gewählt und zugleich eine Produktfamilienbildung implementiert. Dabei wurden die ursprünglichen Absatzdaten der Einzelprodukte auf 40 Produktfamilien aggregiert. Jede dieser Familien fasst zahlreiche Varianten zusammen. Diese Gruppenbildung folgt den Prozessrouten innerhalb des Betriebs und rückt damit die PPS in den Fokus. Dieser Ansatz ermöglichte es, die Komplexität zu reduzieren, indem Produkte mit ähnlichen Fertigungswegen und -

anforderungen in Familien zusammengefasst wurden, ohne dabei wichtige spezifische Unterschiede zu verlieren.

Die Entscheidung, die Aggregationsebene an den betrieblichen Prozessabläufen auszurichten, fußte auf Erkenntnissen in der zweiten PA-Sitzung.

Die Absatzwerte variieren dabei stark zwischen den Produktfamilien. Einige Familien zeigen kontinuierlich hohe Verkaufszahlen, während andere lediglich sporadische Verkäufe oder häufig Nullwerte aufweisen. Diese unterschiedliche Dynamik ermöglicht eine erste Klassifizierung in stark nachgefragte („Top-Seller“) und weniger nachgefragte („Slow-Mover“) Produktfamilien. Die Top-Seller zeichnen sich durch eine konstante, hohe Verkaufsfrequenz aus, was auf eine solide Grundnachfrage oder ein kontinuierliches Angebot hindeutet. Im Gegensatz dazu sind die Slow-Mover von langen Perioden ohne Absatz geprägt. Diese Verhaltensmuster können darauf hinweisen, dass solche Produkte entweder nur saisonal, auf Abruf oder in begrenzten Mengen produziert werden.

Darüber hinaus lassen sich anhand der Daten weitere Absatzmuster erkennen. Einige Produktfamilien unterliegen ausgeprägten saisonalen Schwankungen, bei denen regelmäßige Anstiege und Rückgänge im Absatz erkennbar sind. Andere Familien zeigen plötzliche Peaks, die auf kurzfristige Aktionen, Kampagnen oder externe Einflüsse zurückzuführen sein könnten. Es gibt auch Fälle, in denen ein stetiger Abwärtstrend zu beobachten ist, was darauf hindeuten könnte, dass diese Produkte langfristig an Relevanz verlieren oder durch neuere Alternativen ersetzt werden.

Zusammengefasst bietet der Datensatz eine fundierte Grundlage für zahlreiche Analysen. Er ermöglicht es, sowohl kurzfristige Schwankungen als auch langfristige Trends und saisonale Effekte zu identifizieren. Die Aggregation von Tausenden einzelner Produktvarianten zu 40 überschaubaren Produktfamilien erleichtert außerdem die statistische Auswertung. Die Benchmarking-Ergebnisse wurden mittels eines systematischen, mehrstufigen Ansatzes erzielt. So wurden mehrere zeitreihenbasierte Prognosemodelle – von einfachen Ansätzen wie Seasonal Naive und Moving Average bis hin zu komplexeren Methoden wie ARIMA, Prophet, LSTM, GRU, SES, SARIMA, Holt Winters, XGBoost, RandomForest und Ensemble-Methoden – entwickelt und optimiert.

Für jeden Modelltyp erfolgte die Berechnung der Prognosegüte anhand des sMAPE (symmetric Mean Absolute Percentage Error). Dabei wurden verschiedene Vorhersagezeiträume (1 Monat, 6 Monate, 12 Monate und 36 Monate) als Horizonte betrachtet. Die Resultate – also die durchschnittlichen sMAPE-Werte pro Modell und Zeithorizont – wurden visualisiert und verglichen. Die Verarbeitung, Modellierung, Analyse und Visualisierung wurde mit Python durchgeführt.

Ergebnis: Die Analyse der zeitreihenbasierten Referenzprognosen, die ohne zusätzliche Datenanreicherung erstellt wurden, liefert einen umfassenden Einblick in die Leistungsfähigkeit der eingesetzten Prognosemodelle über verschiedene Vorhersagezeiträume hinweg.

Benchmarking-Ergebnisse nach Prognosehorizonten

- **1-Monats-Horizont:** Bei kurzfristigen Prognosen zeigen sich einfache Modelle als besonders leistungsfähig. So erreichte der Saisonal Naive-Ansatz einen durchschnittlichen sMAPE von 78,67 %, gefolgt von Moving Average (81,71 %) und Prophet (95,66 %). Diese Resultate deuten darauf hin, dass kurzfristige saisonale und trendbasierte Muster weitgehend durch einfache Modelle adäquat erfasst werden können.

- **6-Monats-Horizont:** Bei mittelfristigen Vorhersagen zeigt sich Moving Average als führend mit einem sMAPE von 103,42 %, während Saisonale Naive (107,62 %) und Random Forest (119,37 %) die Top-3 abrunden. Die Zunahme der Fehlerwerte im Vergleich zum 1-Monats-Horizont spiegelt die erhöhte Unsicherheit und Variabilität bei längeren Prognosezeiträumen wider.
- **12-Monats-Horizont:** Für Jahresprognosen sind Moving Average (105,85 %) und Saisonale Naive (109,01 %) weiterhin gut geeignet, während Random Forest mit einem sMAPE von 118,37 % ebenfalls starke Ergebnisse liefert. Dies zeigt, dass auch bei längeren Vorhersagen einfache Methoden oft robuste Ergebnisse liefern, obwohl komplexere Modelle zum Teil höhere Fehlerwerte aufweisen.
- **36-Monats-Horizont:** Überraschenderweise sinkt der Fehler bei sehr langfristigen Prognosen teilweise wieder: Moving Average erreichte einen sMAPE von 101,81 % und Random Forest 102,47 %, während Seasonal Naive (111,67 %) etwas schlechter abschnitt. Diese Entwicklung könnte auf Aggregationseffekte und die Stabilisierung langfristiger Trends hindeuten.

Neben der Auswertung der sMAPE-Werte liefert das Benchmarking weitere wertvolle Kennzahlen, die das Gesamtbild der Modellperformance abrunden.

Die Auswertung, wie oft ein bestimmtes Modell als Bestes identifiziert wurde, unterstreicht, dass auch komplexe Modelle häufig als beste Lösung hervortreten, wenn sie in der Lage sind, nichtlineare Zusammenhänge adäquat zu modellieren. Dabei erzielen KI-basierte Ansätze wie LSTM oder GRU trotz suboptimaler Trainingsbedingungen in bestimmten Zeiträumen stabile und konkurrenzfähige Vorhersagen.

Eine weitere Metrik, die aus dem Benchmarking hervorgeht, ist der Anteil der Vorhersagen, die einen Fehler von weniger als 20 % aufweisen. Diese Kennzahl zeigt, dass selbst Modelle mit moderaten durchschnittlichen sMAPE-Werten bei verschiedenen Produkten in unterschiedlichen Prognosehorizonten eine hohe Erfolgsrate erzielen. Insbesondere KI-Modelle beweisen, dass sie in vielen Fällen innerhalb eines akzeptablen Fehlerpektrums stabile Vorhersagen liefern – ein Hinweis darauf, dass sie trotz gelegentlicher Überanpassung oder Fehlerhaftigkeit in bestimmten Szenarien eine robuste Prognosequalität aufweisen.

Insgesamt fallen die Ergebnisse jedoch im Durchschnitt schlecht aus, was mehrere Ursachen haben kann:

Datenkomplexität und Heterogenität: Die Aggregation von tausenden Einzelproduktvarianten zu 40 Produktfamilien reduziert zwar die Komplexität, führt aber gleichzeitig zu einer erheblichen Varianz innerhalb der Familien. Unterschiedliche Absatzmuster – von konstant hohen Verkaufszahlen bei Top-Sellern bis hin zu sporadischen oder saisonalen Verläufen bei Slow-Movern innerhalb einer einzigen Produktfamilie – erhöhen die Unsicherheit in den Vorhersagen. Eine aus technischer Sicht gesehene Produktfamilie verkauft sich demnach nicht in gleichen Mustern.

Modellierung und Parameteroptimierung: Insbesondere komplexere Modelle wie ARIMA, LSTM, GRU oder ensemblebasierte Ansätze können aufgrund unzureichender Kalibrierung und möglicher Überanpassung anfällig sein. Eine nicht optimale Abstimmung der Hyperparameter führt dazu, dass diese Modelle in manchen Fällen nicht konsistent bessere Ergebnisse liefern als einfachere Basismodelle.

Natur der Absatzdaten: Absatzdaten unterliegen häufig externen Einflüssen, abrupten Veränderungen durch Aktionen und Schwankungen, die keinem klaren Muster unterliegen. Diese Faktoren sind schwer vollständig in univariaten Modellen zu berücksichtigen und erhöhen die prognostische Unsicherheit.

Die Ergebnisse der Benchmarking-Studie verdeutlichen, dass einfache Modelle wie SeasonalNaive und Moving Average insbesondere bei kurzfristigen und mittelfristigen Vorhersagen solide Leistungen erbringen. Gleichzeitig zeigen zusätzliche Auswertungen wie die der besten Modelle und die Erfolgsrate (20% Abweichungsfenster), dass selbst KI-basierte Ansätze - trotz moderater durchschnittlicher sMAPE-Werte - in vielen Fällen stabile und wettbewerbsfähige Vorhersagen liefern. Die moderaten Gesamtresultate unterstreichen die inhärente Komplexität des Anwendungsfalls und weisen auf Optimierungspotenziale hin, beispielsweise durch verbesserte Parameteranpassung oder den Einsatz zusätzlicher erklärender Variablen im Rahmen künftiger Datenanreicherungsmaßnahmen.

Insgesamt bildet dieser Ansatz eine belastbare Basis für die weitere Optimierung und Evaluierung des IT-Tools, um den analytischen Mehrwert zukünftiger Datenanreicherungsmaßnahmen systematisch zu überprüfen und die Prognosegüte langfristig zu steigern.

Methodik zur AB-Prognose unter Zuhilfenahme der angereicherten Datenquellen

Auf Basis des Kriterienkatalogs und der damit verbundenen Anwenderanforderungen, den detaillierten Erkenntnissen zur Datenanreicherung aus Kapitel 5.2 sowie den Benchmarking-Ergebnissen der Referenzprognosen aus Kapitel 5.3.1 wurde eine allgemeingültige Methodik formuliert, die als zentrales Projektergebnis für die Pilotierung und spätere Entwicklung des IT-Werkzeugs dient. Die zentrale Erkenntnis ist, dass eine prädiktive Absatz- und Bedarfsplanung in der kundenorientierten Auftragsfertigung mittels ML-Verfahren nicht durch ein universelles, generalisiertes KI-Modell realisiert werden sollte. Stattdessen sprechen die Erkenntnisse der ersten Arbeitspakete dafür, dass der heterogene Charakter der Anwender, ihrer Produktionsprozesse und der verfügbaren Datenquellen einen individualisierten Ansatz erfordert. Unternehmen müssen in die Lage versetzt werden, unterschiedliche Modelle anhand ihrer Vorhersageleistung zu vergleichen und eigenständig zu entscheiden, welche Daten sie zur Anreicherung nutzen - unterstützt durch entwickelte Gruppierung der Anwender.

Die Methodik orientiert sich, wie die Projektbearbeitung am CRISP-DM-Framework, da die Absatzprognose eine Data-Mining-Aufgabenstellung ist. Dabei bilden die folgenden Phasen den Rahmen:

- 1. Business Understanding:** In dieser Phase erfolgt die Ermittlung des Geschäftsverständnis. Dabei findet die Klassifizierung der Anwender anhand der in Kapitel 5.1 ermittelten Kriterien statt. Die Unternehmen werden basierend auf Aspekten wie der industriellen Klassifikation, dem Unternehmenslebenszyklus, geographischen Einflüssen sowie internen Produktions- und Vertriebsstrukturen eingeordnet. Diese Gruppierung definiert den *potenziellen Einsatz von Datenquellen*. Außerdem müssen Anwender ihre Aufgabe bestimmen, die sie mithilfe der Absatzprognose lösen wollen, und damit den *Prognosehorizont* bestimmen, der in der weiteren Analyse berücksichtigt wird.
- 2. Data Understanding:** Aufbauend auf den in Kapitel 5.2 gewonnenen Erkenntnissen wird analysiert, welche internen und externen Datenquellen den Anwenderunternehmen zur Verfügung stehen und welche für die Absatzprognose verwendet werden sollen. Dabei werden Absatzdaten analysiert, um Aspekte wie Datenqualität, -granularität und typische Muster (z. B. saisonale Schwankungen, Trends und Ausreißer) zu identifizieren. Diese Analyse *begrenzt gleichzeitig die Auswahl der geeigneten Prognoseverfahren*. Externe Datenquellen mit großem Potential (siehe Umfragestudie, Kapitel 5.2.) werden dem Anwender niederschwellig bereitgestellt.

3. **Data Preparation:** Die Vorbereitung der Daten umfasst die Vorverarbeitung der Absatzdaten aus der Vergangenheit sowie die Zusammenführung und Harmonisierung mit den angereicherten Datenquellen.
4. **Modelling:** In dieser Phase werden verschiedene Prognosemodelle angewendet - von klassischen statistischen Ansätzen wie exponentielle Glättung und ARIMA bis hin zu modernen ML-Verfahren wie LSTM, GRU, Random Forest und kombinierten Ensemble-Methoden. Die Benchmarking-Ergebnisse aus Kapitel 5.3.1 haben gezeigt, dass einfache statistische Modelle insbesondere bei kurzen Vorhersagezeiträumen häufig robustere Ergebnisse liefern als komplexe KI-Modelle. Daher müssen den Anwendern alle Verfahren – univariat wie multivariat - zur Verfügung stehen, sodass sie je nach Anforderung und Prognosehorizont individuell entscheiden können, welcher Ansatz für ihren speziellen Fall am besten geeignet ist. So können Anwender selbst entscheiden, inwiefern sie – falls nötig – zwischen Erklärbarkeit ihrer Vorhersage und besten Vorhersageergebnissen wählen möchten.
5. **Evaluation:** Die Modelle werden anhand eines breiten Spektrums von Gütekriterien bewertet. Neben der Berechnung des sMAPE werden auch Kennzahlen wie MAE, RMSE sowie die individuellen Kriterien wie Rechenzeit und Speicherbedarf herangezogen, um die Vorhersagegüte und Stabilität genauso wie die technische Anforderung der Modelle zu beurteilen.
6. **Deployment:** Abschließend wird mit ausgewählten Verfahren die Prognose für zukünftige Absätze erzeugt. Diese muss in die bestehenden Unternehmensprozesse integrierbar sein. Dadurch wird sichergestellt, dass die individuell optimierten Prognoseansätze praxisnah und flexibel in die PPS eingebunden werden können.

Zusammengefasst zeigt diese Methodik, dass die prädiktive Absatz- und Bedarfsplanung in der kundenorientierten Auftragsfertigung nicht durch einen einheitlichen KI-Ansatz, sondern durch einen flexiblen, CRISP-DM-orientierten Prozess realisiert werden kann. Die gewonnenen Erkenntnisse aus den vorangegangenen Kapiteln bestätigen, dass Unternehmen von einem individuell angepassten Vergleich verschiedener Prognosemodelle profitieren - sie können eigenständig entscheiden, welche Datenquellen zur Anreicherung genutzt werden sollen und welches Modell ihren spezifischen Anforderungen am besten entspricht. Diese Herangehensweise bildet somit die Grundlage für die pilotierende Umsetzung der AB-Prognose und die spätere Entwicklung eines IT-Werkzeugs, das den praktischen Mehrwert der Datenanreicherung in der kundenzentrierten Auftragsfertigung nachhaltig unterstützt.

Pilotierende Umsetzung der Methodik zur AB-Prognose bei mehreren Anwenderunternehmen

Anschließend wurde die zuvor entwickelte Methodik zur AB-Prognose - unter Zuhilfenahme zusätzlicher Datenquellen - in mehreren Anwenderunternehmen praxisnah pilotiert. Diese Phase dient dazu, die Praxistauglichkeit der datenanalytischen Maßnahmen sowie den Mehrwert der ergänzenden Datenanreicherung in der kundenzentrierten Auftragsfertigung systematisch zu evaluieren. Dabei sollen nicht nur die technischen Aspekte der Datenvorbereitung, Modellierung und Evaluation überprüft werden, sondern auch die Anwendbarkeit der Prognoseergebnisse im betrieblichen Kontext.

Ziel: Pilotierende Umsetzung der Methodik zur AB-Prognose bei mehreren Anwenderunternehmen

Vorgehen: Im Anschluss an die in Kapitel 5.3.2 beschriebene Entwicklung einer allgemeinen Methodik zur AB-Prognose wurde diese in drei ausgewählten Anwenderunternehmen pilotiert. Die Auswahl der

Pilotpartner erfolgte nach den in Kapitel 5.1 definierten Kriterien, um ein möglichst breites Spektrum unterschiedlicher Unternehmensgrößen, Branchen und Produktions- bzw. Vertriebsstrukturen abzudecken. Aus Gründen der Vertraulichkeit werden die Unternehmen im Folgenden als Unternehmen A, Unternehmen B und Unternehmen C bezeichnet.

Unternehmen A ist ein großer Industriebetrieb, bei dem ihr Kernprodukt im Fokus der Betrachtung stand, das bei eindeutigem Trendverlauf erfahrungsgemäß stark von gesamtwirtschaftlichen und konjunkturellen Einflussfaktoren abhängt. Unternehmen B, ein mittelständischer Hersteller langlebiger Gebrauchsgüter, wurde in die Pilotierung einbezogen, um eine primär explorative Datenanalyse und Prognose durchzuführen. Dabei spielte insbesondere die Erschließung neuer, zuvor ungenutzter Datenquellen eine wesentliche Rolle. Unternehmen C, ein kleines Unternehmen, das Halbzeuge bzw. Vormaterialien für verschiedene weiterverarbeitende Branchen liefert, brachte einen weiteren Anwendungsfall ein.

Zu Beginn der Pilotierung erfolgte in enger Abstimmung mit den jeweiligen Partnern die Festlegung bestimmter Ziele, die mit der Anwendung der Prognosemethodik verfolgt werden sollten, um das Vorgehen daraufhin zu prüfen. Dazu gehörte unter anderem die Bestimmung geeigneter Prognosehorizonte (z. B. kurzfristige vs. mittelfristige Horizonte), die Auswahl relevanter Gütekriterien für den Modellvergleich (z. B. sMAPE, RMSE, Rechenzeit, Modellinterpretierbarkeit) sowie die Festlegung, in welchem Umfang und mit welcher Priorität externe Datenquellen eingebunden werden sollten. Auf dieser Basis wurde eine strukturierte Datenakquise und -aufbereitung in allen drei Unternehmen durchgeführt. Diese umfasste neben der Zusammenführung historischer Absatzdaten auch die Bereinigung von Ausreißern und fehlenden Werten und die Anpassung der Zeitauflösung an den jeweils gewählten Prognosehorizont. Danach wurden die weiteren Phasen entsprechend durchgeführt.

Alle Analysen wurden mit Python durchgeführt und so gestaltet, dass sie für weitere Prozesse wiederverwendbar sind und im IT-Tool integriert werden können

Ergebnis: Die Ergebnisse zeigten, dass sich in allen Pilotszenarien durch die Methodik konsistente Prognosen generieren ließen, die – je nach Anforderung – durch gezielte Datenanreicherungen und modellseitige Optimierungen verbessert werden konnten. Dabei wird die Pilotumsetzung bei Unternehmen A im Detail beschrieben, die Anwendung bei Unternehmen B und C auf die Besonderheiten begrenzt.

Unternehmen A:

Business Understanding: Das Unternehmen wurde als Großunternehmen im Bereich der Industrials unter der Gruppe Capital Goods entsprechend GICS einklassifiziert. Dabei sind insbesondere Europa, Asien und Nordamerika als Märkte und Produktionsstandorte interessant. In der Analyse und Prognose wurde nur ein Produkt betrachtet. Eine klare Aufgabe besteht in dieser Pilotumsetzung nicht, es dient eher als explorative Analyse und Vergleich mit bestehenden, spezialisierten Verfahren bei Unternehmen A selbst.

Data Understanding: Die Absatzzeitreihen umfassten den Absatz von drei aus verschiedenen Varianten gebildeten Produktgruppen einer Produktfamilie. Die Absatzzeitreihen aller Gruppen zeigen dabei einen sehr ähnlichen Verlauf über den Zeitraum 2013-2023. Auffällig ist dabei ein nahezu linearer Trend mit Streuung bis 2018. Bis Mitte 2020 verläuft der Absatz stationär, wonach über 2 Jahre ein starker linearer Trend folgt, auf den wieder eine stationäre Phase erfolgt. Im Rahmen der Pilotumsetzung zur Datenanreicherung der Absatzprognose wurde eine multiperspektivische Auswahl von Finanzmarktdaten entsprechend der Unternehmensklassifikation integriert.

- Konjunkturdaten: Für die entsprechend als relevant identifizierten Regionen wurden randomisiert Konjunkturdaten der Federal Reserve Economic Data (FRED-) Datenbank herangezogen. FRED ist eine vom Research-Bereich der Federal Reserve Bank of St. Louis gepflegte Online-Datenbank mit über 825.000 wirtschaftlichen Zeitreihen aus 114 Quellen. Sie bietet Daten zu Themen wie Inflation, Arbeitslosigkeit, Bruttoinlandsprodukt und Zinssätzen und ermöglicht Nutzern, diese Daten herunterzuladen, zu visualisieren und zu analysieren.

Grundlage für die weiteren Daten bildete Yahoo Finance. Yahoo Finance ist eine Finanznachrichten- und -datenplattform von Yahoo, die Echtzeit-Kurse, historische Marktdaten, Unternehmensanalysen und Finanznachrichten bereitstellt.

- *Aktien*: Es wurden Aktien ausgewählter Unternehmen herangezogen, die im ähnlichen Bereich tätig sind.
- *ETFs*: Thematisch fokussierte ETFs, welche Investitionen in Branchen wie Robotik, künstliche Intelligenz und industrielle Technologien abbilden, ergänzten die Aktienauswahl. Auch hier wurde bewusst auf die Anonymisierung geachtet, um eine Identifikation der Ausgangsfirma auszuschließen.
- *Rohstoffe*: Zusätzlich wurden Rohstoff-Ticker (Futures) integriert, die essenzielle Rohstoff- und Energiepreise repräsentieren. Diese Daten liefern wertvolle Informationen über die zugrunde liegenden Marktbedingungen, die ebenfalls in die Absatzprognose einfließen.

Data Preparation: In der Data Preparation wurden die relevanten externen Finanz- und Wirtschaftsdaten zunächst aus den identifizierten Quellen (FRED, Yahoo Finance) extrahiert und mit den unternehmensspezifischen Absatzzeitreihen harmonisiert. Dies umfasste eine Vereinheitlichung der Zeitstempel, eine Aggregation auf vergleichbare Granularitätsstufen sowie eine Bereinigung und Vervollständigung unvollständiger Werte. Zur Reduktion von Redundanz und zur Identifikation relevanter Einflussfaktoren wurden anschließend statistische Analysen durchgeführt. Hierzu zählten die Bestimmung von Korrelationen zwischen den exogenen Variablen und den Absatzzeitreihen, um potenziell relevante Prädiktoren zu selektieren, sowie kausale Analysen, um die Richtung und Stärke der Zusammenhänge zwischen externen Einflussgrößen und der Nachfrage zu bestimmen. Schließlich wurde ein multivariater Datensatz erstellt, der sowohl für univariate als auch multivariate Prognoseverfahren geeignet ist. Dabei wurde sichergestellt, dass alle Variablen eine konsistente Zeitstruktur aufweisen, sodass sowohl klassische Zeitreihenmodelle als auch ML-Verfahren die Daten ohne strukturelle Verzerrungen verarbeiten können.

Die Analyse der Korrelationen (siehe Abbildung 8, schlechte Lesbarkeit wegen Screenshot aus finalem IT-Tool, Anzeige des vollen Namens der Datenquelle zur Unterscheidung) zeigt, dass der Absatz des Produkts besonders stark mit den Aktienkursen mehrerer Industrie- und Technologieunternehmen zusammenhängt. Dies deutet darauf hin, dass die wirtschaftliche Entwicklung dieser Unternehmen – und möglicherweise der gesamte Industriesektor – in Zusammenhang mit der Nachfrage nach dem Produkt hat. Dies erscheint sinnvoll, da es sich um das Renner-Produkt einer wichtigen Sparte in diesem Segment handelt.

Neben den Aktienkursen wurde auch eine moderate bis schwache Korrelation mit Arbeitsmarktdaten festgestellt. Insbesondere die Zahl der Langzeitarbeitslosen und die durchschnittliche Dauer der Arbeitslosigkeit zeigen eine leichte negative Korrelation mit dem Absatz. Dies könnte darauf hinweisen, dass eine

Verschlechterung der Arbeitsmarktlage, insbesondere eine Zunahme der Langzeitarbeitslosigkeit, tendenziell mit einem Rückgang des Absatzes einhergeht. Allerdings sind diese Zusammenhänge weniger stark ausgeprägt als bei den Aktienkursen.

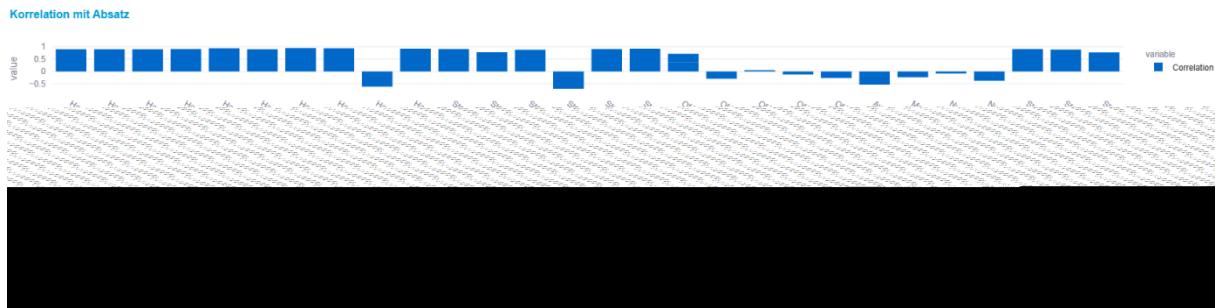


Abbildung 8: Korrelationsanalyse - Übersicht aus IT-Werkzeug (AP5)

Die Granger-Kausalitätsanalyse (siehe Abbildung 9, Grund für schlechte Lesbarkeit s. Abbildung 8) liefert Hinweise darauf, dass einige der betrachteten Variablen nicht nur mit dem Absatz korrelieren, sondern ihm auch zeitlich vorausgehen. Besonders auffällig ist die potenzielle Kausalität zwischen den Aktienkursen der betrachteten Industrieunternehmen und dem Absatz des Produkts. Dies deutet darauf hin, dass die wirtschaftliche Entwicklung dieser Unternehmen als ein Frühindikator für den Absatz genutzt werden könnte. Gleichzeitig ist die Kausalität generell nur als moderat einzustufen. Arbeitsmarktdaten hingegen zeigen keinerlei kausale Beziehung zum Absatz, was darauf schließen lässt, dass deren Einfluss eher indirekt oder durch andere, nicht untersuchte Faktoren vermittelt wird.

Abbildung 9: Kausalitäts-Prüfung - Übersicht aus IT-Werkzeug (AP5)

Zusammenfassend lässt sich feststellen, dass der Absatz des Produkts eng mit der wirtschaftlichen Entwicklung im Industrie- und Technologiesektor verbunden ist. Die starke Korrelation mit den Aktienkursen dieser Branchen sowie deren potenzielle kausale Wirkung auf den Absatz legen nahe, dass konjunkturelle Entwicklungen in diesen Bereichen eine wesentliche Rolle für die Absatzentwicklung spielen. Arbeitsmarktdaten haben hingegen nur eine untergeordnete Bedeutung als Einflussfaktor oder Frühindikator für den Absatz. Für die Prognosen wurde ein Datensatz mit den Absatzdaten und 30 Indizes gebildet.

Modelling: Es wurden Prognosen für einen 12-Monatigen Zeitraum durchgeführt. Es wurden sowohl univariate als auch multivariate Forecasting-Modelle entwickelt, um den Absatz des Produkts zu prognostizieren. Die univariaten Ansätze stützten sich ausschließlich auf die historische Absatzzeitreihe und setzten dabei etablierte Zeitreihenmodelle ein – darunter ARIMA, SARIMA, Seasonal Exponential Smoothing (SES), Meta Prophet und den Saisonal Naiven-Ansatz. Diese Modelle berücksichtigen zentrale Elemente wie Trend, Saisonalität und Zufallsschwankungen, um präzise Vorhersagen zu ermöglichen. Ergänzend wurden multivariate Modelle verwendet. Hierbei kamen LSTM und XGBoost zum Einsatz. Es wurde der gesamte Zeitraum für das Training genutzt.

Evaluation: Zur Bewertung der Modellleistung wurden standardisierte Fehlermaße wie MAE, RMSE und sMAPE herangezogen (siehe Tabelle 3). Die Ergebnisse der univariaten Modelle zeigen, dass das SES-Modell mit einem MAE von etwa 466, einem RMSE von rund 510 und einem sMAPE von ca. 1,49 % herausragt und damit die höchste Prognosegenauigkeit erzielt. Im Vergleich dazu weisen ARIMA und SARIMA MAE-Werte von circa 2033 bzw. 1898 und RMSE-Werte von rund 2242 bzw. 2179 auf, während die sMAPE-Werte bei etwa 6,21 % beziehungsweise 5,79 % liegen. Prophet und der Seasonal Naive-Ansatz liefern mit MAE-Werten von ungefähr 4029 und 3783, RMSE-Werten von etwa 4540 und 4319 sowie sMAPE von 11,82 % bzw. 13,06 % deutlich höhere Fehlermaße. Die multivariaten Modelle erreichen differenzierte Ergebnisse: Das LSTM-Modell erzielt einen MAE von etwa 3696, einen RMSE von ca. 3928 und ein sMAPE von rund 9,67 %, während XGBoost mit einem MAE von ungefähr 5272, einem RMSE von etwa 5474 und einem sMAPE von rund 14,17 % die höchsten Fehlerwerte aufweist. Dabei muss jedoch die geringe Trainingszeit der multivariaten Modelle berücksichtigt werden, die in diesem Piloten vorausgesetzt wurde. Insgesamt zeigt die Evaluation, dass für den vorliegenden Datensatz der univariaten Ansatz – insbesondere das SES-Modell – die robusteste und präziseste Vorhersage ermöglicht. Die zusätzlichen Variablen in den multivariaten Modellen konnten in diesem Fall nicht zu einer Verbesserung der Prognosegenauigkeit beitragen, die erzielten Ergebnisse waren jedoch konkurrenzfähig.

Tabelle 3: Ergebnisse zur Pilotumsetzung bei Unternehmen A

Modell	MAE	RMSE	sMAPE	Trainingszeit (s)	Speicherverbrauch (MB)
ARIMA	2033,33	2242,21	6,21 %	4,63	0,96
Prophet	4029,16	4540,43	11,82 %	1,07	1,33
SES	465,59	509,54	1,49 %	0,05	0,03
SARIMA	1897,82	2179,11	5,79 %	6,82	12,54
Seasonal Naive	3782,50	4318,91	13,06 %	0,00	0,00
LSTM (multivariat)	3695,95	3927,97	9,67 %	18,69	8,34
XGBoost (multivariat)	5272,27	5473,60	14,17 %	0,44	0,20

Deployment: Das Unternehmen hat die Ergebnisse der Analyse als vielversprechend bewertet und plant, seine KI-Rechenkapazitäten künftig auch für Absatzprognosen einzusetzen. Die wissenschaftliche Evaluierung hat das Potenzial der KI-Anwendung aufgezeigt, sodass nun eine Integration in den operativen Forecasting-

Prozess angestrebt wird, um fundierte und kontinuierlich optimierte Entscheidungsgrundlagen zu schaffen. Insbesondere auf höher granularer Ebene bei Absatzdaten mit weniger klaren Mustern oder Trends stellen ML-Verfahren für sie eine gute Alternative dar.

Unternehmen B:

Business Understanding: Unternehmen B ist im Segment langlebiger Gebrauchsgüter tätig ist. Die Produkte – gefertigt in verschiedensten Varianten- sind aufgrund ihrer robusten Bauweise und langen Lebensdauer charakterisiert. Entsprechend der GICS-Klassifikation sind diese Produkte typischerweise im Sektor Consumer Discretionary anzusiedeln. Innerhalb dieses Sektors ordnet man das Unternehmen in der Industriegruppe Consumer Durables & Apparel ein – konkret in der Industrie Household Durables – da es Produkte herstellt, die über einen langen Nutzungszeitraum verfügen. Bisher erfolgt die Absatzprognose qualitativ, der Pilot im Rahmen dieses Projektes dient in erster Linie der explorativen Evaluierung und dem Vergleich von Datenquellen und Prognoseverfahren, um datengetriebene Ansätze zur Absatzprognose zu testen.

Data Understanding: Das Datenset umfasst die Absatzdaten sämtlicher Produkte von Unternehmen B im Zeitraum von 2009 bis 2024. Im Rahmen des Piloten wurde der Fokus auf eine Premium-Produktgruppe gelegt, die exemplarisch für die robusten und langlebigen Gebrauchsgüter des Unternehmens steht. Konkrete Muster sind in der Zeitreihe nicht direkt erkennbar. Es gab keine weiteren internen Datenquellen. Ergänzend zur internen Absatzhistorie wurden externe Marktdaten integriert, um den Einfluss makroökonomischer und branchenspezifischer Faktoren abzubilden. Hierzu zählen Konjunkturdaten, wieder aus der FRED-Datenbank, welche Indikatoren wie Inflation, Arbeitslosenquote und BIP aus relevanten Märkten (z. B. Deutschland, EU, USA) bereitstellen. Zusätzlich wurden ebenfalls wieder Finanzdaten von Yahoo Finance einbezogen, darunter Aktienkurse vergleichbarer Unternehmen, thematisch fokussierte ETFs sowie ausgewählte Rohstoffpreise, die potenziell auf die Kosten- und Preisentwicklung der Premium-Produkte einwirken.

Data Preparation: Die Data Preparation erfolgte analog zur Pilotstudie mit Unternehmen A.

Die Korrelations- und Granger-Kausalitätsanalysen zeigen, dass einige der aus der FRED-Datenbank und Yahoo Finance bezogenen Makro- und Finanzindikatoren – beispielsweise Aktienkurse des großen amerikanischen Unternehmens im Sektor – leichte Zusammenhänge mit den Absatzdaten aufweisen. Jedoch sind die meisten Korrelationen eher moderat (siehe Abbildung 10), und die Granger-Kausalitätstests deuten nur schwach auf zeitliche Einflussfaktoren hin. Diese Ergebnisse verdeutlichen, dass externe Datenquellen wie Konjunkturindikatoren oder Börsenkurse zwar potenzielle Erklärungsansätze liefern können, die Signifikanz in Bezug auf die Absatzentwicklung von Unternehmen B jedoch begrenzt bleibt.



Abbildung 10: Korrelationsanalyse Unternehmen B - Übersicht aus IT-Werkzeug (AP5)

Modelling: Es wurden Prognosen für einen 6-Monatigen Zeitraum durchgeführt und die gleichen Modelle genutzt wie in der Analyse für Unternehmen A.

Evaluation: Die univariaten Modelle liefern in diesem Szenario die präzisesten Ergebnisse: SES und Seasonal Naive erreichen mit einem MAE von unter 30 und einem sMAPE von rund 1,15 % die besten Werte. Das multivariate XGBoost erreicht nur einen sMAPE von ca. 85%. Interessant ist hier jedoch die unternehmensseitige Perspektive auf die Ergebnisse. SES (Simple Exponential Smoothing) glättet die Zeitreihe so stark, dass es letztlich zu einer nahezu konstanten Prognose führt – ideal für den Mittelwert über einen längeren Zeitraum, aber nicht geeignet, um den dynamischen Kurvenverlauf abzubilden. Das hervorragende Ergebnis in Bezug auf Fehlermaße (z. B. MAE, sMAPE) spiegelt also die gute Mittelwertschätzung wider, während saisonale oder trendbedingte Schwankungen verloren gehen (siehe Abbildung 11). Im Gegensatz dazu erfasst das multivariate XGBoost die dynamischen Bewegungen der Zeitreihe relativ gut (siehe Abbildung XX), zeigt jedoch einen starken Bias von 331 – also eine systematische Abweichung in eine Richtung, in diesem Fall überschätzt das Modell den Absatzverlauf. Dies kann bedeuten, dass das XGBoost zwar die kurzfristigen Schwankungen und Muster gut modelliert, aber langfristig einen konstanten Fehler aufweist. Mögliche Ursachen hierfür sind unzureichende Kalibrierung oder ein Missverhältnis im Bias-Variance-Trade-off. Eine Anpassung, beispielsweise durch die Korrektur des Bias nachträglich, könnte hier helfen, das richtige Verfahren auszuwählen.

Modellvergleich der Prognosen

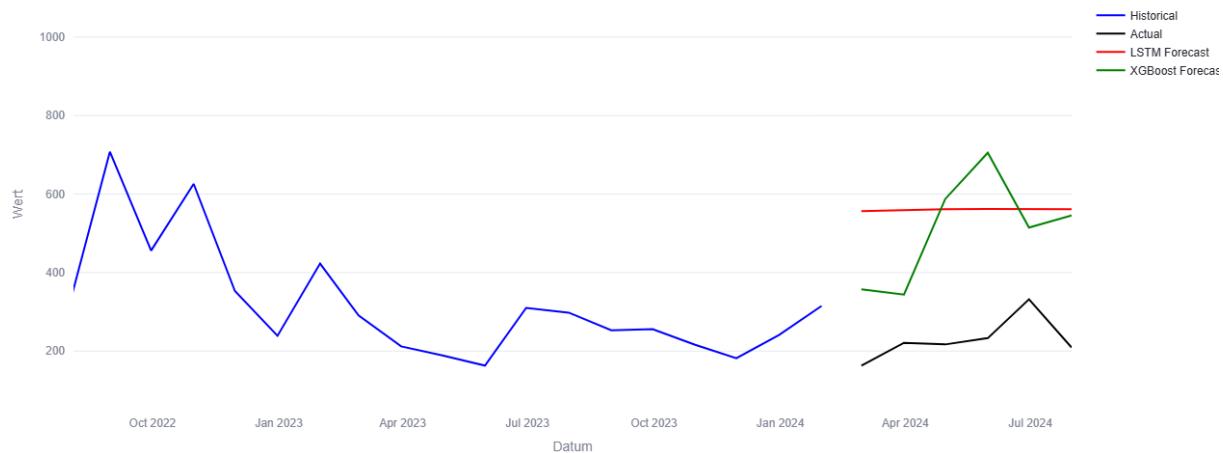


Abbildung 11: Zeitlicher Verlauf der multivariaten ML Verfahren im Vergleich mit den Ist-Daten von Unternehmen B

Deployment: Für operative Planungsaufgaben zeigt sich, dass die Wahl des Prognosemodells von der spezifischen Fragestellung abhängt. Ein einfacher univariater Ansatz wie SES liefert einen stabilen Mittelwert, der sich für langfristige Entscheidungen wie die Komponentenbestellung als vorteilhaft erweist, da hier die Aggregation der erwarteten Absatzmengen im Vordergrund steht. Im Gegensatz dazu bietet ein komplexeres Modell wie ein XGBoost den Vorteil, kurzfristige Schwankungen und den genauen Kurvenverlauf präzise abzubilden – ein entscheidendes Merkmal, wenn es um die flexible Planung von Produktionsressourcen und Personaleinsatz über einen Zeitraum von sechs Monaten geht. Diese Beispiele illustrieren, dass die Modellwahl zwischen Stabilität und dynamischer Detailtreue abgewogen werden muss, um den unterschiedlichen operativen Anforderungen gerecht zu werden.

Unternehmen C:

Business Understanding: Unternehmen C – anonymisiert als solches bezeichnet – ist ein Akteur im Handel mit metallbasierten Handelswaren und wird gemäß der GICS-Klassifikation im Sektor Materials, genauer in der Industriegruppe Metals & Mining, eingeordnet. Im Fokus der Pilotstudie stand die präzise Absatzprognose einer Produktgruppe, die essenziell für Einkaufsentscheidungen und Lagerhaltungsstrategien ist. Zur Prognose wurden neben den Absatzdaten von 2020-2024 ausschließlich Rohstoffindizes herangezogen, um die Einflüsse der volatilen Rohstoffmärkte adäquat abzubilden.

Data Understanding: Es wurden zunächst alle Handelswaren identifiziert. Zusätzlich wurden Rohstoffe und Metallpreise hinzugezogen.

Metallpreise: Hierzu zählen Edelmetalle und Basismetalle, die als wichtige Indikatoren für makroökonomische Entwicklungen und industrielle Nachfrage gelten. Die ausgewählten Ticker für Gold, Silber, Kupfer, Platin und Palladium repräsentieren klassische Anlagewerte. Ergänzt werden diese durch

Ticker für Nickel und Aluminium, welche essenzielle Rollen in der industriellen Produktion und Stahlherstellung spielen.

Energierohstoffe: Rohöl und Brent-Rohöl sowie Erdgas, Heizöl und RBOB-Benzin liefern Informationen über volatile Energiemarkte, die direkten Einfluss auf Produktions- und Transportkosten haben.

Agrarrohstoffe: Zur Abrundung der Analyse werden außerdem agrarische Basiswerte herangezogen. Getreide (Mais, Weizen und Sojabohnen) sowie Baumwolle, Kaffee, Kakao und Zucker dienen als weitere Indikatoren für globale Rohstoffmärkte.

Data Preparation: Die Data Preparation erfolgte analog zur Pilotstudie mit Unternehmen A und B. Jedoch ist ein klassisches Problem vieler KMU aufgetreten. Aufgrund einer IT-systemischen Umstellung wurden im Jahr 2022 kaum, und wenn vorhanden, fehlerhafte Daten zu den Absatzzahlen erfasst. Gleichzeitig lässt der kurze Zeitraum seit 2020 nicht zu, einen längeren Zeitraum zu prognostizieren. Hier schränkt die Datenbasis die Analysefreiheit ein. Die statistischen Analysen wurden daher für 2023 und 2024 durchgeführt.

Die statistische Analyse (siehe Tabelle 4) ergab, dass einige Rohstoffe signifikante Zusammenhänge mit dem Absatz aufweisen. So zeigt Kupfer (HG=F) eine Korrelation von 0,71 und einen p-Wert von 0,0184, was darauf hinweist, dass Kupferpreise als Frühindikator für Absatzentwicklungen herangezogen werden können.

Tabelle 4: Statistische Analysen der Absatzdaten von Unternehmen C mit diversen Rohstoffpreisen (Top 5)

Index	Correlation	Granger Causality
HG=F	0,710139	0,0184
KC=F	0,652305	0,0421
CC=F	0,548859	0,0015
GC=F	0,622273	0,038
PL=F	0,096302	0,0892

Ähnlich verhält es sich mit Kaffee (KC=F), der mit einer Korrelation von 0,65 und einem p-Wert von 0,0421 eine relevante Vorhersagekraft besitzt – auch wenn Kaffee auf den ersten Blick ungewöhnlich erscheint, könnte er makroökonomische Trends widerspiegeln.

Die Analyse zeigt, dass Kupfer und Kaffee signifikante Frühindikatoren für den Stahlabsatz darstellen. Diese Rohstoffe reflektieren makroökonomische Trends, die auf eine zukünftige Nachfrageentwicklung für Unternehmen C hindeuten. Gleichzeitig ist die Analyse auf Grund der geringen Datenbasis mit Vorsicht zu betrachten. Dafür spricht auch die Gesamtbetrachtung der Ergebnisse, da Platin (PL=F) unter die besten fünf Ergebnisse von 20 hinzugezogenen Rohstoffen fällt, aber schon keinen statistischen Zusammenhang mit dem Absatz mehr aufweist.

Modelling: Es wurden Prognosen für einen 3-Monatigen Zeitraum durchgeführt und die gleichen Modelle genutzt wie in der Analyse für Unternehmen A und B.

Evaluation: Der Absatzdatensatz zeigte eine extreme Volatilität und keine erkennbaren Trends oder Muster in den 1,5 betrachteten Jahren. Interessant ist hier, dass in Jahr 2023 der Absatz im vierten Quartal stark gestiegen, in 2024 aber stark gefallen ist. Kein Modell war in der Lage, dies auf Basis der Daten vernünftig abzubilden. Insbesondere die saisonal naive Vorhersage schnitt dadurch sehr schlecht ab. Die multivariaten Verfahren schlugen die besten statistischen, univariaten Vorhersagen hier klar (sMAPE XGBoost/LSTM:

24,4%/13,8%; sMAPE SARIMA/Holt-Winters: 77,3%/82,8%). Dieses Ergebnis zeigt, dass die Nutzung externer Datenquellen und von ML-Verfahren in diesem Beispiel mit eher schlechter Datenbasis an vergangenen Absatzdaten und volatilem Verlauf hilfreich sein kann.

Deployment: Unternehmen C sieht vor allem in der Zusammenhangsanalyse großes Potential. Gleichzeitig hat eine Diskussion der Ergebnisse im Unternehmen positiv zur generellen Einstellung gegenüber dem Einsatz von KI-Lösungen beigetragen.

Zusammenfassung und Erkenntnisse aus der Entwicklung einer Methodik zur AB-Planung mit ML-Verfahren, dem Benchmarkings und der Pilotierenden Umsetzung der AB-Prognose

Die im Arbeitspaket 3 entwickelte Methodik zur prädiktiven Absatzplanung als auch die Ergebnisse aus Benchmarking und Pilotstudien demonstrieren, dass es kein einzelnes Modell im Bereich der Absatzprognose gibt, welches für alle Anwendungsfälle stabil funktioniert. Stattdessen erfordert die heterogene Natur der Anwendungsfälle – von der Vielfalt der Produktvarianten bis hin zu den unterschiedlichen Markt- und Unternehmensbedingungen – einen flexiblen, auf den Einzelfall angepassten Ansatz. Die Integration externer Datenquellen, ausgewählt anhand des Potenzials aus der Umfragestudie und in Abstimmung mit einer detaillierten Klassifizierung der Unternehmen, erwies sich dabei als vielversprechend. Die Ergebnisse der Benchmarking-Studien verdeutlichen, dass einfache Modelle wie Seasonal Naive und Moving Average bei kurzfristigen Vorhersagen oft robuste Resultate liefern, während komplexe ML-Modelle wie LSTM oder RandomForest in volatilen oder langfristigen Szenarien Vorteile bieten können. Diese Erkenntnis unterstreicht, dass die Modellwahl stark von den spezifischen Anforderungen und den Eigenschaften der verfügbaren Daten abhängt.

Besonders hervorzuheben ist der konzeptuelle Nutzen der Datenanreicherung: Durch die gezielte Auswahl und Integration relevanter externer Variablen – wie beispielsweise Rohstoffpreise, die signifikante Frühindikatoren darstellen – konnten wertvolle Zusammenhänge identifiziert werden, die den Prognosemodellen zusätzliche Erklärungskraft verleihen. Die Klassifizierung der Unternehmen und die darauf basierende Auswahl der Anreicherungsquellen tragen wesentlich dazu bei, dass der prädiktive Prozess individuell und bedarfsgerecht gestaltet werden kann.

Insgesamt liefert die entwickelte Methodik eine belastbare, flexible Grundlage für die zukünftige Absatzplanung, die es den Unternehmen ermöglicht, ihre Prognoseansätze kontinuierlich zu evaluieren und zu optimieren – angepasst an die spezifischen Rahmenbedingungen und Anforderungen des jeweiligen Geschäftsmodells.

3.4 Arbeitspaket 4: Übertragung und Generalisierung des entwickelten Modellierungsansatzes

Anschließend werden die im vorangegangenen AP entwickelten Prognoseverfahren weitergeführt und insbesondere auf eine anwenderfreundliche Nutzung der Lösungen fokussiert. Während es im Sinne des CRISP-DM keinen direkten Vergleichspunkt zum Arbeitspaket gibt, zeichnet sich dieser Ansatz durch wiederholte Iterationen in den Bereichen Datenvorverarbeitung, Modellierung und Evaluation aus – stets mit dem Ziel, die Generalisierbarkeit der Prozesse zu verbessern. Insbesondere die Implementierung kombinierter Modelle spielt hierbei eine zentrale Rolle, da sie KMU dabei unterstützt, Entscheidungen auf Basis konsistenter und

nachvollziehbarer Prognoseergebnisse zu treffen. Im Folgenden werden die erzielten Ergebnisse und deren Implikationen detailliert vorgestellt.

Reproduktion der Prognose weiterer Anwendungsfälle und Bewertung der Klassenabhängigkeiten

Ziel: Reproduktion der Prognose weiterer Anwendungsfälle und Bewertung der Klassenabhängigkeiten

Vorgehen: Im Rahmen dieses Arbeitspaketes wurde zunächst eine standardisierte Datenvorbereitung durchgeführt und ein standardisiertes Datenformat bestimmt, in dem alle verfügbaren Datensätze der PA-Partner harmonisiert werden konnten und danach bereinigt wurden. Anschließend wurde die entwickelte Prognosemethodik reproduziert und auf diese weiteren Anwendungsfälle angewendet. Außerdem wurde unternehmensübergreifend analysiert, wie sich charakteristische Anwender- oder Produkteigenschaften (etwa Fertigungstiefe, Kundenstruktur oder Position in der Wertschöpfungskette, aber auch Bedeutung verschiedener Produkte) auf die Auswahl entsprechender Modelle und datenquellen auswirken. Ziel war es, systematische Klassenabhängigkeiten zu identifizieren und somit zu validieren oder gegebenenfalls die ursprüngliche Gruppierung anzupassen, um zukünftig maßgeschneiderte und bedarfsgerechte Prognoseansätze zu ermöglichen.

Ergebnisse: Die Ergebnisse der Reproduktion weiterer Prognoseanwendungsfälle zeigen, dass die Effektivität der Datenanreicherung wesentlich vom primären Preistreiber des Produkts abhängt – sei es Personal, Energie oder Material. Bei materialgetriebenen Produkten erweisen sich externe Rohstoffdaten als besonders nützlich, während bei energie- und personalgetriebenen Produkten der Mehrwert dieser Anreicherung geringer ausfällt. Gleichzeitig wird festgestellt, dass strukturelle Übertragbarkeiten zwischen Unternehmen in vergleichbaren Branchen bestehen. Beispielsweise zeigen Stahlunternehmen trotz unterschiedlicher Produkte konsistente Zusammenhänge mit Rohstoffpreisen, während in Konsumgüterunternehmen am Ende der Wertschöpfungskette Renner-Produkte klare Korrelationen mit konjunkturellen Indikatoren aufweisen, während bei Slow Movern individuelle, unternehmensspezifische Dynamiken dominieren. Gleichzeitig unterliegen diese Rennerprodukte teils so klaren Trends und Muster, sodass einfache Prognoseverfahren stabil gute Ergebnisse erzielen. In der Elektronikproduktion im Beleuchtungssektor bestehen zwar Verbindungen zu branchenspezifischen und konjunkturrelevanten Daten, jedoch können keine generalisierbaren Aussagen zu einzelnen Varianten getroffen werden. Positiv hervorzuheben ist zudem, dass in kleineren Unternehmen durch den partizipativen Implementierungsprozess ein verstärktes Vertrauen in KI-Lösungen entwickelt wird. Insgesamt bestätigen diese Erkenntnisse, dass ein universeller „One-Model-Fits-All“-Ansatz („No Free Lunch“) nicht realisierbar ist und stattdessen eine kontextbezogene, flexible Auswahl von Anreicherungsquellen und Modellen erforderlich ist, um den spezifischen Anforderungen unterschiedlicher Anwender gerecht zu werden.

Im Rahmen der Diskussion mit den Anwendungspartnern zeigt sich jedoch, dass – sofern die Klassifizierung im Business Understanding vom Anwender selbst geschehen soll – einfach gestaltet und erklärt werden muss. Insbesondere die aus wissenschaftlicher Betrachtung sinnvolle Unterteilung in Erzeugung und Markt bei Klassifikation nach Industrien und Geographie ist aus praktischer Sicht einfacher aufzuteilen, ohne weniger Datenquellen heranzuziehen. Dabei ist das Zusammenfassen auf „ingesamt relevante Regionen“ und „Industrieklassifikation von Erzeugern, folgenden Schritten der Wertschöpfung und Markt“ gesammelt zu beantworten.

Generalisierung der Modellstrukturen zur Reduktion der Dauer der Modellierungsphase

Folgend wurden Modellierungsergebnisse genutzt, um generalisierte Modellstrukturen zu entwickeln, die die Dauer der Modellierungsphase reduzieren. Hierbei sollte eine Fallunterscheidung basierend auf der zuvor

erstellten Anwendergruppierung erfolgen. Parallel werden Ansätze des Transfer Learning implementiert, um vortrainierte Modelle mit allgemeinen Gewichtungen bereitzustellen, die in weiteren Umsetzungen schnell zu optimalen Ergebnissen führen. Dieses Vorgehen zielt darauf ab, für jede Anwendergruppe ein möglichst spezifisches, aber zugleich generalisierbares Modell zu etablieren, welches als essenzieller Bestandteil des zu entwickelnden IT-Werkzeugs dient.

Ziel: Generalisierung der Modellstrukturen zur Reduktion der Dauer der Modellierungsphase

Vorgehen: Im Rahmen des Arbeitspakets wurde zunächst die Heterogenität der Anwendungsfälle analysiert, wobei deutlich wurde, dass das Training eines einzigen, generalisierten Modells für bestimmte Klassifikationsgruppen aufgrund der unterschiedlichen Produktvarianten, Marktbedingungen und Unternehmensmerkmale nicht zielführend ist. Stattdessen wurde ein Ensemble-Ansatz favorisiert, da dieser mehrere Modelle kombiniert, um die jeweiligen Stärken einzelner Prognoseverfahren zu nutzen und individuelle Schwächen zu kompensieren.

Ensemble-Methoden bieten den Vorteil, dass sie durch die Aggregation verschiedener Modelle - etwa einfacher statistischer Ansätze (z. B. Seasonal Naive, MovingAverage) und komplexer ML-Modelle (z. B. LSTM, RandomForest) - eine robustere und stabilere Prognose ermöglichen. Dies führt zu einer besseren Generalisierbarkeit, da unterschiedliche Datencharakteristika und kurzfristige wie langfristige Trends adäquat abgebildet werden können. Gleichzeitig wird die Vorhersagegenauigkeit durch die Reduktion von Modellspezifischen Fehlern verbessert. Ensemble-Methoden erfordern einen höheren Rechenaufwand und können die Nachvollziehbarkeit einzelner Modellbeiträge erschweren. Dennoch überwiegt in diesem Kontext in verschiedenen Anwendungsfällen der Nutzen, da die Flexibilität und die erhöhte Prognosegenauigkeit essenziell sind, um den spezifischen Anforderungen der unterschiedlichen Anwender gerecht zu werden. Gleichzeitig wird so eine weitere Alternative in die Prognosen integriert. Dieses Vorgehen ermöglicht eine kontinuierliche Evaluation und Optimierung der Prognoseansätze und bildet die Basis für eine anwenderfreundliche, datengetriebene Absatzplanung.

Ergebnis: Der implementierte Ensemble-Ansatz integriert mehrere einzelne Prognosemodelle, indem diese parallel trainiert werden und ihre jeweiligen Vorhersagen aggregiert werden. Konkret werden die Basisprognosen aller enthaltenen Modelle auf einen gemeinsamen Zeithorizont extrapoliert und in einem Datensatz zusammengeführt. Der finale Forecast wird dann als arithmetischer Mittelwert der Einzelprognosen berechnet. Diese Methode nutzt die komplementären Stärken der unterschiedlichen Modellansätze und reduziert modellinduzierte Varianzen, was zu robusteren und stabileren Prognosen führt. Insbesondere in Kontexten mit heterogenen Datenstrukturen stellt diese Vorgehensweise eine effektive Strategie dar, um Unsicherheiten einzelner Modelle abzumildern und eine verlässlichere Gesamtvorhersage zu erzielen. Genau wie andere Ansätze hat dieser Ansatz auch Nachteile. Trotz der Robustheit und Stabilität, die durch die Aggregation mehrerer Modelle erreicht wird, weist der Ensemble-Ansatz auch einige Einschränkungen auf. Erstens führt die parallele Verarbeitung mehrerer Modelle zu einem erhöhten Rechenaufwand, was insbesondere bei groß angelegten Anwendungen die Effizienz beeinträchtigen kann. Zweitens kann die Aggregation mittels arithmetischem Mittel zu einer Reduzierung der Interpretierbarkeit einzelner Modellbeiträge führen, da systematische Fehler einzelner Modelle nicht differenziert gewichtet werden. Ferner besteht die Gefahr, dass stark korrelierte Modelle im Ensemble ähnliche Fehler machen, sodass der Nutzen der Diversifizierung eingeschränkt ist. Abschließend erschwert die Komplexität des Ensemble-Ansatzes oft die Rückverfolgbarkeit und Analyse von Vorhersageursachen, was insbesondere in regulierten Anwendungsfeldern problematisch sein kann.

Gleichzeitig wurden dennoch KI-Modelle mit Absatzdaten vortrainiert, die im IT-Tool integriert werden. Dabei handelt es sich um branchenspezifische Modelle für „Elektronik“ und „Stahl“, sowie ein Modell für „Konsumgüter im Hochpreissegment“ entwickelt. Die Generalisierung der LSTM-Modelle erfolgt in mehreren methodischen Schritten, die sowohl die Datenaufbereitung als auch die Modellarchitektur, das Training und die Evaluierung umfassen. Zunächst werden die Zeitreihendaten aus den relevanten Quellen eingelesen, bereinigt und mittels geeigneter Skalierungsverfahren normiert, um die unterschiedlichen Größenordnungen der Merkmale anzugeleichen. Anschließend erfolgt die Transformation der Daten in sequenzielle Formate, indem über ein festgelegtes Fenster sukzessive Zeitabschnitte extrahiert und als Input für das Modell genutzt werden.

Im Anschluss wird der Datensatz in Trainings- und Testsegmente aufgeteilt, um eine robuste Validierung des Modells zu ermöglichen. Die Modellarchitektur wird unter Berücksichtigung der Komplexität der Daten so gewählt, dass sie ausreichende Kapazitäten zur Erfassung langzeitlicher Abhängigkeiten bietet – typischerweise durch den Einsatz mehrerer LSTM-Schichten kombiniert mit Dropout-Mechanismen zur Regularisierung und Vermeidung von Überanpassung. Die Trainingsphase wird mittels eines optimierten Lernalgorithmus („Adam“) durchgeführt, wobei die Verlustfunktion („MSE“) als Indikator für die Modellanpassung dient.

Zur Sicherstellung der Generalisierbarkeit wird das Modell kontinuierlich anhand von Validierungsdaten evaluiert und angepasst. Durch iterative Trainingsläufe, Hyperparameteroptimierung und die Integration von Regularisierungsstrategien kann die Robustheit des Modells weiter gesteigert werden. Schließlich erfolgt die Persistierung des trainierten Modells und der Skalierungsparameter, um eine spätere Wiederverwendung und Übertragung in produktive Umgebungen zu gewährleisten.

In Tests erreichen auch diese Modelle in einzelnen Beispielen gute Ergebnisse, bleiben jedoch in zahlreichen Fällen hinter anderen Modellen zurück. Potential könnten hier unternehmensinterne, eigene Modelle haben.

Entwicklung von Maßnahmen zur Erreichung von Transparenz und Nachvollziehbarkeit der Methodik

Parallel steht die Akzeptanz der Methodik nicht zuletzt mit Blick auf den Kriterienkatalog im Fokus, da der Erfolg der Einführung in Unternehmen maßgeblich von der Fähigkeit abhängt, komplexe Entscheidungsprozesse nachvollziehbar zu machen. Ein Teil des Projektes widmete sich daher der Konzeption und Implementierung von Maßnahmen, die Transparenz und Nachvollziehbarkeit der prognostischen Methodik nachhaltig erhöhen. Ziel war es, in engem Austausch mit den PA-Partnern ein Erklärungssystem zu etablieren, das nicht nur die interne Funktionsweise der Modelle offenlegt, sondern auch die Akzeptanz der Lösungen in der Praxis maßgeblich fördert.

Ziel: Maßnahmen zur Steigerung der Akzeptanz durch Transparenz und Nachvollziehbarkeit

Vorgehen: Im Rahmen aller Pilotstudien sowie in der dritten Sitzung des PA wurde explizit die Schaffung von Transparenz und Nachvollziehbarkeit thematisiert. Dabei wurden zwei Ansätze verfolgt, um Transparenz und Nachvollziehbarkeit der prognostischen Methodik zu erhöhen und somit die Akzeptanz des IT-Tools zu fördern.

Komplexitätsadaptive Modellwahl: Zum einen stand die methodische Entwicklung eines Erklärungssystems im Fokus, darin, einen Gesamtansatz zu etablieren, der eine adaptive Modellselektion ermöglicht. Dabei werden einfache, leicht nachvollziehbare Modelle bevorzugt und eingesetzt, sofern sie eine überlegene Prognosegenauigkeit erzielen. Diese Komplexitätsadaptive Modellwahl fördert die Nachvollziehbarkeit, indem er sicherstellt, dass die eingesetzten Modelle nicht unnötig komplex sind, wenn simpler Alternativen ausreichende

Ergebnisse liefern. Dieser Teilansatz erlaubt es, Entscheidungen der Modelle transparent darzustellen und die Vorteile auch komplexerer Modelle nachvollziehbar zu machen.

UX/UI-Design: Parallel dazu wurde in Zusammenarbeit mit der Firma mosaic und im Rahmen eines UX/UI-Design-Workshops in der dritten Sitzung des PA ein partizipativer Gestaltungsprozess initiiert. Hierbei wurden die Vorstellungen der Unternehmen hinsichtlich der Benutzeroberfläche und der darstellungsbezogenen Ansichten des IT-Tools erfasst und in Form von Skizzen und Konzepten visualisiert. Die gewonnenen Designansätze, gestützt durch wissenschaftliche Literatur zu benutzerzentrierten Gestaltungsmethoden, flossen in die Entwicklung eines benutzerfreundlichen und erkläруngsorientierten Tools ein. Die Kombination beider Ansätze – die systematische Erklärbarkeit der Modellentscheidungen und die partizipative, designorientierte Ausgestaltung des IT-Tools – dient dazu, eine möglichst hohe Akzeptanz und Transparenz zu erreichen, indem sowohl die technische Funktionsweise als auch die Benutzerinteraktion verständlich und nachvollziehbar gemacht werden.

Ergebnis: Das Ergebnis dieses Arbeitspaketes findet sich in UX/UI-Design, Aufbau und Inhalt des IT-Werkzeuges, das viele Bausteine zur Schaffung von Nachvollziehbarkeit wie Erklärungen und Visualisierungen enthält.

Zusammenfassung und Erkenntnisse aus der Übertragung und Generalisierung des entwickelten Modellierungsansatzes

Die Ergebnisse der Übertragung und Generalisierung des in den vorangegangenen Arbeitspaketen entwickelten Modellierungsansatzes unterstreichen die Notwendigkeit einer kontextbezogenen und flexiblen Herangehensweise in der prädiktiven Absatzplanung. Es wurde festgestellt, dass in vergleichbaren Branchen strukturelle Übertragbarkeiten existieren. So weisen Stahlunternehmen konsistente Zusammenhänge mit Rohstoffpreisen auf, während in Konsumgüterunternehmen am Ende der Wertschöpfungskette Bestseller-Produkte klare Korrelationen mit konjunkturellen Indikatoren zeigen, wohingegen Slow Runner von individuellen Dynamiken geprägt sind. Dieser Befund bestätigt, dass ein universeller „One-Model-Fits-All“-Ansatz nicht realisierbar ist und stattdessen eine adaptive Modellwahl – bei der einfache, nachvollziehbare Modelle bevorzugt werden, sofern sie eine überlegene Prognosegüte erzielen – vorteilhaft ist.

Die Implementierung eines Ensemble-Ansatzes, der mehrere Modellvorhersagen aggregiert, führt zu robusteren und stabileren Prognosen, auch wenn dies mit einem erhöhten Rechenaufwand und einer verminderter Interpretierbarkeit einzelner Modellbeiträge einhergeht. Ergänzend dazu wurden vortrainierte, branchenspezifische KI-Modelle integriert, um die Anpassungsfähigkeit an unterschiedliche Anwendungsfälle zu erhöhen und den Modellierungsprozess zu beschleunigen.

Insgesamt bestätigen die gewonnenen Erkenntnisse, dass die Möglichkeit der adaptiven Modellwahl, Ensemble-Methoden und vortrainierten, kontextbezogenen Modellen eine belastbare Basis für eine anwenderfreundliche, datengetriebene Absatzplanung bildet – ein Ansatz, der kontinuierlich evaluiert und optimiert werden kann, um den spezifischen Anforderungen unterschiedlicher Anwender gerecht zu werden.

3.5 Arbeitspaket 5: Begleitende Einführung und Optimierung der AB-Prognose in der praktischen Anwendung

Durch die praktische Umsetzung wird der postulierte Mehrwert überprüft. Dafür erfolgt eine begleitende Einführung und Optimierung der entwickelten Methodik, angelehnt an den letzten Schritt im CRISP-DM, das Deployment.

Vorbereitung und Begleitung während der Einführung der entwickelten Methodik

Den Abschluss datenanalytischer Projekte stellt nicht die Modellbildung dar, sondern die Integration der Modelle in die unternehmerischen Entscheidungsprozesse. Dies wird auch im Forschungsvorhaben angestrebt, jedoch obliegt die Durchführung der praktischen Umsetzung innerhalb der Werke vorrangig den Unternehmen im PA.

Ziel: Begleitung der unternehmensinternen Umsetzungen der AB-Prognose

Vorgehen: Es wurde die Einführung der entwickelten Methodik in den Pilotstudien und in der gesamten strukturierten Studie eng begleitet. Die Unternehmen wurden während des gesamten Implementierungsprozesses aktiv unterstützt. Durch die klare Struktur der Methodik konnten etwaige Vorbehalte und Umsetzungsbarrieren frühzeitig identifiziert und adressiert werden, sodass die Anwender mit dem Ansatz vertraut gemacht wurden. Diese begleitende Rolle ermöglichte nicht nur eine reibungslose Übertragung der prädiktiven Absatzprognose in operative Abläufe, sondern leistete auch einen wesentlichen Beitrag zur nachhaltigen Steigerung des Mehrwerts der implementierten Lösungen.

Ergebnisse: Die Anwender wurden systematisch in die Funktionsweise und Anwendung der unterschiedlichen Modelle eingeführt, ohne dass eine verbindliche Nutzung des eigens entwickelten IT-Tools vorgeschrieben wurde. Vor dem Hintergrund einer heterogenen IT-Landschaft und variierender betrieblicher Anforderungen lag der Schwerpunkt darauf, den Unternehmen ein fundiertes Verständnis der prognostischen Verfahren zu vermitteln und sie in die Lage zu versetzen, diese Verfahren eigenständig in ihre bestehenden Systeme zu integrieren. Während einige Unternehmen, die bereits über leistungsfähige, integrierte Systeme verfügen, die Konzepte und Ideen in ihre internen Tools übernehmen, wurde anderen durch den Zugang zu unserem Tool eine praxisnahe Lösung bereitgestellt. Ziel dieser begleitenden Maßnahmen war es, die Akzeptanz und das Verständnis für die prädiktive Absatzprognose zu erhöhen und somit einen nachhaltigen Mehrwert für die unternehmerischen Entscheidungsprozesse zu erzielen. Dies war insbesondere durch die hohen Anforderungen in Bezug auf Datensicherheit entscheidend.

Untersuchung und abschließende Bewertung der Einführung hinsichtlich der initialen Zielsetzung

In diesem Kapitel wird die nachhaltige Implementierung und Integration des IT-Werkzeugs zur prädiktiven Absatzprognose abschließend evaluiert. Dabei werden die während der Einführungsphase gewonnenen Rückmeldungen sowie die quantitativen und qualitativen Leistungskennzahlen herangezogen, um den Einfluss der implementierten Lösungen auf die unternehmerischen Entscheidungsprozesse zu bewerten.

Ziel: Bewertung der Einführung

Vorgehen: Durch den begleiteten Prozess über das Projekt wurde dies durchgängig iterativ im Rahmen der Entwicklung und Pilotierung realisiert. Es wurde durch die *durchgängige, semi-strukturierte Studie* während des gesamten Projekts Praxisrelevanz gewährleistet.

Ergebnis: Das Ergebnis dieses Arbeitspaketes findet sich im Aufbau und Inhalt des IT-Werkzeuges. Als konkrete Beispiele dienen hier die Granularität und die hier die Gestaltung der Integration und Auswahl des Prognosehorizonts.

Granularität: Es wurde sowohl an tageweisen Prognosen als auch an langfristigen Vorhersagen über Jahre gearbeitet. Dabei wurde durch die Anwender der Fokus auf monatsweise Betrachtungen eingegrenzt (min. 1 Monat, max. 24 Monate), da dies für viele der Anwendungsfälle als ausreichend bewertet wurde.

Prognosehorizont: Im Projekt wurde lange die Verbindung konkreter Aufgaben, die mithilfe der Absatzprognose gelöst werden sollen, fokussiert und in der zweiten Sitzung des PA auch konkretisiert: Insgesamt sind Absatzprognosen für viele Unternehmensbereiche unverzichtbar: von der kurzfristigen Bedarfsplanung in der Beschaffung und Produktion, über die mittelfristige Personaleinsatz- und Kapazitätsplanung, bis hin zu langfristigen Entscheidungen über Investitionen und nachhaltige Unternehmensstrategien. Dabei war lange geplant, dass Nutzer ihre Aufgabe auswählen und das IT-Werkzeug den entsprechenden Prognosehorizont vorgibt. Im Rahmen der dritten Sitzung des PA kristallisierte sich jedoch heraus, dass die Anwender sehr wohl auch verschiedene Horizonte testen möchten und das Werkzeug vor allem als Unterstützung ihres Prozesses sehen.

Zusammenfassung und Erkenntnisse aus der Untersuchung und abschließende Bewertung der Einführung hinsichtlich der initialen Zielsetzung

Die Evaluierung der Einführung der prädiktiven Absatzprognose in den teilnehmenden Unternehmen bestätigt den postulierten Mehrwert der entwickelten Methodik. Dabei wurde durch einen begleiteten Einführungsprozess – ohne eine verbindliche Nutzung des IT-Werkzeugs zu erzwingen, sondern die Ansätze und Ideen für sich zielbringend zu integrierend – erreicht, dass die Unternehmen ein vertieftes Verständnis für die zugrunde liegenden Prognoseverfahren erlangen konnten. Die heterogene IT-Landschaft führte dazu, dass manche Partner ihre bestehenden, integrierten Systeme weiter nutzten und die neuen Konzepte in ihre Tools implementierten, während andere auf das bereitgestellte IT-Werkzeug zurückgriffen.

Die anschließende Bewertung zeigt, dass die flexible Granularität – von kurzfristigen bis zu langfristigen Prognosen – den spezifischen Anforderungen der unterschiedlichen Anwendungsfälle gerecht wird. Die Ergebnisse verdeutlichen, dass die prädiktiven Ansätze nicht nur die operative Planungsflexibilität, sondern auch als strategisches Instrument zur nachhaltigen Unternehmenssteuerung dienen können. Insgesamt unterstreichen diese Erkenntnisse die erfolgreiche Integration und praktische Anwendbarkeit der entwickelten Methodik im Hinblick auf die initial definierten Zielsetzungen.

3.6 Arbeitspaket 6: Überführung der Methodik in ein nutzerfreundliches IT-Werkzeug und begleitende Optimierung

Ziel: IT-Werkzeug zur nutzerfreundlichen Verwendung der AB-Prognose

Vorgehen: Im Rahmen der Entwicklung des IT-Werkzeuges wurde ein strukturiertes Vorgehen realisiert, das die Entwicklung eines Demonstrators basierend auf den Anforderungen der Anwender zur Folge hat. Die semi-strukturierte Studie diente als Grundlage, um die spezifischen funktionalen Anforderungen der Anwender systematisch zu erfassen und in das Design des IT-Werkzeugs zu integrieren.

Im Mittelpunkt standen dabei drei wesentliche Aspekte:

UX/UI-Design: Aufbauend auf den grundlegenden Prinzipien dieses Bereichs, wurde ein benutzerfreundliches und intuitives Interface konzipiert. Das UI-Design stellt dabei nicht nur ästhetische, sondern vor allem funktionale Aspekte in den Vordergrund. So ist zu betonen betont, dass ein gelungenes UI-Design den effizienten und intuitiven Umgang mit digitalen Systemen ermöglicht und durch einen nutzerzentrierten Ansatz (Human Centered Design) mittels iterativer Zyklen – bestehend aus Beobachtung, Ideenfindung, Prototyping und Testen – fortlaufend optimiert (Stone et al. 2014). Dieser iterative Prozess erlaubt es, frühzeitig potenzielle Usability-Probleme zu identifizieren und gezielt zu beheben, was letztlich zu einer erheblichen Steigerung der Benutzerfreundlichkeit führt.

Datensicherheit: Es wurde besonderes Augenmerk daraufgerichtet, dass sämtliche Absatzdaten und Analysen innerhalb der Unternehmensgrenzen verbleiben. Diese Maßnahme gewährleistet, dass sensible Daten nicht unbefugt nach außen gelangen und somit ein hohes Sicherheitsniveau beibehalten wird.

Interoperabilität: So wird sichergestellt, dass Absatzdaten und Forecasts im weit verbreiteten CSV-Format importiert und exportiert werden können. Diese Offenheit in der Datenbereitstellung ermöglicht eine nahtlose Integration in bestehende Systeme und unterstützt zudem die externe Analyse von Metriken.

Durch diese zielgerichtete und methodisch fundierte Vorgehensweise konnte das IT-Werkzeug optimal an die Bedürfnisse der Anwender angepasst werden, wodurch eine effiziente und sichere Nutzung gewährleistet ist.

Ergebnis: Final wurde nach dem Vergleich verschiedener Technologien (Streamlit, Dash, Panel) für die Umsetzung ein browserbasiertes IT-Werkzeug konzipiert. Diese Entscheidung begründet sich darin, dass eine im Browser arbeitende Lösung den alltäglichen Arbeitsumgebungen der Anwender sehr nahekommt – nahezu jeder nutzt täglich webbasierte Anwendungen. Die Implementierung erfolgt unter Einsatz von Streamlit, das für eine intuitive und interaktive Weboberfläche sorgt, während Flask als Framework zur Realisierung von API-Schnittstellen dient und so die Anbindung verschiedener Daten ermöglicht. NGINX fungiert als Reverse-Proxy und übernimmt dabei eine zentrale Rolle im Sicherheitskonzept: Es sorgt für eine verschlüsselte Kommunikation und gewährleistet, dass sensible Absatzdaten innerhalb der Unternehmensgrenzen bleiben.

Das entwickelte Tool baut auf drei Kernanwendungen auf – Absatzanalyse, Modellvergleich und Absatzprognose – und wird durch zwei unterstützende Hilfsfunktionen ergänzt. Im Folgenden werden die einzelnen Komponenten detailliert beschrieben, um den Mehrwert und die Funktionalitäten des IT-Werkzeugs umfassend darzustellen.

Grundaufbau: Die Benutzeroberfläche von PrABCast zeichnet sich durch eine klare, tab-basierte Struktur aus, die eine intuitive Navigation zwischen den einzelnen Funktionsbereichen ermöglicht.

Die Navigation erfolgt über mehrere Tabs, die jeweils einen spezifischen Anwendungsbereich – „Was ist PrABCast?“ (siehe Abbildung 12), „Datenansicht“, „Absatzanalyse“, „Modellvergleich“, „Absatzprognose“ und „Glossar“ – repräsentieren.

Was ist PrABCast?

PrABCast ist ein Forschungsprojekt des RIF - Instituts für Forschung und Transfer in Kooperation mit dem Institut für Produktionssysteme (IPS) an der Technischen Universität Dortmund. Ziel dieses Vorhabens ist es, es Unternehmen zu erleichtern, Maschinelle Lernverfahren in der Absatz- und Bedarfsprognose einzusetzen.



Abbildung 12: Startseite des IT-Werkzeugs mit Tab-Übersicht

Der erste Tab „Was ist PrABCast?“ (siehe Abbildung 12) bietet eine kompakte Einführung in das System und erläutert die grundlegenden Zielsetzungen von PrABCast. Weitere Tabs ermöglichen den Zugriff auf die Datenansicht, in der Nutzer ihre Datensätze hochladen und konfigurieren können, sowie auf Bereiche zur Absatzanalyse, zum Modellvergleich und zur Absatzprognose. Ein zusätzliches Glossar stellt erklärende Inhalte bereit, die insbesondere für die Interpretation der Fachbegriffe von Bedeutung sind.

Innerhalb der Analyse- und Prognosebereiche werden die Funktionen weiter unterteilt, sodass die Nutzer je nach Bedarf zwischen verschiedenen Darstellungs- und Auswertungsmethoden (z. B. Rohdatenanzeige, Datenaggregation, Zeitreihenzerlegung) wählen können. Die modulare Struktur der Oberfläche ermöglicht es, komplexe Datenanalysen übersichtlich und zielgerichtet zu präsentieren, ohne den Anwender mit zu vielen Informationen auf einmal zu überladen. Jeder Tab besitzt eine eigene Übersicht, in der Funktionen und Vorgehensweise für den Anwender greifbar dokumentiert sind. Gleichzeitig besitzt jede Unterfunktion in einem ein- und ausklappbaren Element vertiefte Informationen, Erklärungen, Verlinkungen zu wissenschaftlicher Literatur oder zuvor ausgewählten Lehrvideos zum Thema, um die Anwendung einfach zu gestalten.

Die einzelnen Funktionen des IT-Werkzeugs besitzen folgende Funktionen:

Datenupload: Im Bereich der Datenansicht beginnt der Anwender mit dem Hochladen einer CSV-Datei, die als Grundlage für die weitere Analyse dient. Nach dem Upload wird die Datei automatisch verarbeitet und zwischengespeichert, um eine schnelle Wiederverwendung der Daten zu ermöglichen. Anschließend wird der Nutzer aufgefordert, eine Spalte auszuwählen, die als Datumsangabe interpretiert werden soll. Dabei erfolgt eine Umwandlung in ein standardisiertes Datumsformat, sodass die frühesten und spätesten Zeitpunkte identifiziert werden können.

Datenansicht

Hier eine CSV-Datei hochladen/aktualisieren.

Drag and drop file here
Limit 200MB per file • CSV

 fiktiver_absatzdatensatz_industrie.csv 116.5KB

Auf dieser Seite können Sie Ihre Daten hochladen und konfigurieren.

- **Dateiupload:** Laden Sie Ihre Datendateien hoch.
- **Datumsauswahl:** Wählen Sie das Datum und die Produkte aus, die Sie betrachten möchten.
- **Zeitraumauswahl:** Definieren Sie einen Gesamtzeitraum, der später filterbar ist.
- **Automatische Datumserkennung:** Die Anwendung erkennt automatisch Datumsformate in Ihren Daten.

Wähle die Datumsspalte:

Details:

Abbildung 13: Funktion "Datenansicht" zum Import der unternehmenseigenen Daten

Parallel dazu hat der Anwender die Möglichkeit, eine oder mehrere Spalten auszuwählen, die die zu analysierenden Produktinformationen enthalten (siehe Abbildung 13). Diese Auswahl stellt sicher, dass nur relevante Variablen in den weiteren Analyseschritten berücksichtigt werden. Im nächsten Schritt wird dem Nutzer ein Filtermechanismus präsentiert, der es erlaubt, einen spezifischen Datumsbereich festzulegen. Nach der Festlegung wird die zugrunde liegende Datenmenge automatisch entsprechend eingeschränkt, und die gefilterten Daten werden in einer übersichtlichen Tabellenansicht dargestellt.

Der erzeugte Datensatz bietet den Vorteil, dass der Anwender flexibel die Aggregationsebene bestimmen kann, sodass er entscheiden kann, ob er mit den originalen Absatzdaten, Sekundärbedarfsdaten oder aggregierten Produktgruppen weiterarbeiten möchte. Diese Flexibilität ermöglicht eine präzisere Analyse und Anpassung an unterschiedliche betriebliche Anforderungen und Zielsetzungen.

Absatzanalyse: Die Absatzanalyse bietet den Anwendern eine umfassende Übersicht über ihre Verkaufs- bzw. Bedarfsdaten und stellt damit eine wichtige Entscheidungshilfe für die Auswahl passender Prognoseverfahren dar. Insbesondere wurden verschiedene Visualisierungsoptionen implementiert, um zentrale Kennwerte, Verteilungen und Zeitreihenkomponenten transparent darzustellen. Diese Funktionen – beispielsweise Rohdatenansichten, Produktverteilungen oder die Zerlegung in Trend- und Saisonkomponenten (siehe Abbildung 14) – wurden auf Wunsch mehrerer Anwender in das Tool integriert, obwohl sie nicht im Kernfokus des Forschungsprojekts standen. Sie ergänzen jedoch den Gesamtprozess im Umgang mit Absatzdaten, indem sie die Interpretation und Bewertung der Daten vereinfachen und so die Grundlage für eine fundierte Prognoseentscheidung schaffen. Ebenso sind vertiefte Analysen für Fortgeschrittene integriert, die in den Unternehmensprozessen auf Basis der Absatzdaten durchgeführt werden können, sodass diese vereinfacht werden (ABC-XYZ-Analyse, KPSS-Test etc.)

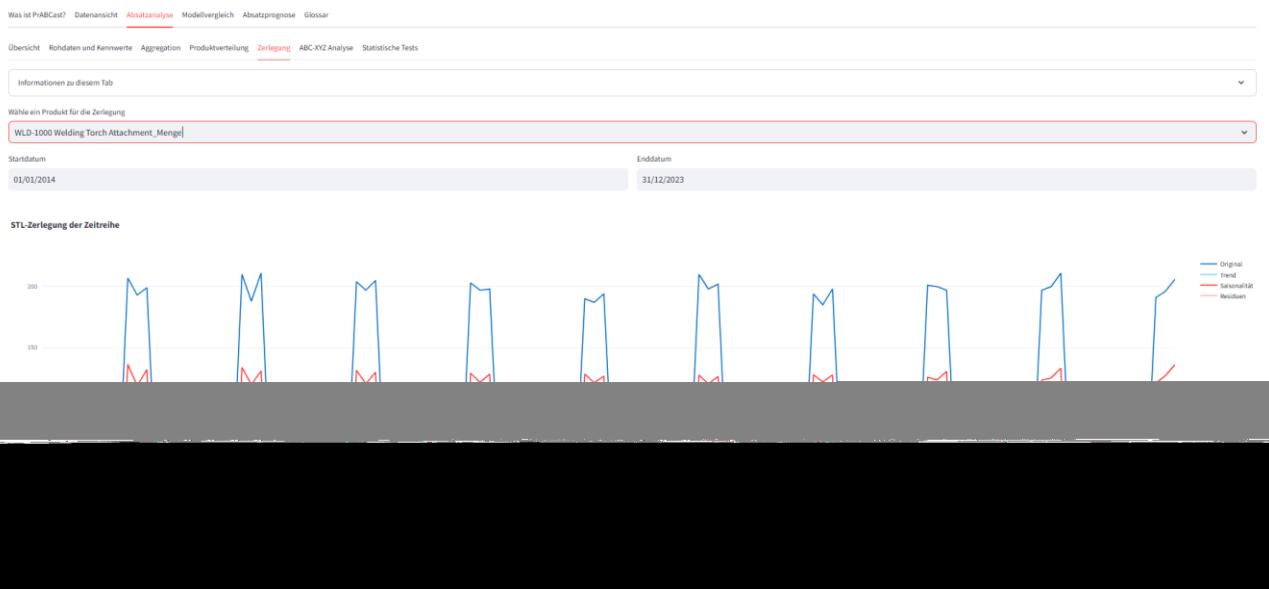


Abbildung 14: Zeitreihendekomposition in der "Absatzanalyse"-Funktion

Modellvergleich: Die Funktion „Modellvergleich“ dient dazu, unterschiedliche Prognosemethoden systematisch gegenüberzustellen und ihre Eignung für spezifische Absatzdaten zu beurteilen. Aus wissenschaftlicher Perspektive verfolgt sie damit das Ziel, auf Basis transparenter Vergleichskriterien eine fundierte Entscheidungsgrundlage für die Auswahl des jeweils besten Verfahrens zu schaffen. Dabei können sowohl einfache statistische Methoden als auch komplexe ML-Ansätze in Bezug auf ihre Prognosegüte miteinander verglichen werden. Der Anwender kann selbst auf Basis der Erkenntnisse aus der Absatzanalyse eine Vorauswahl treffen, muss dies aber nicht.

Die erste Unterfunktion „Einfach“ ermöglicht die Erstellung univariater Prognosen mit den elf vielversprechendsten Verfahren aus den Analysen für einen Prognosehorizont bis zu 24 Monaten in monatlicher Abstufung. Dabei sind die Parameter verschiedener Verfahren (ARIMA, LSTM) voreingestellt, können aber für Fortgeschrittene im Werkzeug selbst nachjustiert werden. Im Tab der Funktion selbst wird jedes Verfahren kurz vorgestellt, Vor- und Nachteile erörtert und vertiefte Literatur verlinkt. Die Ergebnisse jeder Prognose werden auf drei Arten dargestellt (siehe Abbildung 15). Der Verlauf der Prognosen wird mit den Testdaten gemeinsam visualisiert, um Vergleichbarkeit zu schaffen. Gleichzeitig wird eine Tabelle mit der Übersicht der Metriken erzeugt. Zur Bewertung der Prognosegüte der entwickelten Modelle werden verschiedene Metriken eingesetzt, die unterschiedliche Aspekte der Vorhersagequalität berücksichtigen. Der MAE gibt den durchschnittlichen absoluten Fehler zwischen vorhergesagten und tatsächlichen Werten an und ist besonders interpretierbar, da er direkt die Fehlergröße in der Einheit der Verkaufszahlen angibt. Ergänzend dazu wird der RMSE verwendet, welcher größere Fehler stärker gewichtet und somit besonders für Anwendungen relevant ist, bei denen Ausreißer vermieden werden sollen. Für eine vergleichbare Bewertung der Prognosegenauigkeit unabhängig von der absoluten Größenordnung der Verkaufszahlen wird der sMAPE genutzt, der die Fehler in Prozent ausdrückt und eine symmetrische Behandlung von Über- und Unterschätzungen ermöglicht. Darüber hinaus wird der Bias als Maß für die systematische Verzerrung der Vorhersagen betrachtet, um zu identifizieren, ob Modelle tendenziell zu hohe oder zu niedrige Prognosen liefern. Zur vergleichenden Bewertung der Modelle gegenüber einer naiven Referenzmethode wird der Theil's U-Koeffizient berechnet, welcher die Prognosegüte im Verhältnis zu einer einfachen Benchmark-Prognose misst. Neben diesen

Gütekriterien werden auch Trainingszeit und Speicherverbrauch als ressourcenbezogene Evaluationskriterien herangezogen, um den praktischen Einsatz der Modelle in realen Anwendungsfällen zu bewerten.

Die Auswahl dieser Metriken gewährleistet eine umfassende Bewertung der Modelle sowohl hinsichtlich der Prognosequalität als auch der Effizienz und ermöglicht eine fundierte Entscheidungsgrundlage für die Anwendung in unternehmensspezifischen Vorhersageszenarien.

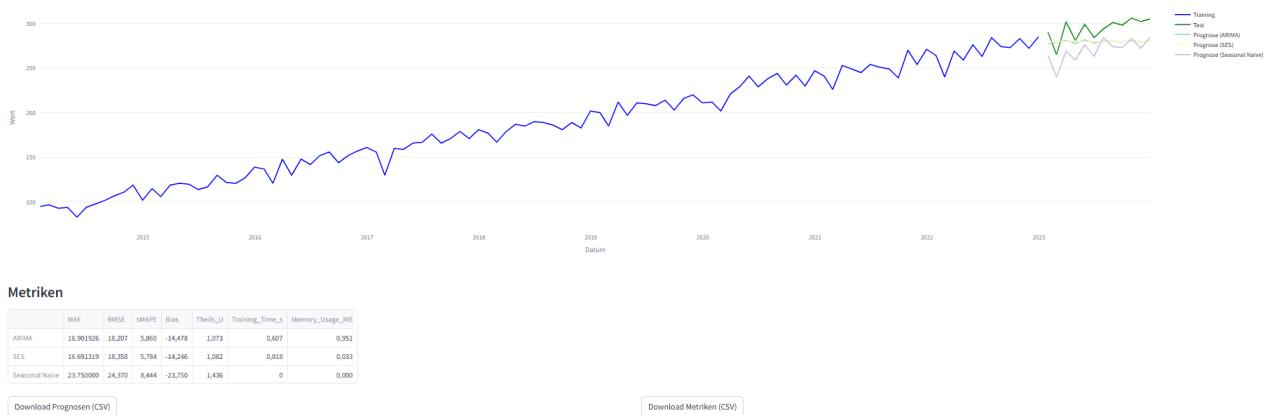


Abbildung 15: Univariate Zeitreihenprognose im Modellvergleich im PrABCast-Tool

Die zweite Unterfunktion „Datenanreicherung“ lässt den Nutzer entsprechend der Klassifizierung einfach die Schnittstellen (FRED, Yahoo Finance) zu Markt- und Konjunkturdaten bedienen. In diesem Tab wird eine Datenanreicherung und Zusammenhangsanalyse durchgeführt, um externe Einflussfaktoren zu identifizieren, die mit den Verkaufszahlen eines Produkts korrelieren oder diese möglicherweise beeinflussen. Zunächst wird das zu analysierende Produkt ausgewählt, bevor ein Fragebogen auf Basis der Klassifizierung der Anwenderunternehmen bestimmt, welche Arten von Indizes untersucht werden sollen. Dazu gehören Industrieindizes für relevante Branchen, Marktindizes wie Aktienindizes zur Abbildung der Marktentwicklung sowie regionale Indikatoren wie BIP oder Arbeitslosigkeit, um makroökonomische Einflüsse zu berücksichtigen. Anschließend erfolgt die Analyse, bei der relevante Indexdaten automatisch ausgewählt und entsprechend des Betrachtungszeitraums angereichert werden. Es werden Pearson-Korrelationen berechnet, um lineare Zusammenhänge zwischen Indizes und Absatz zu erkennen, und eine Granger-Kausalitätsanalyse durchgeführt, um zu bestimmen, ob Veränderungen in einem Index zeitlich vor Veränderungen im Absatz auftreten. Die stärksten Zusammenhänge werden identifiziert und in interaktiven Grafiken visualisiert (siehe Abbildung 16).



Abbildung 16: Normalisierte Zeitreihen nach Datenanreicherung

Die Ergebnisse können anschließend genutzt werden, um die Zusammenhänge detailliert untersuchen oder die angereicherten Daten und Analysen für weitere Verarbeitungsschritte herunterzuladen. Final wird ein Datensatz aus Absatzdaten und angereicherten Daten erzeugt und für die multivariate Prognose

bereitgestellt. An dieser Stelle können Anwender den Datensatz auch mit weiteren Attributen aus eigenen Quellen ergänzen.

In der dritten Unterfunktion wird mit dem erzeugten Datensatz eine multivariate Prognose mit LSTM und XGBoost Verfahren durchgeführt. Dabei können auch vtrainierte Modelle verwendet werden. Auch hier sind Parametereinstellungen möglich. Der Modellvergleich ist dann über die gleichen Funktionen wie in der univariaten Analyse (Visualisierungen, Metriken) möglich.

Absatzprognose: Während der Modellvergleich die Prognosemethoden und Datenanreicherung für einen Testzeitraum analog zum gewünschten Vorhersagehorizont ermöglicht, kann im Rahmen der Funktion die tatsächliche Prognose in die Zukunft durchgeführt werden. Die Prognosen werden visualisiert und können als csv-Dateien exportiert werden. (siehe Abbildung 17)

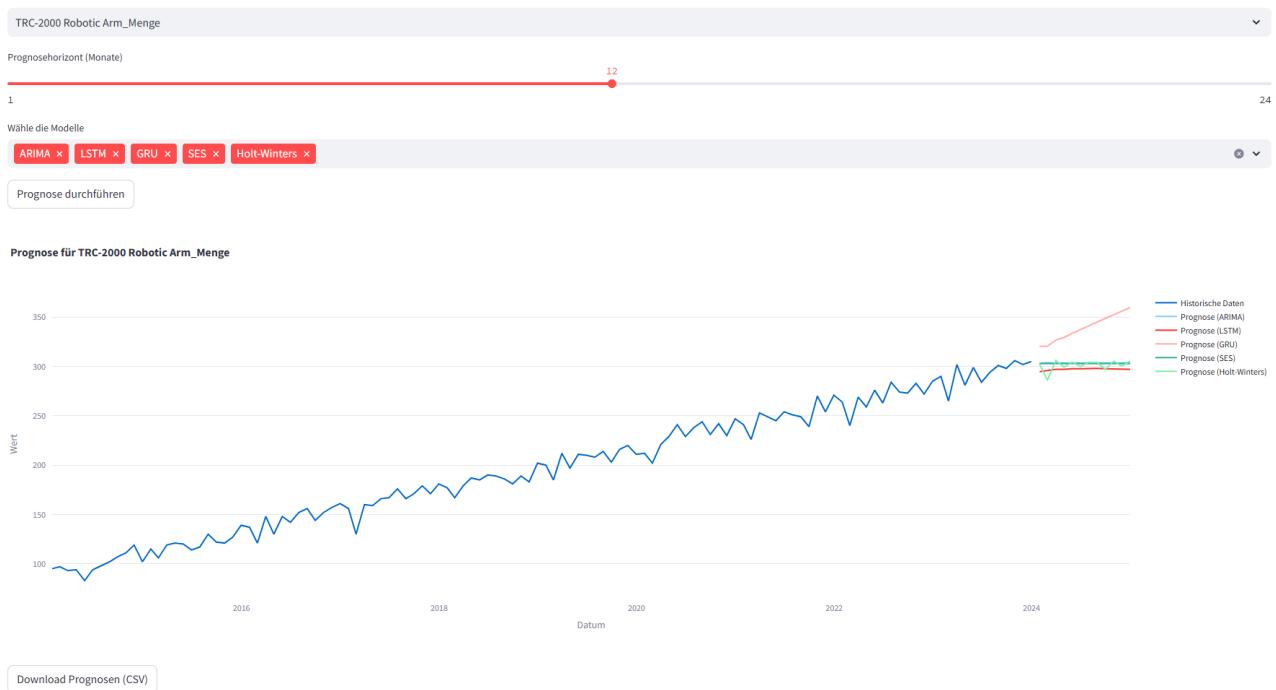


Abbildung 17: Absatzprognose der Absatzdaten in die Zukunft

Glossar: Im Glossar werden wichtige Begrifflichkeiten zusammengefasst, um eine schnelle Nachschlagemöglichkeit für Anwender zu bieten. Sie dient der Erklärung verschiedener Analysen und Erhöhung der Akzeptanz des IT-Werkzeugs.

Zusammenfassend wurde ein IT-Werkzeug erstellt, welches Unternehmen individuelle Modellvergleiche und Absatzprognosen mit automatisiert angereicherten Datensätzen ermöglicht. Zahlreiche Erklärungen und Visualisierungen helfen Anwendern, die einzelnen Schritte der Methodik nachvollziehen zu können und Mehrwerte für sich zu generieren.

3.7 Arbeitspaket 7: Projektmanagement, Öffentlichkeitsarbeit, Dokumentation und Ergebnistransfer

Die Koordination des Projekts sowie der Transfer der Ergebnisse begleitete das gesamte Projekt und diente der strukturierten Organisation, Dokumentation sowie der Verbreitung der erzielten Ergebnisse in Wissenschaft und Industrie. In regelmäßigen Arbeitstreffen wurden die Fortschritte der koordiniert, offene Fragen diskutiert und das weitere Vorgehen abgestimmt. Dabei gab es vier Sitzungen des PA, die für weitere im Rahmen des Projektes gewonnene interessierte Unternehmen offen gestaltet wurden, davon eine Sitzung in 2023 und drei Sitzungen in 2024. Diese Treffen ermöglichen einen kontinuierlichen Austausch zwischen den beteiligten Partnern und stellten sicher, dass die gesetzten Projektziele erreicht wurden. Innerhalb der Treffen wurde die semi-strukturierte Studie projektdurchgängig durchgeführt.

Die Dissemination der Projektergebnisse erfolgte über verschiedene Kanäle. Wesentliche Erkenntnisse wurden in wissenschaftlichen Publikationen aufbereitet und in (inter-)nationalen Fachzeitschriften oder bei Fachkonferenzen eingereicht oder veröffentlicht:

- Syberg, Marius; West, Nikolai; Lenze, David; Deuse, Jochen: „*Framework for predictive sales and demand planning in customer-oriented manufacturing systems using data enrichment and machine learning*“, Procedia CIRP, Volume 120, 2023, Pages 1107-1112, ISSN 2212-8271, (CIRP CMS 2023 South Africa), <https://doi.org/10.1016/j.procir.2023.09.133>.
- Pähler, Sebastian; Syberg, Marius; Deuse, Jochen: "Modular Data Analytics as a Tool for Citizen Data Scientists in Quality Management", 2024 International Conference on Electrical, Computer and Energy Technologies, pp. 1-8 (ICECET, Sydney, Australia, 2024), doi: 10.1109/ICECET61485.2024.10698360.
- Rokoss, A., Syberg, M., Tomidei, L. et al. Case study on delivery time determination using a machine learning approach in small batch production companies. Journal of Intelligent Manufacturing 35, 3937–3958 (2024). <https://doi.org/10.1007/s10845-023-02290-2>

In Publikation oder in Vorbereitung:

- Syberg, Marius; Polley, Lucas; Deuse, Jochen: Evaluating Sales Forecasting Methods in Make-to-Order Environments: A Cross-Industry Benchmark Study, International conference on Time Series and Forecasting (ITISE 2025)
- Polley, Lucas; Syberg, Marius; Deuse, Jochen: Optimierung der Absatzprognose mithilfe von KI - Eine Studie zur Anwendung in KMU (ZWF – Zeitschrift für wissenschaftlichen Fabrikbetrieb, 5/2025)
- Syberg, Marius; Polley, Lucas; Deuse, Jochen: Systematic Integration of External Data Sources for Enhanced Sales Forecasting in Make-to-Order Manufacturing, IEEE International Conference on Industrial Engineering and Engineering Management (IEEM)
- Syberg, Marius; Polley, Lucas; Deuse, Jochen: Adapting Machine Learning for Sales Forecasting in Industrial Enterprises: A Practical Perspective (JIII - Journal of Industrial Information Integration 2025)

Ein zentraler Bestandteil des Ergebnistransfers war zudem die Bereitstellung relevanter (Teil-)Ergebnisse für eine breite Fachöffentlichkeit über digitale Plattformen wie LinkedIn, die Homepage des RIF e.V. sowie der

Kooperationspartner Institut für Produktionssysteme der TU Dortmund sowie dem Netzwerk Industrie Ruhr Ost (NIRO e.V.). Dies gewährleistete eine diskriminierungsfreie Verfügbarkeit der Forschungsergebnisse und ermöglichte weiteren Interessierten, die gewonnenen Erkenntnisse nachzuvollziehen und für eigene Anwendungen zu nutzen. Darüber hinaus wurden wertvolle Anregungen für potenzielle Anschlussprojekte genutzt, mehrere Vorhaben, die direkt aus PrABCast hervorgehen, sind in Begutachtung oder Beantragung.

Die Projektdokumentation erfolgte fortlaufend in Form interner Berichte sowie im abschließenden Gesamtbereich. Zusätzlich wird eine Dissertationsschrift erstellt, die die wissenschaftlichen Erkenntnisse des Projekts systematisch zusammenfasst und weiterführende Forschungsfragen aufzeigt.

4 Verwendung der Zuwendung

Im Zentrum des Vorhabens PrABCast stand die Entwicklung einer Methodik zur prädiktiven Absatz- und Bedarfsplanung in kundenorientierten Auftragsfertigungssystemen unter Einsatz maschineller Lernverfahren. Die angestrebte Lösung wurde über eine Kombination datengetriebener Modellierungsansätze, methodischer Generalisierung und nutzerorientierter Implementierung in ein IT-Werkzeug realisiert. Die Projektergebnisse ermöglichen produzierenden Unternehmen – insbesondere KMU – eine vorausschauende Planung trotz hoher Kundenindividualisierung und sporadischem Abrufverhalten.

Die Bearbeitung des Vorhabens erfolgte durch wissenschaftliches Personal (23,83 Personenmonate), das die Koordination des Gesamtprojekts sowie die Entwicklung und Umsetzung der Modellierungsansätze übernahm. Schwerpunkte lagen dabei auf der Identifikation und Bewertung relevanter Datenquellen, der Durchführung multivariater Prognosen mit und ohne Datenanreicherung sowie der Validierung der Modelle in realen Anwendungsfällen der beteiligten Industriepartner.

Zur Erreichung der Projektziele wurde das wissenschaftliche Team durch studentische Hilfskräfte (8,2125 Personenmonate) unterstützt, die insbesondere bei der Recherche, Datenaufbereitung und der Erstellung erster Modellvarianten eingebunden waren. Zusätzlich wurden Teilarbeiten in Form wissenschaftlicher Abschlussarbeiten bearbeitet, um spezifische Fragestellungen tiefergehend zu untersuchen.

5 Notwendigkeit und Angemessenheit der geleisteten Arbeit

Die im Projekt PrABCast erbrachten Arbeiten erwiesen sich durchgängig als notwendig und angemessen, um die angestrebten Projektziele zu erreichen und die entwickelte Methodik zur prädiktiven Absatz- und Bedarfssplanung erfolgreich umzusetzen.

Die Bearbeitung der Projektinhalte erfolgte durch wissenschaftliches Personal, das insbesondere für die Konzeption, Durchführung und Validierung der datenanalytischen Verfahren sowie für die Überführung in ein praxisgerechtes IT-Werkzeug verantwortlich war. Die kontinuierliche Abstimmung mit Praxispartnern erwies sich insbesondere in den späteren Arbeitspaketen (AP 4–6) als erfolgskritisch. Hier fanden nahezu wöchentliche Rücksprachen mit Anwendern und Entwicklern statt, um modellbezogene Fragen, Anforderungen an die Softwarelösung sowie konkrete Anwendungsfälle eng abgestimmt bearbeiten zu können.

Im Vergleich zu klassischen Vorhaben zeigte sich frühzeitig, dass ein agiles, iteratives Vorgehen im digitalen Austausch – insbesondere über Microsoft Teams – ein besonders effektives Zusammenarbeitsmodell darstellte, da die Projektbearbeitung an Softwareentwicklung orientiert erfolgte. Größere Workshops

außerhalb der projektbegleitenden Ausschusssitzungen waren dadurch nicht erforderlich. Die enge und flexible Kommunikation ermöglichte eine zielgerichtete Umsetzung auch komplexer Inhalte in einem sich dynamisch entwickelnden Projektumfeld durch wechselnde Ansprechpartner bei den Anwenderunternehmen.

Maßgeblich für die entwickelten Ergebnisse war der Austausch mit größeren Unternehmen und Zielbranchen-fernen Unternehmen, die bereits fortgeschritten in datenbasierter Absatz- und Bedarfsprognose sind. Wichtige Hinweise und bestehendes Wissen konnte in die KMU-taugliche Lösung direkt integriert werden. Die Zusammensetzung des PA war ein weiterer zentraler Erfolgsfaktor für die industrielle Relevanz der Ergebnisse. Durch die Beteiligung unterschiedlicher Unternehmen aus der produzierenden Industrie sowie Systemanbieter konnte sowohl die Anwendbarkeit in verschiedenen Branchen als auch die technische Validität der entwickelten Lösung gewährleistet werden. Der regelmäßige Austausch mit dem PA – orientiert an den Meilensteinen – diente nicht nur der Qualitätssicherung, sondern auch der praxisnahen Ausrichtung der entwickelten Methodik.

Insgesamt waren alle geleisteten Arbeiten – sowohl im wissenschaftlichen als auch im praktischen Kontext – erforderlich, um die angestrebten Resultate im Sinne einer übertragbaren, anwendungsnahen Lösung für die prädiktive Absatz- und Bedarfsplanung in der kundenorientierten Auftragsfertigung zu realisieren.

6 Darstellung des wissenschaftlich-technischen und wirtschaftlichen Nutzens der erzielten Ergebnisse insbesondere für KMU sowie ihres innovativen Beitrags und ihrer industriellen Anwendungsmöglichkeiten

6.1 Wissenschaftlich-technische und wirtschaftlicher Nutzen

Das Forschungsprojekt PrABCast adressiert wesentliche wissenschaftlich-technische Herausforderungen in der kundenorientierten Auftragsfertigung. Diese Form der Fertigung stellt hohe Anforderungen an die Flexibilität und Reaktionsfähigkeit, da sie stark durch individuelle Kundenwünsche geprägt ist und mit einer hohen Variabilität in der Nachfrage einhergeht. Das Projekt zielte darauf ab, mithilfe verbesserter Absatz- und Bedarfsprognosen Variabilität früher auf das eigene Produktionssystem einwirken zu sehen. Darüber hinaus sind bestehende Prognosevorgehen in der kundenauftragsbasierten Fertigung nicht auf dem aktuellen Stand der Wissenschaft. Auftragsfertiger, insbesondere KMU, nutzen bislang häufig einfache, manuelle Schätzungen oder grundlegende statistische Verfahren, ohne sie zu hinterfragen, die aber vor allem für Lagerfertiger geeignet sind (Lödding 2008). Aufgrund der hohen Variabilität und Individualität in der Auftragsfertigung stoßen diese Methoden schnell an ihre Grenzen, insbesondere bei hybriden Strategien wie Assemble-to-Order (Meredith und Akinc 2007). Gleichzeitig bleiben viele Datenpotenziale ungenutzt, da KMU oft nicht über die Ressourcen oder das Know-how verfügen, diese systematisch für Prognosen zu verwenden (Buchholz et al. 2017). ML-Verfahren wie LSTM oder GRU können diese Lücke schließen, indem sie nicht nur präzisere Vorhersagen ermöglichen, sondern auch komplexe Bedarfsprofile und Datenquellen integrieren. (Hochreiter und Schmidhuber 1997a; Sherstinsky 2020; Akinc und Meredith 2015). Die in PrABCast entwickelte Methodik und die Umsetzung im Tool senken die Einstiegshürden für KMU und steigern die Akzeptanz moderner Technologien, ohne umfangreiche Investitionen in IT oder Personal zu erfordern (WIK 2019). Der wissenschaftlich-technische Nutzen zeigt sich insbesondere in folgenden Aspekten:

Adaption von ML-Verfahren für die Auftragsfertigung: Bisherige Prognosemethoden, insbesondere für die kundenorientierte Auftragsfertigung, basieren weitgehend auf traditionellen quantitativen Ansätzen wie ARIMA oder exponentiellen Glättungsverfahren. Diese Methoden stoßen bei komplexen, dynamischen Anforderungen häufig an ihre Grenzen. PrABCast setzt hier an, indem es auch ML-Verfahren (z. B. LSTM, GRU) adaptiert, die nicht-lineare Muster und Abhängigkeiten in großen, heterogenen Datensätzen identifizieren können. Damit wird eine höhere Prognosegüte auch unter Bedingungen von hoher Variabilität und sporadischem Bedarf erreicht.

Nutzung unerschlossener Datenpotenziale: Ein zentraler Innovationsaspekt des Projekts ist die Nutzung von Daten, die bislang ungenutzt bleiben. Durch die Kombination traditioneller Produktions- und Absatzdaten mit externen Datenquellen wie Markttrends, saisonalen Einflüssen und weiteren qualitativen Informationen werden zusätzliche Potenziale für eine präzisere Bedarfsplanung erschlossen und gezielt Prognosen angereichert. Besonders für KMU, die oft mit eingeschränkten Datenressourcen arbeiten, eröffnet dies neue Möglichkeiten, die bislang unzugänglich waren. Dies fördert nicht nur die Prognosegenauigkeit, sondern ermöglicht auch die Anwendung moderner Verfahren in datenarmen Umfeldern.

Entwicklung eines generalisierten Modells: Durch die Generalisierung der entwickelten Modelle wird eine breite Anwendbarkeit sichergestellt. Mithilfe von Transfer-Learning-Ansätzen können vortrainierte Modelle auf spezifische Anwendungsfälle von Unternehmen übertragen werden, wodurch sich der Trainingsaufwand reduziert und die Effizienz der Implementierung steigt. Die Modelle berücksichtigen typische Bedarfsprofile (stationär, trendartig, saisonal, sporadisch) und sind flexibel anwendbar. Auch das Training von Modellen ausschließlich mit eigenen Daten ist möglich.

Beitrag zur Transparenz und Nachvollziehbarkeit: Ein zentraler Kritikpunkt an vielen ML-Verfahren ist ihre fehlende Nachvollziehbarkeit, was ihre Akzeptanz in der Praxis einschränkt. Im Rahmen von PrABCast werden Transparenzmechanismen wie eine Nutzerführung integriert, um die Entscheidungsgrundlagen der Modelle transparent zu machen. Außerdem können Anwender selbst entscheiden, nach welchen Kriterien eine für sie relevante Prognose bewertet werden soll. So wird nicht nur die Prognosegüte gesteigert, sondern auch das Vertrauen der Anwender in die Modelle erhöht.

Langfristige Auswirkungen: Der wissenschaftlich-technische Nutzen des Projekts erstreckt sich über die unmittelbare Anwendung hinaus. Die im Projekt gewonnenen Erkenntnisse fördern den Wissenstransfer zwischen Forschung und Industrie, schaffen neue Standards für die prädiktive Planung und eröffnen Perspektiven für weiterführende Forschungsprojekte. Insbesondere die Einbeziehung von KMU trägt zur Erschließung bislang ungenutzter Anwendungsfelder bei.

Zusammenfassend stellt das Projekt PrABCast einen wesentlichen Beitrag zur wissenschaftlich-technischen Entwicklung im Bereich der prädiktiven Produktionsplanung durch eine verbesserte Absatz- und Bedarfsprognose dar. Es schließt bestehende Forschungslücken, hebt die Leistungsfähigkeit der Absatz- und Bedarfsprognose auf ein neues Niveau und erleichtert KMU den Zugang zu innovativen Technologien.

6.2 Wirtschaftliche Bedeutung der Forschungsergebnisse für KMU

Die Ergebnisse des Forschungsprojekts PrABCast sind von hoher wirtschaftlicher Relevanz für KMU in der kundenorientierten Auftragsfertigung und sogar darüber hinaus relevant und verwendbar. Unternehmen mit hybriden Produktionsstrategien, die Elemente der Lager- und Auftragsfertigung kombinieren, stehen vor der Herausforderung, kurzfristige Kundennachfragen flexibel und effizient zu bedienen (Stütz 2011). Diese

Anforderungen erfordern präzisere Absatz- und Bedarfsprognosen, um Kosten zu reduzieren und die Planbarkeit zu erhöhen.

Relevanz von Prognosen für KMU: Für KMU ist eine verlässliche Absatzplanung entscheidend, da sie oft von Abhängigkeiten innerhalb der Lieferkette geprägt sind (Buchholz et al. 2017, S. 8). KMU sind aber parallel circa 25% weniger mit ihrem Prognoseprozess zufrieden als größere Unternehmen. (Agrawal et al. 2020) Die im Projekt entwickelte Lösung ermöglicht auch Unternehmen mit eingeschränkter Datenverfügbarkeit zuverlässige Vorhersagen. Dies stellt einen signifikanten Fortschritt dar, da bisherige Ansätze – wie einfache lineare Modelle oder qualitative Verfahren – für die Anforderungen von KMU in der Auftragsfertigung oft unzureichend sind (Doberanzke 2020; Patil und Capgaon 2016). Dies erhöht die Flexibilität von KMU in nachfolgenden Prozessen wie Einkauf und Beschaffung, in denen sie häufig aufgrund der Abnahme kleinerer Mengen und kurzen Fristen in schlechteren Positionen sind. Dynamische Fähigkeiten wirken sich positiv auf die Wettbewerbsfähigkeit von KMU aus (Fabrizio et al. 2022).

Erschließung neuer Einsatzbereiche: Die Methodik von PrABCast ermöglicht die Nutzung von ML-Verfahren in bisher für die Absatzprognose ungeeigneten Produktgruppen der Anwender, wie etwa bei stark individualisierten Produkten oder variablen Nachfragemustern. So können KMU mit hybriden Strategien von denselben Einsparpotenzialen profitieren, die in anderen Branchen bereits nachgewiesen wurden.

Monetäre und strategische Vorteile: Eine Verbesserung der Prognosegenauigkeit um 15 % führte beispielsweise in der Lagerfertigung zu Einsparungen von 6 Millionen USD und einem Unternehmenswachstum von 5 % (Dillmann 2012, S. 15). Im Benchmarking erzielt die IT-Lösung aus PrABCast in vielen Vergleichen eine bessere Prognose des Absatzes als naive Verfahren oder die in den jeweiligen Unternehmen genutzten Vorgehensweisen. Damit können außerdem nicht nur Lager- und Produktionskosten reduziert, sondern auch die Durchlaufzeiten gesenkt und die Termintreue gesteigert werden. Zudem fördert die Anwendung digitaler Technologien eine langfristige Skalierbarkeit (Bargoni et al. 2024). Studien zeigen, dass stärker digitalisierte Unternehmen höhere Wachstumsraten bei Umsatz und Beschäftigung erzielen (Lichtblau et al. 2018).

Abbau von Hemmnissen: KMU stehen häufig vor Barrieren bei der Einführung neuer Technologien, etwa durch hohe Investitionskosten oder fehlende Kompetenzen (BMW 2015). Trotz wachsender Investitionen haben weniger als ein Drittel der Unternehmen einer BCG-Studie von Apotheker et al. (2025) ein Viertel ihrer Belegschaft im Umgang mit KI geschult, und nur 22 % überwachen finanzielle KPIs ihrer KI-Initiativen. Das im Projekt entwickelte IT-Werkzeug adressiert diese Hürden durch eine anwenderfreundliche Gestaltung und die aktive Begleitung der Anwendenden bei der Nutzung. Dies senkt die Eintrittsschwelle erheblich und baut Vorbehalte gegenüber KI ab.

Die im Projekt entwickelte Methodik bringt KMU nicht nur einen direkten wirtschaftlichen Nutzen, sondern erleichtert auch den Zugang zu digitalen Technologien und stärkt ihre Position in zunehmend dynamischen Märkten. Die Reduktion von Unsicherheiten in der Planung und die gesteigerte Effizienz machen PrABCast zu einem bedeutenden Beitrag für die Wettbewerbsfähigkeit von KMU.

7 Wissenstransfer in die Wirtschaft

Im Projektverlauf wurde der Wissenstransfer in die Wirtschaft aktiv gestaltet und nachhaltig verstetigt. Besonders auffallend war dabei die stetig wachsende Beteiligung von Unternehmen in Sitzungen des PA, was durch den Fortschritt und die Steigerung der praktischen Nähe der Ergebnisse bedingt war. Die

Rückmeldungen und Impulse der KMU flossen auch dann noch in die Ausarbeitung ein und führten dazu, dass spezifische Anwendungsszenarien frühzeitig identifiziert und adressiert werden konnten.

Ein weiterer entscheidender Faktor war die Zusammenarbeit mit NIRO als etabliertem Netzwerkpartner. Mit Hilfe der NIRO-Kommunikationsplattformen und bei Veranstaltungen des Netzwerks wurden erste Projektergebnisse zielgerichtet an ein breites Publikum aus der regionalen und überregionalen Wirtschaft vermittelt. So ermöglichte NIRO nicht nur den Zugang zu weiteren potenziellen Anwendern, sondern unterstützte auch den interdisziplinären Dialog zwischen Forschung, Systemanbietern und wirtschaftlichen Akteuren.

Darüber hinaus erwies sich die digitale Arbeitsweise über Microsoft Teams als äußerst wirkungsvoll: Kurze, regelmäßige Abstimmungen führten zu schnellen Reaktionen und einer kontinuierlichen Optimierung der entwickelten Verfahren. Der nahezu wöchentliche Austausch mit beteiligten Industrievertretern und Entwicklern schuf eine agile Umgebung, in der praxisrelevante Anpassungen zügig implementiert werden konnten. Auf diese Weise wurde nicht nur Wissen effektiv ausgetauscht, sondern auch direkt in unternehmensrelevante Fragestellungen übersetzt.

Zusätzlich fanden während der Projektlaufzeit gezielte Fachvorträge und die Einbindung des Projekts in Lehrveranstaltungen der TU Dortmund statt. Diese Formate trugen dazu bei, die wissenschaftlichen Erkenntnisse in den konkreten betrieblichen Alltag zu übertragen und auch Studierende sowie Nachwuchskräfte in die Thematik einzubinden.

Insgesamt ist der Wissenstransfer in die Wirtschaft während des Projekts PrABCast als erfolgreich zu betrachten, indem das Projekt dazu beigetragen hat, neu gewonnene wissenschaftliche Erkenntnisse direkt in die industrielle Praxis zu überführen und somit die Relevanz und Nachhaltigkeit der entwickelten Konzepte zu unterstreichen.

8 Durchgeführte Transfermaßnahmen

Die in Kapitel 7 beschriebenen Transfermaßnahmen sind in Tabelle 5 zusammengefasst.

Tabelle 5 - Übersicht über durchgeführte Transfermaßnahmen

Maßnahme	Ziel	Ort / Rahmen	Datum / Zeit
Informationen über die Institutshomepage	Verbreitung von Projektfortschritt und Projektergebnissen	Webbasiert	Fortlaufend
Sitzung des PA	<ul style="list-style-type: none"> • Ermittlung von Anforderungen • Inhaltliche Diskussion des Projektfortschritts • Charakterisierung von Unternehmen • UX/UI-Workshop • Sicherstellung der Akzeptanz des Tools • Verbreitung der Ergebnisse 	Der 2. PA wurde auf Grund eines digitalen Workshopformats und wegen Autobahnsperrung bei Dortmund vollständig digital durchgeführt	1. PA: 26.01.2023 2. PA: 14.03.2024 3. PA: 27.06.2024 4. PA: 12.12.2024

Transfer in die Industrie durch Netzwerke	Kontaktaufnahme zu interessierten Unternehmen und Diskussion der Ergebnisse	NIRO e.V.	Fortlaufend
Ergebnispräsentation auf Wissensplattformen	Austausch und Ergebnistransfer in die (regionale) Wirtschaft durch Plattformen.	<ul style="list-style-type: none"> Teilnahme an der Digitalen Woche Dortmund 2023 	27.09.2022 monatlich
Newsletter	Verbreitung der Entwicklungsarbeiten über Newsletter des IPS der TU Dortmund in die Wirtschaft	Digital	Fortlaufend
Master- / Bachelor- und Projektarbeiten im Themenfeld des Forschungsvorhabens	Fertigstellung wissenschaftlicher Arbeiten zur <ul style="list-style-type: none"> Vermittlung wissenschaftlicher Erkenntnisse im Themenfeld Heranführung von Studierenden an selbständiges wissenschaftliches Arbeiten 	<ul style="list-style-type: none"> Betreuung von studentischen Arbeiten durch die wissenschaftlichen Mitarbeiter und Professoren des IPS (insgesamt 5 studentische Arbeiten) Einbindung der Ergebnisse in die Veranstaltungsreihe „Gestaltung von Produktionssystemen“ (TU Dortmund) 	Fortlaufend
Ergebnisvorstellung auf Tagungen / Kongressen / Konferenzen	Schriftlicher Bericht und Vortrag über die Projektergebnisse	Vortrag über das Forschungsvorhaben: <ol style="list-style-type: none"> CIRP CMS ICECET 	1. 24.-26.10.2023 2. 25.-27.07.2024
Veröffentlichungen in Fachzeitschriften	Publikation der Ergebnisse für Industrie und Forschung	<ol style="list-style-type: none"> Procedia CIRP Journal of Intelligent Manufacturing Proceedings ICECET 	1. Publikation in 2023 2. Publikation in 2024 3. Publikation in 2024
Abschlussbericht	Informationen über Projektfortschritt	Veröffentlichung über BVL	Fortlaufend

9 Geplante spezifische Transfermaßnahmen nach der Projektlaufzeit

Nach Abschluss der Projektlaufzeit sind mehrere Maßnahmen geplant, um den Wissenstransfer nachhaltig fortzuführen. Bereits während des Projekts bekundeten mehrere Unternehmen ihr Interesse an einer weiterführenden Zusammenarbeit, sodass die Einführung zu diesen Partnern fortgesetzt wird. Ergänzend dazu sind Folgeforschungsaktivitäten vorgesehen, welche die bestehenden Ergebnisse vertiefen und in neue Forschungsfragen überführen sollen, die Anträge sind in Beantragung oder bereits in Begutachtung. Geplant ist

auch eine Workshopreihe unter dem Titel „Absatzprognose für KMU“, in der insbesondere die Bedürfnisse und Herausforderungen von mittelständischen Unternehmen adressiert werden.

Darüber hinaus stehen mehrere wissenschaftliche Publikationen in Vorbereitung, etwa

- Syberg, Marius; Polley, Lucas; Deuse, Jochen: Evaluating Sales Forecasting Methods in Make-to-Order Environments: A Cross-Industry Benchmark Study, (Akzeptiert: International conference on Time Series and Forecasting (ITISE 2025), evtl. Contributions on Statistics)
- Polley, Lucas; Syberg, Marius; Deuse, Jochen: Identifying and Refining Requirements for ML-Based Sales Forecasting Solutions: Evidence from Industrial Practice (Eingereicht: 10th International Conference on Operational Excellence, ISEP Porto)
- Syberg, Marius; Polley, Lucas; Deuse, Jochen: Systematic Integration of External Data Sources for Enhanced Sales Forecasting in Make-to-Order Manufacturing (geplant: IEEE International Conference on Industrial Engineering and Engineering Management (IEEM))
- Syberg, Marius; Polley, Lucas; Deuse, Jochen: Adapting Machine Learning for Sales Forecasting in Industrial Enterprises: A Practical Perspective (geplant: JIII - Journal of Industrial Information Integration 2025)

Ergänzend zu den geplanten Maßnahmen wird eine Dissertation angestrebt, in der die im Projekt gewonnenen Erkenntnisse vertiefend evaluiert und in strukturierter Form der wissenschaftlichen Gemeinschaft zugänglich gemacht werden sollen.

10 Zusammenfassung der Forschungsergebnisse und Ausblick

Das Forschungsprojekt PrABCast hat im Zuge der Entwicklung eines IT-Werkzeugs zur Absatz- und Bedarfsprognose in der kundenorientierten Auftragsfertigung zentrale Erkenntnisse erzielt, die sowohl den Stand der Technik als auch bestehende Forschungslücken adressieren. Insgesamt konnten die im Projekt formulierten Arbeitshypothesen bestätigt und weiter konkretisiert werden.

Die Ergebnisse verdeutlichen, dass klassische Prognosemodelle, etwa auf Basis von exponentieller Glättung oder ARIMA, den spezifischen Anforderungen variantenreicher Auftragsfertigungen nicht in vollem Umfang gerecht werden. Insbesondere stoßen diese Verfahren bei unregelmäßigen Nachfrageverläufen und hoher Produktindividualisierung an ihre Grenzen. Die entwickelte Methodik unter Integration von ML-Methoden hat gezeigt, dass eine Erweiterung bestehender Algorithmen in den Unternehmen - ergänzt durch eine systematische Anreicherung um weitere Datenquellen - zu einer zuverlässigen Prognoseleistung führt (AH 3: *Durch die Adaption verfügbarer ML-Verfahren und einer Anreicherung um qualitative und quantitative Datenquellen können zuverlässige Absatz- und Bedarfsprognosen in kundenorientierten Auftragsfertigung getroffen werden.*). Mit der Methodik werden nicht nur bisherige methodische Limitationen überwunden, sondern auch neue Potenziale erschlossen, die sich aus der Nutzung bislang ungenutzter Datenquellen ergeben (AH1: *Neben einsatzbereiten Quellen existieren unerschlossene (Daten-)Potentiale für Absatz- und Bedarfsprognosen*; AH 2: *Durch eine Bewertung und Kombination aller möglichen Datenquellen werden neue Einsatzbereiche erschlossen*).

Nicht zuletzt wurde auch der Aspekt der Generalisierbarkeit fokussiert. Während erste ML-Lösungen häufig nur für eng definierte Teilbereiche entwickelt wurden, zeigt das Projekt, dass die Identifikation charakteristischer Produktmerkmale und die Übertragung vortrainierter Modelle auf ähnliche Anwendungsfelder die Modellbildung unterstützen können (*AH 4: Eine Generalisierung durch charakteristische Produktmerkmale kann den Verlauf der Modellbildung unterstützen.*), aber nicht müssen. In Anwendungsfällen, in denen Absatzverläufe klare Trends oder Muster zeigen, sind statistische Verfahren gut für die Prognosen geeignet und gleichzeitig in ihrem Ergebnis interpretierbar. Daher wurde in der Entwicklung des IT-Tools beides integriert. Dieses IT-Werkzeug schafft eine hohe Transparenz über Analysen und wurde durch die durchgängige Kommunikation mit dem PA entwickelt, sodass es für eine hohe Nutzungsbereitschaft gestaltet wurde. (*AH 5: Durch hohe Nachvollziehbarkeit und Transparenz von Modellaussagen wird die Nutzungsbereitschaft gesteigert.; AH 6: Durch die Umsetzung der Methodik in einem IT-Werkzeug können KMU ML-Verfahren ohne Vorkenntnisse anwenden, wodurch Vorbehalte und Barrieren zu Datengenerierung, -aufbereitung und -verarbeitung abgebaut werden.*)

Die gewonnenen Erkenntnisse legen nahe, dass der weitere Ausbau datengetriebener Prognoseverfahren in der kundenorientierten Auftragsfertigung nicht nur technisch, sondern auch wirtschaftlich von hoher Relevanz ist. Dabei steigert PrABCast die Akzeptanz der Nutzung künstlicher Intelligenz in den Anwenderunternehmen merklich, wobei auch die gesellschaftliche Entwicklung maßgeblich ist. Für zukünftige Forschungsarbeiten ist so zu erörtern, inwiefern der gesamte Prozess rund um die Absatz-, Nachfrage- und Bedarfsplanung neben der Prognose selbst mit KI unterstützt werden kann. Auch die Absatzprognose selbst bietet Potential: Insbesondere der Fokus auf die Gütebestimmung einzelner Vorhersagen basierend auf den Aufgaben, die mit der Absatzprognose verbessert werden sollen, ist untersuchungsrelevant. Gleichzeitig muss erforscht werden, inwiefern KI-Verfahren auch genau diese Aufgaben unterstützen und verbessern können. Zukünftige Forschungsarbeiten sollten sich außerdem verstärkt der Integration zusätzlicher Datenquellen – vor allem interner Natur – widmen. Einzelne Versuche mit CRM-Daten eines Anwenderunternehmens waren vielversprechend, jedoch lagen diese Daten nicht im zeitlichen Verlauf vor, wodurch zwar der aktuelle Stand von Vertriebsaktivitäten mit in Prognosen integriert werden konnte, die Historie jedoch nicht. Dieses Beispiel zeigt auch, dass KMU teils nicht vom Potential ihrer Daten wissen und deswegen wenig Wert auf durchgängige Datenhaltung legen. Projekte wie PrABCast unterstützen jedoch das Verständnis der Entscheider für diese grundlegende Problematik datengetriebener Projekte.

Insgesamt leistet PrABCast einen signifikanten Beitrag zur Schließung bestehender Forschungslücken und demonstriert, wie durch die Adaption moderner Prognoseverfahren sowie einer zielgerichteten Datenanreicherung und benutzerfreundlichen Implementierung in IT-Werkzeugen eine nachhaltige Verbesserung der Absatz- und Bedarfsprognose in kundenorientierten Auftragsfertigungen erreicht werden kann.

11 Literaturverzeichnis

- Adizes, Ichak (1989): Corporate lifecycles. How and why corporations grow and die and what to do about it. 6th printing. Englewood Cliffs: Prentice Hall.
- Agrawal, A.; Khavkin, M.; Slonim, J. (2020): Bringing a real-world edge to forecasting. To improve the accuracy of corporate forecasts, build in the physical parameters from company operations. McKinsey. Online verfügbar unter <https://www.mckinsey.com/capabilities/strategy-and-corporate-finance/our-insights/bringing-a-real-world-edge-to-forecasting>, zuletzt aktualisiert am 28.03.2025.
- Akinc, Umit; Meredith, Jack R. (2015): Make-to-Forecast. Customization with Fast Delivery. In: *International Journal of Operations & Production Management* 35 (5), S. 728–750.
- Alvarado-Valencia, Jorge; Barrero, Lope H.; Önkal, Dilek; Dennerlein, Jack T. (2017): Expertise, credibility of system forecasts and integration methods in judgmental demand forecasting. In: *International Journal of Forecasting* 33 (1), S. 298–313. DOI: 10.1016/J.IJFORECAST.2015.12.010.
- Apotheker, Jessica; Duranton, Sylvain; Lukic, Vladimir; Bellefonds, Nicolas de; Iyer, Sesh; Bouffault, Olivier; Laubier, Romain de (2025): From Potential to Profit: Closing the AI Impact Gap. BCG AI Radar. BCG. Online verfügbar unter <https://www.bcg.com/publications/2025/closing-the-ai-impact-gap>, zuletzt aktualisiert am 28.01.2025.
- Armstrong, J. Scott (2008): Sales Forecasting. In: *SSRN Electronic Journal*, S. 1–16.
- Armstrong, J. Scott; Brodie, Roderick (1999): Forecasting for Marketing.
- Assmus, Gert; Farley, John U.; Lehmann, Donald R. (1984): How Advertising Affects Sales: Meta-Analysis of Econometric Results. In: *Journal of Marketing Research* 21 (1), S. 65. DOI: 10.2307/3151793.
- Babongo, Flora; Niemi, Tapio; Chavez-Demoulin, Valérie; Hameri, Ari-Pekka; Appelqvist, Patrik (2019): Forecasting (un-) seasonal demand using geostatistics, socio-economic and weather data. In: *International Journal of Business Forecasting and Marketing Intelligence* 5 (1), S. 103–124.
- Bandara, Kasun; Shi, Peibei; Bergmeir, Christoph; Hewamalage, Hansika; Tran, Quoc; Seaman, Biran (2019): Sales Demand Forecast in E-commerce using a Long Short-Term Memory Neural Network Methodology. In: *Computer Science - Machine Learning (arXiv.org)* 2, S. 1–16.
- Bargoni, Augusto; Ferraris, Alberto; Vilamová, Šárka; Wan Hussain, Wan Mohd Hirwani (2024): Digitalisation and internationalisation in SMEs: a systematic review and research agenda. In: *JEIM* 37 (5), S. 1418–1457. DOI: 10.1108/jeim-12-2022-0473.
- Bathaei, Yavar (2018): The artifical intelligence of black box and the failure of intent and causation. In: *Harvard Journal of Law & Technology* 31 (2), S. 889–938.
- BMWi (2015): Industrie 4.0. Volks- und betriebswirtschaftliche Faktoren für den Standort Deutschland. Eine Studie im Rahmen der Begleitforschung zum Technologieprogramm AUTONOMIK für Industrie 4.0. Berlin: Bundesministerium für Wirtschaft und Energie.

Bohlmann, Andreas; Scholten, Claudia; Desai, Rachana; Klapic, Edin (2024): Integrierte Datenanalyse zur Kolaboration in der Auftragsplanung. In: Jochen Deuse, Ralf Klinkenberg und Nikolai West (Hg.): Industrielle Datenanalyse. Wiesbaden: Springer Fachmedien Wiesbaden, S. 123–132.

Box, George E. P.; Jenkins, Gwilym M.; Reinsel, Gregory C. (2008): Time Series Analysis. Forecasting and Control. 4. Aufl.: John Wiley & Sons Inc. Publications.

Breiman, Leo (2001): Random Forests. In: *Machine Learning* 45 (1), S. 5–32. DOI: 10.1023/A:1010933404324.

Breiman, Leo; Friedman, Jerome H.; Olshen, Richard A.; Stone, Charles J. (1984): Classification And Regression Trees: Chapman and Hall/CRC.

BSI - Bundesamt für Sicherheit in der Informationstechnik (2018): IT-Grundschutz-Kompendium.

Buchholz, Birgit; Ferdinand, Jan-Peter; Gieschen, Jan-Hinrich; Seidel, Uwe (2017): Digitalisierung industrieller Wertschöpfung. Transformationsansätze für KMU. Berlin: iit-Institut für Innovation und Technik in der VDI/VDE Innovation + Technik GmbH.

Burbidge, John L. (1975): The introduction of group technology. London: Heinemann.

Buttle, Francis; Maklan, Stan (2019): Customer Relationship Management. Fourth Edition. | New York : Routledge, 2019. | Revised edition of the authors' Customer relationship management, 2015.: Routledge.

Cadavid, Juan Pablo Usuga; Lamouri, Samir; Grabot, Bernard (Hg.) (2018): Trends in machine learning applied to demand & sales forecasting: A review.

Case, Karl E.; Fair, Ray C.; Oster, Sharon M. (2020): Principles of Microeconomics. Thirteenth edition, Global Edition. Harlow, England, London, New York (und 19 weitere): Pearson.

Chai, T.; Draxler, R. R. (2014): Root mean square error (RMSE) or mean absolute error (MAE)? – Arguments against avoiding RMSE in the literature. In: *Geosci. Model Dev.* 7 (3), S. 1247–1250. DOI: 10.5194/GMD-7-1247-2014.

Chapman, Pete; Clinton, Julian; Kerber, Randy; Khabaza, Thomas; Reinartz, Thomas; Shearer, Colin; Wirth, Rüdiger (Hg.) (1999): The CRISP-DM user guide: sn (1999).

Chatfield, Christopher (1982): Analyse von Zeitreihen. Eine Einführung. München: Carl Hanser Verlag.

Chen, Tianqi; Guestrin, Carlos (2016): XGBoost. In: Balaji Krishnapuram, Mohak Shah, Alex Smola, Charu Aggarwal, Dou Shen und Rajeev Rastogi (Hg.): Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. KDD '16: The 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. San Francisco California USA, 13 08 2016 17 08 2016. New York, NY, USA: ACM, S. 785–794.

Cho, Kyunghyun; Merrienboer, Bart; Gulcehre, Caglar; Bougares, Fethi; Schwenk, Holger; Bengio, Y. (2014): Learning Phrase Representations using RNN Encoder-Decoder for Statistical Machine Translation. DOI: 10.3115/v1/D14-1179.

Choi, Hyunyoung; Varian, H. A.I. (2012): Predicting the Present with Google Trends. In: *Economic Record* 88 (s1), S. 2–9. DOI: 10.1111/j.1475-4932.2012.00809.x.

Cleveland, Robert B.; Cleveland, William S.; McRae, Jean E.; Terpenning, Irma (1990): STL: A seasonal-trend decomposition. In: *J. off. Stat* 6 (1), S. 3–73.

- Cohn, Mike (2005): Agile Estimating and Planning. USA: Prentice Hall PTR.
- Cools, Mario; Moons, Elke; Wets, Geert (2009): Investigating the variability in daily traffic counts through use of ARIMAX and SARIMAX models: Assessing the effect of holidays on two site locations. In: *Transportation research record* 2136 (1), S. 57–66.
- Das, Kauschik (2024): How Recurrent Neural Network (RNN) Works. dataaspirant.com. Online verfügbar unter <https://dataaspirant.com/how-recurrent-neural-network-rnn-works/>.
- Dey, Roshmita (2024): Time Series Decomposition. medium.com. Online verfügbar unter <https://medium.com/@roshmitadey/time-series-decomposition-62cbf31ab65e>.
- dida.do (2024): Was ist ein Random Forest? dida.do. Online verfügbar unter <https://dida.do/de/was-ist-ein-random-forest>.
- DIN EN ISO/IEC 27001:2024-01: DIN EN ISO/IEC 27001:2024-01.
- Doberanzke, Volker (2020): Der Einsatz qualitativer Methoden der Nachfrageprognose bei mittelständischen Unternehmen. Kiel, Hamburg: Leibniz Information Centre for Economics (ZBW).
- Draenert, Patric (2001): Kooperative Absatzplanung. Einführungsstrategie für den Prognosedatenaustausch. Wiesbaden: Springer Fachmedien.
- Eickelmann, Michel; Wiegand, Mario; Konrad, Benedikt; Deuse, Jochen (2015): Die Bedeutung von Data-Mining im Kontext von Industrie 4.0. In: *Zeitschrift für Wirtschaftlichen Fabrikbetrieb* 110 (11), S. 738–743.
- Enns, Phillip G.; Machak, Joseph A.; Spivey, W. Allen; Wrobleksi, William J. (1982): Forecasting Applications of an Adaptive Multiple Exponential Smoothing Model. In: *Management Science* 28 (9), S. 1035–1044. DOI: 10.1287/MNSC.28.9.1035.
- Escudero, Pedro; Alcocer, Willian; Paredes, Jenny (2021): Recurrent Neural Networks and ARIMA Models for Euro/Dollar Exchange Rate Forecasting. In: *Applied Sciences* 11 (12), S. 5658. DOI: 10.3390/app11125658.
- Fabrizio, Cleomar Marcos; Kaczam, Fabíola; Moura, Gilnei Luiz de; Da Silva, Luciana Santos Costa Vieira; Da Silva, Wesley Vieira; Da Veiga, Claudimar Pereira (2022): Competitive advantage and dynamic capability in small and medium-sized enterprises: a systematic literature review and future research directions. In: *Rev Manag Sci* 16 (3), S. 617–648. DOI: 10.1007/s11846-021-00459-8.
- Fayyad, Usama M.; Piatetsky-Shapiro, Gregory; Smyth, Padhraic (1996): From Data Mining to Knowledge Discovery. An Overview. In: Usama M. Fayyad, Gregory Piatetsky-Shapiro, Padhraic Smyth und Ramasamy Uthurusamy (Hg.): *Advances in Knowledge Discovery and Data Mining*. Menlo Park, CA: AAAI Press, S. 1–36.
- Fildes, Robert; Ma, Shaohui; Kolassa, Stephan (2022): Retail forecasting: Research and practice. In: *International Journal of Forecasting* 38 (4), S. 1283–1318. DOI: 10.1016/j.ijforecast.2019.06.004.
- Formánek, Tomáš; Sokol, Ondřej (2022): Location effects: Geo-spatial and socio-demographic determinants of sales dynamics in brick-and-mortar retail stores. In: *Journal of Retailing and Consumer Services* 66, S. 102902. DOI: 10.1016/j.jretconser.2021.102902.
- Friedman, Jerome H. (2001): Greedy function approximation: A gradient boosting machine. In: *Ann. Statist.* 29 (5). DOI: 10.1214/aos/1013203451.

Fritsch, Benjamin; Ullmann, Georg; Stonis, Malte; Nyhuis, Peter (2017): Absatzprognose mit Suchmaschinen Daten. In: *ZWF Zeitschrift für wirtschaftlichen Fabrikbetrieb* 112 (1-2), S. 16–19. DOI: 10.3139/104.111657.

Frost, Irsantiy (2018): Einfache lineare Regression. In: Irsantiy Frost (Hg.): Einfache lineare Regression. Wiesbaden: Springer Fachmedien Wiesbaden (essentials), S. 3–8.

Gansser, Oliver; Krol, Bianca (2015): Markt- und Absatzprognosen. Modelle, Methoden, Anwendung. Wiesbaden: Springer Gabler (FOM-Edition).

Gardner, Everette S. (2006): Exponential smoothing: The state of the art—Part II. In: *International Journal of Forecasting* 22 (4), S. 637–666. DOI: 10.1016/j.ijforecast.2006.03.005.

Goodfellow, Ian; Bengio, Yoshua; Courville, Aaron (2016): Deep Learning: The MIT Press.

Goodwin, Paul; Wright, George (2010): The limits of forecasting methods in anticipating rare events. In: *Technological forecasting and social change* 77 (3), S. 355–368.

Granger, C. W. J. (1969): Investigating Causal Relations by Econometric Models and Cross-spectral Methods. In: *Econometrica* 37 (3), S. 424. DOI: 10.2307/1912791.

Greene, William (2019): Econometric Analysis Global Edition: Pearson Deutschland. Online verfügbar unter <https://elibrary.pearson.de/book/99.150005/9781292231150>.

Hand, David J. (2003): Introduction. In: Michael Berthold und David J. Hand (Hg.): Intelligent Data Analysis. 2. Aufl. Berlin, Heidelberg: Springer Verlag, S. 1–15.

Hansmann, Karl-Werner (1983): Kurzlehrbuch Prognoseverfahren. Wiesbaden: Springer Fachmedien.

Hasan, M. Rokibul (2024): Addressing Seasonality and Trend Detection in Predictive Sales Forecasting: A Machine Learning Perspective. In: *JBMS* 6 (2), S. 100–109. DOI: 10.32996/jbms.2024.6.2.10.

Hastie, Trevor; Tibshirani, Robert; Friedman, Jerome (2009): The Elements of Statistical Learning. New York, NY: Springer New York.

Hellmers López, David; Kramer, Kathrin Julia; Schmidt, Matthias (2023): ML-basierte Absatzprognose mit Frühindikatoren. In: *ZWF Zeitschrift für wirtschaftlichen Fabrikbetrieb* 118 (5), S. 324–329. DOI: 10.1515/zwf-2023-1060.

Hevner, Alan; R, Alan; March, Salvatore; T, Salvatore; Park, Park, Jinsoo et al. (2004): Design Science in Information Systems Research. In: *Management Information Systems Quarterly* 28, 75–.

Hochreiter, Sepp; Schmidhuber, Jürgen (1997a): Long Short-term Memory. In: *Neural Computation MIT-Press*.

Hochreiter, Sepp; Schmidhuber, Jürgen (1997b): Long Short-Term Memory. In: *Neural Computation* 9 (8), S. 1735–1780.

Hoerl, Arthur E.; Kennard, Robert W. (2000): Ridge Regression: Biased Estimation for Nonorthogonal Problems. In: *Technometrics* 42 (1), S. 80–86. DOI: 10.1080/00401706.2000.10485983.

Holmes, William H.; Rinaman, William C. (2014): Multiple Linear Regression. In: William H. Holmes und William C. Rinaman (Hg.): Statistical Literacy for Clinical Practitioners. Cham: Springer International Publishing, S. 367–396.

- Holt, Charles C. (2004): Forecasting seasonals and trends by exponentially weighted moving averages. In: *International Journal of Forecasting* 20 (1), S. 5–10.
- Huang, Tingliang; van Mieghem, Jan A. (2014): Clickstream Data and Inventory Management: Model and Empirical Analysis. In: *Prod Oper Manag* 23 (3), S. 333–347. DOI: 10.1111/poms.12046.
- Hyndman, Rob J.; Athanasopoulos, George (2018): Forecasting. Principles and practice. 2nd edition. Melbourne: OTexts. Online verfügbar unter <https://otexts.com/fpp2/>.
- Hyndman, Rob J.; Koehler, Anne B. (2006): Another look at measures of forecast accuracy. In: *International Journal of Forecasting* 22 (4), S. 679–688. DOI: 10.1016/j.ijforecast.2006.03.001.
- Ingle, Chaitanya; Bakliwal, Dev; Jain, Jayesh; Singh, Preeyesh; Kale, Preeti; Chhajed, Vaibhav (2021): Demand Forecasting : Literature Review On Various Methodologies. In: 2021 12th International Conference on Computing Communication and Networking Technologies (ICCCNT). 2021 12th International Conference on Computing Communication and Networking Technologies (ICCCNT). Kharagpur, India, 06.07.2021 - 08.07.2021: IEEE, S. 1–7.
- Jadon, Aryan; Patil, Avinash; Jadon, Shruti (2024): A Comprehensive Survey of Regression-Based Loss Functions for Time Series Forecasting. In: Neha Sharma, Amol C. Goje, Amlan Chakrabarti und Alfred M. Bruckstein (Hg.): Data Management, Analytics and Innovation, Bd. 998. Singapore: Springer Nature Singapore (Lecture Notes in Networks and Systems), S. 117–147.
- Johnston, F. R.; Boyland, J. E.; Meadows, M.; Shale, E. (1999): Some properties of a simple moving average when applied to forecasting a time series. In: *Journal of the Operational Research Society* 50 (12), S. 1267–1271. DOI: 10.1057/PALGRAVE.JORS.2600823.
- Ke, Guolin; Meng, Qi; Finley, Thomas; Wang, Taifeng; Chen, Wei; Ma, Weidong et al. (2017): LightGBM: a highly efficient gradient boosting decision tree. In: Proceedings of the 31st International Conference on Neural Information Processing Systems. Red Hook, NY, USA: Curran Associates Inc (NIPS'17), S. 3149–3157.
- Kim, Sehoon (2023): Innovating knowledge and information for a firm-level automobile demand forecast system: A machine learning perspective. In: *Journal of Innovation & Knowledge* 8 (2), S. 100355. DOI: 10.1016/j.jik.2023.100355.
- Konzen, Evandro; Ziegelmann, Flavio A. (2016): LASSO-Type Penalties for Covariate Selection and Forecasting in Time Series. In: *Journal of Forecasting* 35 (7), S. 592–612. DOI: 10.1002/for.2403.
- Kotler, Philip; Keller, Kevin Lane; Opresnik, Marc Oliver (2017): Marketing-Management. Konzepte - Instrumente - Unternehmensfallstudien. 15., aktualisierte Auflage. Hallbergmoos, Germany: Pearson (Studium Economic BWL). Online verfügbar unter <https://elibrary.pearson.de/book/99.150005/9783863267742>.
- Kreinovich, Vladik; Nguyen, Hung T.; Ouncharoen, Rujira (2014): How to estimate forecasting quality: A system-motivated derivation of symmetric mean absolute percentage error (SMAPE) and other similar characteristics.
- Kreuter, Tobias; Scavarda, Luiz Felipe; Thomé, Antonio Márcio Tavares; Hellingrath, Bernd; Seeling, Marcelo Xavier (2022): Empirical and theoretical perspectives in sales and operations planning. In: *Rev Manag Sci* 16 (2), S. 319–354. DOI: 10.1007/s11846-021-00455-y.

- Kruse, Rudolf; Borgelt, Christian; Braune, Christian; Klawonn, Frank, Moewes, Christian; Steinbrecher, Matthias (2015): Computational Intelligence. Eine methodische Einführung in Künstliche Neuronale Netze, Evolutionäre Algorithmen, Fuzzy-Systeme und Bayes-Netze. 2. Aufl. Wiesbaden: Springer Vieweg.
- Kühnnapfel (2019): Vertriebsprognosen: Springer Fachmedien Wiesbaden.
- Kühnnapfel, Jörg B. (2015): Prognosen für Eilige: Naive Forecasts und ihre Rolle als Richtmaß. In: *Vertriebsprognosen: Methoden für die Praxis*, S. 166–171.
- Kuhne, Dirk (2015): Multiple Regression als Konzept zur Absatzprognose. In: Oliver Gansser und Bianca Krol (Hg.): Markt- und Absatzprognosen. Wiesbaden: Springer Fachmedien Wiesbaden, S. 3–26.
- Kuo, R. J.; Tseng, Y. S.; Chen, Zhen-Yao (2016): Integration of fuzzy neural network and artificial immune system-based back-propagation neural network for sales forecasting using qualitative and quantitative data. In: *J Intell Manuf* 27 (6), S. 1191–1207. DOI: 10.1007/s10845-014-0944-1.
- Lichtblau, Karl; Schleiermacher, Thomas; Goecke, Henry; Schützdeller, Peter (2018): Digitalisierung der KMU in Deutschland. Konzeption und empirische Befunde. Köln: IW Consults.
- Lödding, Hermann (2008): Verfahren der Fertigungssteuerung. Grundlagen, Beschreibung, Konfiguration. 2. Aufl. Berlin, Heidelberg: Springer-Verlag.
- Makridakis, Spyros; Hibon, Michele (1997): ARMA models and the Box–Jenkins methodology. In: *Journal of Forecasting* 16 (3), S. 147–163.
- Makridakis, Spyros; Spiliotis, Evangelos; Assimakopoulos, Vassilios (2018): Statistical and Machine Learning forecasting methods. Concerns and ways forward. In: *PLoS one* 13 (3), 1-26.
- Makridakis, Spyros; Spiliotis, Evangelos; Assimakopoulos, Vassilios (2020): The M4 Competition: 100,000 time series and 61 forecasting methods. In: *International Journal of Forecasting* 36 (1), S. 54–74.
- Makridakis, Spyros; Spiliotis, Evangelos; Assimakopoulos, Vassilios (2022): M5 accuracy competition: Results, findings, and conclusions. In: *International Journal of Forecasting* 38 (4), S. 1346–1364.
- Marill, Keith A. (2004): Advanced statistics: linear regression, part II: multiple linear regression. In: *Academic emergency medicine : official journal of the Society for Academic Emergency Medicine* 11 (1), S. 94–102. DOI: 10.1197/J.AEM.2003.09.006.
- Mentzer, John; Moon, Mark (2005): Sale Forecasting Management. A Demand Management Approach. 2. Aufl.: SAGE Publications Inc.
- Meredith, Jack; Akinc, Umit (2007): Characterizing and structuring a new make-to-forecast production strategy. In: *Journal of Operations Management* 25 (3), S. 623–642.
- Mertens, Peter; Rässler, Susanne (2012): Prognoserechnung. Heidelberg: Physica-Verlag HD.
- Meyer, David (2002): Naive time series forecasting methods. In: *R news* 2 (2), S. 7–10.
- Miller, Jon R. (1998): Spatial aggregation and regional economic forecasting. In: *The Annals of Regional Science* 32 (2), S. 253–266. DOI: 10.1007/s001680050073.
- Mir, Mostafa; Kabir, H. DipuM.; Nasirzadeh, Farnad; Khosravi, Abbas (2021): Neural network-based interval forecasting of construction material prices. In: *Journal of Building Engineering* 39, S. 102288. DOI: 10.1016/j.jobe.2021.102288.

Mitra, Rony; Saha, Priyam; Kumar Tiwari, Manoj (2024): Sales forecasting of a food and beverage company using deep clustering frameworks. In: *International Journal of Production Research* 62 (9), S. 3320–3332.

Montgomery, D. C.; Jennings, C. L.; Kulahci, M. (2015): *Introduction to Time Series Analysis and Forecasting*: Wiley. Online verfügbar unter <https://books.google.de/books?id=Xeh8CAAAQBAJ>.

MSCI (2024): The Global Industry Classification Standard (GICS®). Online verfügbar unter <https://www.msci.com/our-solutions/indexes/gics>, zuletzt geprüft am 01.10.2024.

MSCI; S&P Global Market Intelligence (2018): Global Industry Classification Standard. Online verfügbar unter https://www.spglobal.com/marketintelligence/en/documents/112727-gics-mapbook_2018_v3_letter_digitalspreads.pdf, zuletzt geprüft am 10.09.2024.

Noh, Jiseong; Park, Hyun-Ji; Kim, Jong Soo; Hwang, Seung-June (2020): Gated Recurrent Unit with Genetic Algorithm for Product Demand Forecasting in Supply Chain Management. In: *Mathematics* 565 (8), S. 1–14.

O'Leary-Kelly, Scott W.; Flores, Benito E. (2002): The integration of manufacturing and marketing/sales decisions: impact on organizational performance. In: *J of Ops Management* 20 (3), S. 221–240. DOI: 10.1016/S0272-6963(02)00005-0.

Okpighe, Sunday (2015): The Seven Factors of Production. In: *BJAST* 5 (3), S. 217–232. DOI: 10.9734/BJAST/2015/12080.

Ord, John Keith; Fildes, Robert; Kourentzes, Nikolaos (2017a): *Principles of business forecasting*. 2nd edition. New York, NY: Wessex Press Inc.

Ord, John Keith; Fildes, Robert; Kourentzes, Nikolaos (2017b): *Principles of business forecasting*. 2nd edition. New York, NY: Wessex Press Inc.

Osadchiy, Nikolay; Gaur, Vishal; Seshadri, Sridhar (2013): Sales Forecasting with Financial Indicators and Experts' Input. In: *Prod Oper Manag* 22 (5), S. 1056–1076. DOI: 10.1111/poms.12022.

Parmezan, Antonio Rafael Sabino; Souza, Vinicius M. A.; Batista, Gustavo EAPA (2019): Evaluation of statistical and machine learning models for time series prediction: Identifying the state-of-the-art and the best conditions for the use of each model. In: *Information sciences* 484, S. 302–337.

Patil, Rohit Vasant; Capgaon, A. N. (2016): Linear and Nonlinear Demand Forecasting for Effective Inventory Control. In: *International Journal of Advanced Research in Science, Engineering and Technology* 3 (1), S. 1223–1227.

Pearson, K. (1895): VII. Note on regression and inheritance in the case of two parents. In: *Proc. R. Soc. Lond.* 58 (347-352), S. 240–242. DOI: 10.1098/rspl.1895.0041.

Pepels, Werner (1995): Die Absatzprognose. In: Werner Pepels (Hg.): *Marketingforschung und Absatzprognose. Informationsgewinnung, Erhebungsmethoden*. Wiesbaden: Gabler (Praxis der Unternehmensführung), S. 86–107.

Probst, Philipp; Wright, Marvin N.; Boulesteix, Anne-Laure (2019): Hyperparameters and tuning strategies for random forest. In: *WIREs Data Min & Knowl* 9 (3), Artikel e1301. DOI: 10.1002/widm.1301.

Qu, T.; Zhang, J. H.; Chan, Felix T. S.; Srivastava, R. S.; Tiwari, M. K.; Park, Woo-Yong (2017): Demand prediction and price optimization for semi-luxury supermarket segment. In: *Computers & Industrial Engineering* 113, S. 91–102. DOI: 10.1016/j.cie.2017.09.004.

Quante, Rainer (2009): Management of Stochastic Demand in Make-to-Stock Manufacturing. Frankfurt a. M.: Peter Lang GmbH.

Rivera, Roberto (2020): Principles of Managerial Statistics and Data Science: Wiley.

Sagaert, Yves R.; Aghezzaf, El-Houssaine; Kourentzes, Nikolaos; Desmet, Bram (2018a): Tactical sales forecasting using a very large set of macroeconomic indicators. In: *European Journal of Operational Research* 264 (2), S. 558–569. DOI: 10.1016/j.ejor.2017.06.054.

Sagaert, Yves R.; Aghezzaf, El-Houssaine; Kourentzes, Nikolaos; Desmet, Bram (2018b): Temporal Big Data for Tactical Sales Forecasting in the Tire Industry. In: *Interfaces* 48 (2), S. 121–129. Online verfügbar unter <https://www.jstor.org/stable/48747750>.

Salehinejad, Hojjat; Sankar, Sharan; Barfett, Joseph; Colak, Errol; Valaee, Shahrokh (2018): Recent Advances in Recurrent Neural Networks. In: *Neural and Evolutionary Computing*.

Saura, José Ramón; Palos-Sánchez, Pedro; Cerdá Suárez, Luis Manuel (2017): Understanding the Digital Marketing Environment with KPIs and Web Analytics. In: *Future Internet* 9 (4), S. 76. DOI: 10.3390/fi9040076.

Scheer, August-Wilhelm (1983): Verfahrensauswahl. In: *Absatzprognosen*, S. 44–50.

Schmidt, Matthias; Nyhuis, Peter (2021): Produktionsplanung und -steuerung im Hannoveraner Lieferkettenmodell. Berlin, Heidelberg: Springer Berlin Heidelberg.

Schoene, Jens; Humayun, Muhammad; Ponnaya, Joseph; Johnson, Anthony; Ang, Julian; Manella, Adam (2024): Operational Forecasting – Use Cases and Implementation Challenges. In: 2024 IEEE/PES Transmission and Distribution Conference and Exposition (T&D). 2024 IEEE/PES Transmission and Distribution Conference and Exposition (T&D). Anaheim, CA, USA, 06.05.2024 - 09.05.2024: IEEE, S. 1–5.

Schuh, G.; Stich, V. (Hg.) (2012): Produktionsplanung und -steuerung 1. Grundlagen der PPS. 4. Aufl. Berlin: Springer (SpringerLink Bücher).

Schuh, Günther; Schmidt, Carsten (Hg.) (2014): Produktionsmanagement. 2. Aufl. Berlin: Springer Vieweg.

Schuh, Günther; Schmidt, Carsten; Adema, Jens (2014a): Auftragsmanagement. In: Günther Schuh und Carsten Schmidt (Hg.): Produktionsmanagement. 2. Aufl. Berlin: Springer Vieweg, S. 109–149.

Schuh, Günther; Schmidt, Carsten; Adema, Jens (2014b): Auftragsmanagement. In: Günther Schuh und Carsten Schmidt (Hg.): Produktionsmanagement. 2. Aufl. Berlin: Springer Vieweg, S. 109–149.

Shahin, Ashraf A. (2016): Using Multiple Seasonal Holt-Winters Exponential Smoothing to Predict Cloud Resource Provisioning. In: *International Journal of Advanced Computer Science and Applications* 7 (1), S. 91–96.

Sherstinsky, Alex (2020): Fundamentals of Recurrent Neural Network (RNN) and Long Short-Term Memory (LSTM) network. In: *Physica D: Nonlinear Phenomena* 404, S. 132306. DOI: 10.1016/j.physd.2019.132306.

Shiha, Ahmed; Dorra, Elkhayam M.; Nassar, Khaled (2022): Identification of Price Leading Indicators for Construction Resources. In: Proceedings of the 7th World Congress on Civil, Structural, and Environmental Engineering. The 7th World Congress on Civil, Structural, and Environmental Engineering, 10.04.2022 - 12.04.2022: Avestia Publishing (World Congress on Civil, Structural, and Environmental Engineering).

Shrestha, Noora (2020): Detecting Multicollinearity in Regression Analysis. In: *AJAMS* 8 (2), S. 39–42. DOI: 10.12691/ajams-8-2-1.

Smith, John Deep (2024): The Impact of Technology on Sales Performance in B2B Companies. In: *JAIGS* 3 (1), S. 246–261. DOI: 10.60087/jaigs.v3i1.118.

Smyl, Slawek (2020): A hybrid method of exponential smoothing and recurrent neural networks for time series forecasting. In: *International Journal of Forecasting* 36 (1), S. 75–85. DOI: 10.1016/j.ijforecast.2019.03.017.

Soule, David; Grushka-Cockayne, Yael; Merrick, Jason (2024): A Heuristic for Combining Correlated Experts When There Are Few Data. In: *Management Science* 70 (10), S. 6637–6668. DOI: 10.1287/mnsc.2021.02009.

Spitz, Beata (2018): Auftragsabwicklung. Profitabilität und Wettbewerbsvorteile durch eine schlanke Auftragsabwicklung. Königen: STAUFEN AG.

Stärk, Johannes (2011): Die Beziehung von Auftragsfertigung und Einzelfertigung - eine produktionswirtschaftliche Betrachtung. In: Wolf Wenger, Martin Josef Geiger und Andreas Kleine (Hg.): *Business Excellence in Produktion und Logistik*. Wiesbaden: Gabler, S. 177–198.

Strohm, O.; Ulich, E. (1997): Unternehmen arbeitspsychologisch bewerten: ein Mehr-Ebenen-Ansatz unter besonderer Berücksichtigung von Mensch, Technik und Organisation: vdf, Hochschulverl. an der ETH Zürich (MTO Schriftenreihe herausgegeben von Eberhard Ulich, Institut für Arbeitspsychologie der ETH Zürich). Online verfügbar unter <https://books.google.de/books?id=8bKIDwAAQBAJ>.

Stütz, Sebastian (2011): Kleine und mittlere Industrieunternehmen in der ökonomischen Theorie. Lohmar: Josef Eul Verlag GmbH (Kleine und mittlere Unternehmen, 22).

Syberg, Marius; West, Nikolai; Lenze, David; Deuse, Jochen (2023): Framework for predictive sales and demand planning in customer-oriented manufacturing systems using data enrichment and machine learning. In: *Procedia CIRP* 120, S. 1107–1112. DOI: 10.1016/j.procir.2023.09.133.

Szostek, Kamil; Mazur, Damian; Drałus, Grzegorz; Kusznier, Jacek (2024): Analysis of the Effectiveness of ARIMA, SARIMA, and SVR Models in Time Series Forecasting: A Case Study of Wind Farm Energy Production. In: *Energies* 17 (19), S. 4803. DOI: 10.3390/en17194803.

Tarallo, Elcio; Akabane, Getúlio K.; Shimabukuro, Camilo I.; Mello, Jose; Amancio, Douglas (2019): Machine Learning in Predicting Demand for Fast-Moving Consumer Goods: An Exploratory Research. In: *IFAC-PapersOnLine* 52 (13), S. 737–742. DOI: 10.1016/j.ifacol.2019.11.203.

Teixeira, Mariana; Oliveira, José Manuel; Ramos, Patrícia (2024): Enhancing Hierarchical Sales Forecasting with Promotional Data: A Comparative Study Using ARIMA and Deep Neural Networks. In: *MAKE* 6 (4), S. 2659–2687. DOI: 10.3390/make6040128.

Thonemann, Ulrich (2010): *Operations Management. Konzepte, Methoden und Anwendungen*. 2. Aufl. München: Pearson Studium.

Tibshirani, Robert (1996): Regression Shrinkage and Selection via the Lasso. In: *Journal of the Royal Statistical Society. Series B (Methodological)* 58 (1), S. 267–288. Online verfügbar unter <http://www.jstor.org/stable/2346178>.

Toktay, L. Beril; Wein, Lawrence M. (2001): Analysis of a Forecasting-Production-Inventory System with Stationary Demand. In: *Management Science* 47 (9), S. 1268–1281. DOI: 10.1287/mnsc.47.9.1268.9787.

Tuomikangas, Nina; Kaipia, Riikka (2014): A coordination framework for sales and operations planning (S&OP): Synthesis from the literature. In: *International Journal of Production Economics* 154, S. 243–262. DOI: 10.1016/J.IJPE.2014.04.026.

Verstraete, Gylian; Aghezzaf, El-Houssaine; Desmet, Bram (2020): A leading macroeconomic indicators' based framework to automatically generate tactical sales forecasts. In: *Computers & Industrial Engineering* 139, S. 106169. DOI: 10.1016/j.cie.2019.106169.

Vogel, Jürgen (2015): Prognose von Zeitreihen. Wiesbaden: Springer Fachmedien Wiesbaden.

Wang, Chih-Hsuan; Gu, Yu-Wei (2022): Sales Forecasting, Market Analysis, and Performance Assessment for US Retail Firms: A Business Analytics Perspective. In: *Applied Sciences* 12 (17), S. 8480. DOI: 10.3390/app12178480.

Weichel, Petra; Herrmann, Jochen (2016): Wie Controller von Big Data profitieren können. In: Utz Schäffer und Jürgen Weber (Hg.): Big Data. Zeitenwende für Controller. Wiesbaden: Springer Gabler (Controlling & management review Sonderheft, 60. Jahrgang, Sonderheft 1 (2016)), S. 8–14.

Weiner, Christian (2005): The impact of industry classification schemes on financial research. Berlin: Humboldt University of Berlin, Collaborative Research Center 649 - Economic Risk (SFB 649 Discussion Paper) (2005,062). Online verfügbar unter <https://hdl.handle.net/10419/25081>.

Weng, Tingyu; Liu, Wenyang; Xiao, Jun (2020): Supply chain sales forecasting based on lightGBM and LSTM combination model. In: *Industrial Management & Data Systems* 120 (2), S. 265–279.

Wiendahl, Hans-Peter; Nyhuis, Peter; Fischer, Andreas; Grabe, Daniel (2006): Controlling in Lieferketten. In: Günther Schuh (Hg.): Produktionsplanung und -steuerung. Berlin, Heidelberg: Springer Berlin Heidelberg (VDI-Buch), S. 467–510.

WIK (2019): Künstliche Intelligenz im Mittelstand. Relevanz, Anwendung, Transfer. Bad Honnef: Begleitforschung Mittelstand-Digital WIK GmbH.

Winters, Peter R. (1960): Forecasting Sales by Exponentially Weighted Moving Averages. In: *Management Science* 6 (3), S. 324–342. DOI: 10.1287/mnsc.6.3.324.

Wolpert, D. H.; Macready, W. G. (1997): No free lunch theorems for optimization. In: *IEEE Trans. Evol. Computat.* 1 (1), S. 67–82. DOI: 10.1109/4235.585893.

Wooldridge, Jeffrey M. (2020): Introductory econometrics : a modern approach / Jeffrey M. Wooldridge (Michigan State University). 7th edition. Boston, MA: Cengage.

Zhang, Hanyuan; Song, Haiyan; Wen, Long; Liu, Chang (2021): Forecasting tourism recovery amid COVID-19. In: *Annals of Tourism Research* 87, S. 103149.

12 Anhang

Anhang 1: Recherche der Prognoseverfahren

Name	Abkürzung	Katego- rie	Art	Klassifizie- rung	Art Datenquellen	Anzahl Da- tenquellen	Beschreibung des Verfahrens	Formel	Detailkategorisie- rung	Quellen
Expertbefragung / Expertenschätzung		Qualita- tiv	Qualitatives Verfahren	Qualitativ	Qualitativ, sub- jektiv	Variabel (mul- tivariat)	Bei einer Expertenbefragung werden Personen mit fundiertem Fachwissen befragt, um zukünftige Entwicklungen, Trends oder Absatzmengen abzuschätzen. Nützlich bei fehlenden oder unvollständigen historischen Daten.	Keine Formel (qualitatives Verfahren)	Qualitativ	Vogel (2015); Menter- zer & Moon (2005); Gansser & Sieper- mann (2021); Hans- mann (1983)
Delphi-Methode		Qualita- tiv	Qualitatives Ex- pertenverfah- ren	Qualitativ, iterativ	Qualitativ, sub- jektiv	Multivariat (mehrere Ex- perten)	Iteratives Expertenverfahren in mehreren Runden. Jede Runde erhalten Experten eine anonyme Zusammenfassung der vorherigen Antworten, um ihre Prognosen ggf. anzupassen. Ziel: Konsens über zukünftige Entwicklungen.	Keine Formel (qualitatives Verfahren)	Qualitativ, iteratives Expertenverfahren	Vogel (2015); Menter- zer & Moon (2005); Gansser & Sieper- mann (2021)
Szenario-Analysen		Qualita- tiv	Qualitatives bzw. semi- quantitatives Verfahren	Qualitativ / Semi- quantita- tiv	Multidimensio- nal	Multivariat	Es werden verschiedene plausible Zukunftsszenarien (Best Case, Trend, Worst Case) entworfen, die auf unterschiedlichen Annahmen beruhen. Unterstützt strategische Planung durch Darstellung möglicher Entwicklungen.	Keine klassische Prognose- formel (Szenarien basieren auf Annahmen)	Qualitativ / Semi- quantitativ	International Journal of Forecasting (2022); Gansser & Siepermann (2021)
Fallstudien		Qualita- tiv	Qualitative, empirische Me- thode	Qualitativ, empirisch	Variabel (mul- tivariat)		Fallstudien untersuchen detailliert einzelne Fälle (z. B. Unternehmen, Projekte) in ihrer natürlichen Umgebung. Sie ermöglichen ein vertieftes Verständnis komplexer Sachverhalte und können qualitative wie auch quantitative Daten umfassen.	Keine Formel (qualita- tive/empirische Methode)	Qualitativ, empirisch	Gansser & Sieper- mann (2021); Menter- zer & Moon (2005)
Naive Prognose		Quanti- tativ	Statistisch	Zeitrei- henorientiert	Univariat	1 (Zeitreihe)	Die einfachste Form der Prognose: Der letzte beobachtete Wert wird als Vorhersage für die Zukunft übernommen.	Besitzt keine eigene Formel außer „Prognose = letzter Ist-Wert“	Zeitreihenbasiert, einfaches Bench- mark-Verfahren	Makridakis & Wheel- wright (1989)
Konstanter Mittel- wert		Quanti- tativ	Statistisch	Zeitrei- henorientiert	Univariat	1 (Zeitreihe)	Verfahren, bei dem für alle zukünftigen Zeitpunkte der konstante Durchschnittswert der Vergangenheit als Prognose genommen wird.	Prognose = (1/N) * \sum (Ver- gangene Werte)	Zeitreihenbasiert, einfaches Bench- mark-Verfahren	Hyndman & Atha- nasopoulos (2018)
Lineare Regression		Quanti- tativ	Statistisch	Regres- sion	Uni-/multivariat	Anzahl der Prädiktoren + 1 abhängige Variable	Ein Regressionsverfahren, das einen linearen Zu- sammenhang zwischen einer abhängigen und einer oder mehreren unabhängigen Variablen annimmt.	Allgemein: $Y = \beta_0 + \beta_1 X_1 + \dots + \beta_n X_n + \varepsilon$	Regressiv, statistisch	Seber & Lee (2003); Hastie et al. (2009)
Polynomiale Regres- sion		Quanti- tativ	Statistisch	Regres- sion	Uni-/multivariat	Variiert	Erweitert die lineare Regression um polynomiale Terme, um nichtlineare Zusammenhänge abzubilden.	$Y = \beta_0 + \beta_1 X + \beta_2 X^2 + \dots + \beta_n X^n + \varepsilon$	Regressiv, statistisch	Seber & Lee (2003); Hastie et al. (2009)
Multiple Regression		Quanti- tativ	Statistisch	Regres- sion	Multivariat	Mehrere Prädiktoren (X_1, X_2, \dots)	Modelliert den linearen Zusammenhang zwischen einer abhängigen Variable und mehreren unabhängigen Variablen.	$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_p X_p + \varepsilon$	Regressiv, statistisch	Seber & Lee (2003); Hastie et al. (2009)
Curvilinearer Trend		Quanti- tativ	Statistisch	Zeitrei- henbasiert	Uni-/multivariat	1 Zeitreihe, ggf. + exogene Variablen	Geht von einem gekrümmten (nichtlinearen) Trend- verlauf aus; wird genutzt, wenn eine einfache lineare Annahme nicht genügt.	$Y_t = a + b_1 t + b_2 t^2 + \dots + \varepsilon_t$ (oder andere nichtlineare Formen)	Trendanalyse, zeit- reihenbasiert	Makridakis et al. (1998); Hyndman & Athanasopoulos (2018)

Komponentenmodell		Quantitativ	Statistisch	Zeitreihenbasiert	Univariat	1 (Zeitreihe)	Zerlegt eine Zeitreihe in Trend, Saison, Zyklus und Residuum, um Prognosen zu erstellen.	Additiv: $Y_t = T_t + S_t + E_t$; Multiplikativ: $Y_t = T_t \times S_t \times E_t$	Zeitreihenzerlegung	Makridakis et al. (1998); Hyndman & Athanasopoulos (2018)
Zyklische Komponenten		Quantitativ	Statistisch	Zeitreihenbasiert	Univariat	1 (Zeitreihe)	Beschreibt längerfristige Schwankungen (z. B. Konjunkturzyklen). Kein eigenständiges Prognoseverfahren, sondern Teil der Zeitreihenzerlegung.	Keine eigenständige Formel; oft Teil: $Y_t = T_t + S_t + C_t + E_t$	Zeitreihenkomponente	Makridakis et al. (1998); Hyndman & Athanasopoulos (2018)
Saisonale Komponenten		Quantitativ	Statistisch	Zeitreihenbasiert	Univariat	1 (Zeitreihe)	Beschreibt periodische Schwankungen innerhalb eines Jahres (z. B. monatlich). Kein eigenständiges Verfahren, sondern Teil vieler Zeitreihenmodelle.	Keine eigenständige Formel; oft S_t in $Y_t = T_t + S_t + E_t$ oder $Y_t = T_t \times S_t \times E_t$	Zeitreihenkomponente	Makridakis et al. (1998); Hyndman & Athanasopoulos (2018)
Gleitender Durchschnitt		Quantitativ	Statistisch	Zeitreihenbasiert	Univariat	1 (Zeitreihe)	Ein einfaches Verfahren zur Glättung von Zeitreihen, indem der Durchschnitt der letzten n Beobachtungen als Prognose genutzt wird. Funktioniert nur, wenn kein Trend vorhanden ist.	$Y_t = (X_t + X_{t-1} + \dots + X_{t-n+1}) / n$	Zeitreihenbasiert, einfaches Benchmark-Verfahren	Makridakis et al. (1998); Hyndman & Athanasopoulos (2018)
Exponentielle Glättung 1. Ordnung		Quantitativ	Statistisch	Zeitreihenbasiert	Univariat	1 (Zeitreihe)	Prognoseverfahren, das vergangenen Beobachtungen einer exponentiell abnehmende Gewichtung zuweist. Eignet sich für Zeitreihen ohne Trend oder Saisonalität.	$S_t = \alpha X_t + (1-\alpha)S_{t-1}$, $0 < \alpha < 1$	Glättend, einfaches Benchmark-Verfahren	Holt (1957); Hyndman & Athanasopoulos (2018)
Exponentielle Glättung 2. Ordnung		Quantitativ	Statistisch	Zeitreihenbasiert	Univariat	1 (Zeitreihe)	Erweiterung der einfachen exponentiellen Glättung, berücksichtigt zusätzlich Trends in der Zeitreihe.	$Y_{t+1} = S_t + T_t$, mit $S_t = \alpha X_t + (1-\alpha)(S_{t-1} + T_{t-1})$ und $T_t = \beta(S_t - S_{t-1}) + (1-\beta)T_{t-1}$	Glättend, trendbasiert	Holt (1957); Hyndman & Athanasopoulos (2018)
Exponentielle Glättung 3. Ordnung	SES	Quantitativ	Statistisch	Zeitreihenbasiert	Univariat	1 (Zeitreihe)	Erweiterung der exponentiellen Glättung 2. Ordnung, die zusätzlich saisonale Komponenten berücksichtigt.	$Y_{t+m} = S_t + mT_t + C_{t+m-1}$ mit S_t, T_t, C_t wie in Holt-Winters-Formel	Glättend, saisonal	Holt-Winters (1960); Hyndman & Athanasopoulos (2018)
Holt-Winters 3. Ordnung	HW	Quantitativ	Statistisch	Zeitreihenbasiert	Univariat	1 (Zeitreihe)	Erweiterte exponentielle Glättung mit Anpassung für Trend- und saisonale Komponenten. Unterstützt additive und multiplikative Saisonalität.	Trend: $T_t = \beta(S_t - S_{t-1}) + (1-\beta)T_{t-1}$, Saison: $C_t = \gamma(X_t/S_t) + (1-\gamma)C_{t-1}$, Prognose: $Y_{t+m} = (S_t + mT_t)C_{t+m-1}$	Glättend, saisonal, trendbasiert	Holt-Winters (1960); Hyndman & Athanasopoulos (2018)
Autoregression	AR	Quantitativ	Statistisch	Zeitreihenbasiert	Univariat	1 (Zeitreihe)	Autoregressive Modelle verwenden vergangene Werte der Zielvariable selbst, um deren zukünftige Werte vorherzusagen.	$Y_t = c + \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \dots + \phi_p Y_{t-p} + \varepsilon_t$	Regressiv, zeitreihenbasiert	Box & Jenkins (1976); Hyndman & Athanasopoulos (2018)
Moving Average	MA	Quantitativ	Statistisch	Zeitreihenbasiert	Univariat	1 (Zeitreihe)	Beim Moving-Average-Modell wird die Zielvariable als lineare Kombination vergangener Fehlerterme modelliert.	$Y_t = \mu + \varepsilon_t + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \dots + \theta_q \varepsilon_{t-q}$	Regressiv, zeitreihenbasiert	Box & Jenkins (1976); Hyndman & Athanasopoulos (2018)
Autoregressive Moving Average	ARMA	Quantitativ	Statistisch	Zeitreihenbasiert	Univariat	1 (Zeitreihe)	ARMA kombiniert autoregressive (AR) und gleitende Durchschnittskomponenten (MA) in einem Modell.	$Y_t = c + \phi_1 Y_{t-1} + \dots + \phi_p Y_{t-p} + \varepsilon_t + \theta_1 \varepsilon_{t-1} + \dots + \theta_q \varepsilon_{t-q}$	Regressiv, zeitreihenbasiert	Box & Jenkins (1976); Hyndman & Athanasopoulos (2018)
ARIMA (Autoregressive Integrated Moving Average)	ARIMA	Quantitativ	Statistisch	Zeitreihenbasiert	Univariat	1 (Zeitreihe)	ARIMA erweitert ARMA um Differenzierung (I), um die Zeitreihe stationär zu machen.	$Y_t = c + \phi_1 Y_{t-1} + \dots + \phi_p Y_{t-p} + \varepsilon_t + \theta_1 \varepsilon_{t-1} + \dots + \theta_q \varepsilon_{t-q}$	Regressiv, zeitreihenbasiert	Box & Jenkins (1976); Hyndman & Athanasopoulos (2018)

Seasonal Autoregressive Integrating Moving Average	SARIMA	Quantitativ	Statistisch	Zeitreihenbasiert	Univariat	1 (Zeitreihe)	Erweitert ARIMA um saisonale AR- und MA-Komponenten, um periodische Muster zu modellieren.	$\Phi(B^s)^d Y_t = c + \Theta(B^s)^d \varepsilon_t$	Regressiv, zeitreihenbasiert, saisonal	Box & Jenkins (1976); Hyndman & Athanasopoulos (2018)
Seasonal Autoregressive Integrated Moving Average and exogenous variables	SARIMAX	Quantitativ	Statistisch	Zeitreihenbasiert	Multivariat	1 Zeitreihe + exogene Variablen	Erweitert SARIMA um externe (exogene) Variablen, die die Zielvariable zusätzlich beeinflussen.	$\Phi(B^s)^d Y_t = c + \Theta(B^s)^d \varepsilon_t + X_t \beta$	Regressiv, zeitreihenbasiert, saisonal, exogen	Box & Jenkins (1976); Hyndman & Athanasopoulos (2018)
Autoregressive Conditional Heteroscedasticity	ARCH	Quantitativ	Statistisch	Zeitreihenbasiert	Univariat	1 (Zeitreihe)	ARCH (von Engle 1982) modelliert die Varianz der Zeitreihe als abhängig von vergangenen Fehlerquadrataten. Geeignet für Finanzdaten mit wechselnder Volatilität.	$\sigma_t^2 = \alpha_0 + \alpha_1 \varepsilon_{t-1}^2 + \dots + \alpha_p \varepsilon_{t-p}^2$	Volatilitätsmodell	Engle (1982)
Generalised Autoregressive Conditional Heteroscedasticity	GARCH	Quantitativ	Statistisch	Zeitreihenbasiert	Univariat	1 (Zeitreihe)	GARCH (von Bollerslev 1986) verallgemeinert ARCH, indem auch frühere Varianzwerte in die Modellierung der aktuellen Varianz einfließen.	$\sigma_t^2 = \alpha_0 + \sum(\alpha_i \cdot \varepsilon_{t-i}^2) + \sum(\beta_j \cdot \sigma_{t-j}^2)$	Volatilitätsmodell	Bollerslev (1986)
Croston		Quantitativ	Statistisch	Zeitreihenbasiert	Univariat	1 (Zeitreihe)	Verfahren zur Prognose von intermittierender Nachfrage. Splittet die Zeitreihe in Nachfragegröße und Zwischenanlagedauer (Interarrival Time).	$p_t = \alpha \cdot l_t + (1-\alpha) \cdot p_{t-1}; q_t = \alpha \cdot D_t + (1-\alpha) \cdot q_{t-1}; \text{Forecast} = q_t / p_t$	Intermittent Demand Forecasting	Croston (1972)
SEATREND-Verfahren		Quantitativ	Statistisch	Zeitreihenbasiert	Univariat	1 (Zeitreihe)	Methode zur Zerlegung einer Zeitreihe in Saison-, Trend- und Restkomponenten. Kann für Prognosen genutzt werden, indem die Komponenten fortgeschrieben werden.	Keine einheitliche Formel; i. d. R. $Y_t = T_t + S_t + E_t$ oder $Y_t = T_t \times S_t \times E_t$	Zeitreihenzerlegung	Makridakis et al. (1998); Hyndman & Athanasopoulos (2018)
Syntetos-Boylan		Quantitativ	Statistisch	Zeitreihenbasiert	Univariat	1 (Zeitreihe)	Syntetos-Boylan Approximation (SBA) ist eine Anpassung von Crostons Methode, um einen Bias bei intermittierender Nachfrage zu verringern.	Forecast = $(p_t - \alpha/2) \times q_t / p_t$ (vereinfacht)	Intermittent Demand Forecasting	Syntetos & Boylan (2005)
Shale-Boylan-Johnson		Quantitativ	Statistisch	Zeitreihenbasiert	Univariat	1 (Zeitreihe)	Erweiterung von Crostons Ansatz zur Prognose intermittierender Nachfrage; versucht Genauigkeit durch angepasste Schätzung von Nachfragegröße und -häufigkeit zu steigern.	Keine einheitliche Kurzformel, Variation von Croston	Intermittent Demand Forecasting	Shale, Boylan & Johnston (2006)
Teuner-Syntetos-Babai		Quantitativ	Statistisch	Zeitreihenbasiert	Univariat	1 (Zeitreihe)	T.S.B.-Methode zur Schätzung von Wahrscheinlichkeit (p_t) und Größe (q_t) der Nachfrage getrennt. Danach Prognose = $p_t \times q_t$.	$p_t = \alpha \cdot z_t + (1-\alpha) \cdot p_{t-1}; q_t = \alpha \cdot X_t + (1-\alpha) \cdot q_{t-1}; \text{Forecast} = p_t \times q_t$	Intermittent Demand Forecasting	Teuner, Syntetos & Babai (2010)
Vektor-Autoregression	VAR	Quantitativ	Statistisch	Zeitreihenbasiert; regressiv	Multivariat	Mehrere Zeitreihen	Erweiterung des univariaten AR-Modells auf mehrere (z. B. makroökonomische) Zeitreihen, um lineare Abhängigkeiten zwischen den Variablen zu modellieren.	$X_t = c + A_1 X_{t-1} + \dots + A_p X_{t-p} + \varepsilon_t$	Regressiv, multivariate Zeitreihen	Lütkepohl (2005); Hamilton (1994)
Multi-Aggregation Prediction		Quantitativ	Statistisch	Mischverfahren	Variabel (kann mehrere Quellen kombinieren)	Mehrere Teilprognosen	Ein Ansatz, bei dem Prognosen aus unterschiedlichen Granularitäten (z. B. unterschiedliche Hierarchieebenen oder Zeitintervalle) zusammengeführt werden, um eine Gesamtprognose zu erzeugen.	Oft gewichtete Kombination: $Y = w_1 \cdot Y_1 + w_2 \cdot Y_2 + \dots + w_n \cdot Y_n$	Aggregationsmethode	Kahn (1998); Armstrong (2001)
Support Vector Regression	SVR	Quantitativ	Machine Learning	Regression	Multivariat	Variiert (abhängig von Features)	Nutzt das Prinzip der strukturellen Risikominimierung, um eine Regressionsfunktion zu finden, deren Abweichung von den Zielwerten nicht größer als ε ist.	$y(x) = \sum_i (\alpha_i - \alpha_i^*) K(x_i, x) + b$	Regressiv, kernelbasiert	Drucker et al. (1997); Smola & Schölkopf (2004)
Support Vector Machines	SVM	Quantitativ	Machine Learning	Klassifikation/Regression	Multivariat	Variiert (abhängig von Features)	Allgemeiner Rahmen der Support-Vector-Methoden, die sowohl für Klassifikations- als auch Regressionsprobleme verwendet werden können.	Klassifikation: $y = \text{sign}(\sum_i \alpha_i y_i K(x_i, x) + b)$; Regression analog SVR	ML, kernelbasiert	Cortes & Vapnik (1995); Schölkopf & Smola (2002)

							Versucht, die optimale Trennungs- oder Approximationshyperfläche zu finden.				
Gradient Boosted Regression	GBR	Quantitativ	Machine Learning	Baumbasiert, Ensemble	Multivariat	Variiert	Ein Ensemble-Verfahren, bei dem sequentiell schwache Regressionsbäume trainiert und kombiniert werden, um die Vorhersageleistung schrittweise zu verbessern.	$\hat{y} = \sum_i (\text{learning_rate} \times h_i(x))$ (Summe über i Bäume)	Baumbasiert, Ensemble, Regressiv	Friedman (2001); Hastie et al. (2009)	
Extreme Gradient Boosted Regression	XGBoost	Quantitativ	Machine Learning	Baumbasiert, Ensemble	Multivariat	Variiert	Schnelle und optimierte Implementierung von Gradient Boosting, basierend auf Entscheidungsbäumen mit Fokus auf Skalierbarkeit und Performance.	$\hat{y} = \sum_k f_k(x)$, k=1..K (mit Regularisierung)	Baumbasiert, Ensemble, Regressiv	Chen & Guestrin (2016)	
Light Gradient Boosting Machines	LightGBM	Quantitativ	Machine Learning	Baumbasiert, Ensemble	Multivariat	Variiert	Ein Gradient-Boosting-Framework, das mithilfe histogrammbasierter Entscheidungsbäume bei großen Datensätzen besonders effizient und schnell arbeitet.	$\hat{y} = \sum_k f_k(x)$, k=1..K (histogram-based approach)	Baumbasiert, Ensemble, Regressiv	Ke et al. (2017)	
Artificial Neural Networks	ANN	Quantitativ	Machine Learning	Deep Learning	Multivariat	Variiert	Allgemeiner Begriff für neuronale Netze, die aus Schichten künstlicher Neuronen bestehen und beliebige nichtlineare Zusammenhänge approximieren können.	$\hat{y} = f(W_1 \dots f(W_2 \cdot f(W_1 \cdot x + b_1) + b_2) \dots + b_l)$	Deep Learning, Nichtlinear	Rumelhart et al. (1986); Goodfellow et al. (2016)	
Feedforward Network	FFN	Quantitativ	Machine Learning	Deep Learning	Multivariat	Variiert	Einfachste Form eines neuronalen Netzes, bei dem die Informationen nur in eine Richtung (vorwärts) durch die Schichten fließen, ohne Rückkopplung.	Ausgabe = $f(\dots (W_2 \cdot f(W_1 \cdot x + b_1) + b_2) \dots)$	Deep Learning, Schichtweise Vorwärts	Rumelhart et al. (1986); Goodfellow et al. (2016)	
Elman Netzwerk	ELMAN	Quantitativ	Machine Learning	Deep Learning	Multivariat	Variiert	Ein einfaches rekurrentes neuronales Netz mit einer Kontextschicht, die vergangene Zustände speichert und zeitliche Muster lernen kann.	$h(t) = f(W_{hx} \cdot x(t) + W_{hh} \cdot h(t-1))$, $y(t) = W_{yh} \cdot h(t)$	Deep Learning, Rekurrent	Elman (1990); Goodfellow et al. (2016)	
Long Short-Term Memory	LSTM	Quantitativ	Machine Learning	Deep Learning	Multivariat	Variiert (abhängig von den Input-Features)	Spezielle Form eines RNN mit internen Gate-Strukturen (Input, Forget, Output), um Langzeitabhängigkeiten in Zeitreihen zu lernen.	$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f)$, $i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i)$, ...	Deep Learning, RNN	Hochreiter & Schmidhuber (1997); Goodfellow et al. (2016)	
Gated Recurrent Unit	GRU	Quantitativ	Machine Learning	Deep Learning	Multivariat	Variiert (abhängig von den Input-Features)	Ähnlich wie LSTM, jedoch mit vereinfachter Gating-Struktur (Update- und Reset-Gate), um kontextabhängige Informationen effizient zu verarbeiten.	$z_t = \sigma(W_z \cdot [h_{t-1}, x_t])$, $r_t = \sigma(W_r \cdot [h_{t-1}, x_t])$, $h_t = (1 - z_t) \odot h_{t-1} + z_t \odot \tanh(W_h \cdot [r_t \odot h_{t-1}, x_t])$	Deep Learning, RNN	Cho et al. (2014); Goodfellow et al. (2016)	
Multilayer Perceptrons	MLP	Quantitativ	Machine Learning	Deep Learning	Multivariat	Variiert (abhängig von den Input-Features)	Einfache Form eines neuronalen Netzes mit mehreren verdeckten Schichten. Jede Schicht besteht aus linearen Transformationen und nichtlinearen Aktivierungsfunktionen.	$\hat{y} = f(\dots f(W_2 \cdot f(W_1 \cdot x + b_1) + b_2) \dots)$	Deep Learning, Feedforward	Rumelhart et al. (1986); Goodfellow et al. (2016)	
Entscheidungsbaum	DT	Quantitativ	Machine Learning	Baumbasiert	Multivariat	Variiert (abhängig von den Features)	Hierarchische Aufteilung der Daten basierend auf Entscheidungsregeln. Blätter enthalten Vorhersagewerte oder Klassen. Leicht interpretierbar, aber anfällig für Overfitting.	Keine geschlossene Formel; Baumstruktur mit if/then-Regeln	Baumbasiert, einfaches ML-Modell	Quinlan (1986); Breiman et al. (1984)	
Random Forest	RF	Quantitativ	Machine Learning	Baumbasiert, Ensemble	Multivariat	Variiert (abhängig von den Features)	Ensemble aus vielen Entscheidungsbäumen, die jeweils auf Bootstrap-Stichproben trainiert werden. Die Endvorhersage ist der Mittelwert (Regression) oder Mehrheitsentscheid (Klassifikation).	Keine einzelne Formel; Ensemble aus Entscheidungsbäumen	Baumbasiert, ensemble, ML	Breiman (2001)	
Recurrent Neural Network	RNN	Quantitativ	Machine Learning	Deep Learning	Multivariat	Variiert (abhängig von den Input-Features)	Verarbeitet sequentielle Daten, indem es Informationen über verdeckte Zustände (Hidden States) rückkoppelt. Eignet sich für Zeitreihen und Sprachverarbeitung.	$h_t = f(W_h \cdot [h_{t-1}, x_t] + b_h)$, $y_t = W_y \cdot h_t + b_y$	Deep Learning, rekurrent	Rumelhart et al. (1986); Elman (1990); Goodfellow et al. (2016)	

Prophet		Quantitativ	Machine Learning	Zeitreihenorientiert, semi-parametrisch	Univariat möglichen gressoren)	(mit 1 (Zeitreihe) + Re-exogene Faktoren (optional)	Additives Modell, das Trend, Saisonalität und Feiertagseffekte kombiniert. Automatische Hyperparameter-Schätzung und benutzerfreundliche Implementierung (Facebook Prophet).	$y(t) = g(t) + s(t) + h(t) + \varepsilon_t$	Additives Zeitreihenmodell (Trend + Saison + Feiertags- effekte)		Taylor (2018)	& Letham
----------------	--	-------------	------------------	---	--------------------------------	---	--	---	--	--	---------------	----------

Anhang 2: Literaturrecherche und Vergleich von Case Studies

Titel: The M4 Competition: Results, findings, conclusion and way forward
 Autoren: Spyros Makridakis a,b,* , Evangelos Spiliotis c, Vassilios Assimakopoulos c
 Jahr: 2018
 DOI: 10.1016/j.ijforecast.2018.06.001
 Link: <https://doi.org/10.1016/j.ijforecast.2018.06.001>
 Beschreibung: Ergebnisaufbereitung der M4 Forecasting competition
 Datenquellen: 100.000 reale Zeitreihen, 6 Domänen, unterschiedliche Frequenzen

Methode	sMAPE (%)	MASE	OWA
Naive Methode (Naïve2)	15,20 %	1,536	1
ARIMA	13,36 %	1,288	0,866
Exponentielle Glättung (ETS)	13,01 %	1,25	0,842
Theta-Methode	13,00 %	1,248	0,841
Kombination statistischer Methoden	12,89 %	1,236	0,834
Neuronale Netze (NN)	12,99 %	1,245	0,84
Hybrid ES-RNN (Smyls Methode)	11,374 %	1,128	0,778

Titel: The M5 Competition: Results, findings, and conclusions
 Autoren: Makridakis, S., Spiliotis, E., & Assimakopoulos, V.
 Jahr: 2022
 DOI: 10.1016/j.ijforecast.2021.11.013
 Link: <https://doi.org/10.1016/j.ijforecast.2021.11.013>
 Beschreibung: Absatzprognose im Einzelhandel
 Datenquellen: Verkaufsdaten von Walmart auf täglicher Basis über mehrere Jahre, einschließlich hierarchischer Informationen (Produkte, Läden, Kategorien)

Methode	WRMSSE
Prophet	0,568
Deep Learning Modelle mit LightGBM (N-BEATS)	0,538
LightGBM (Gradient Boosting Machines)	0,52
Naive Methode	1.752
Saisonale Naive Methode (sNaive)	0.847
Simple Exponential Smoothing (SES)	0.969
Gleitender Durchschnitt (MA)	0.956
Croston-Methode (CRO)	0.957
Optimierte Croston-Methode (optCRO)	0.958
Syntetos-Boylan Approximation (SBA)	0.957
Teunter-Syntetos-Babai (TSB)	0.961
Aggregated Demand Intermittency Analysis (ADIDA)	0.955
Intermittent Multiple Aggregation Prediction Algorithm (iMAPA)	0.960
Exponentielle Glättung Top-Down (Estd)	0.720
Exponentielle Glättung Bottom-Up (Esbu)	0.671
ARIMA Top-Down (ARIMAtd)	0.796
ARIMA Bottom-Up (ARIMAbu)	0.908
ARIMAX (mit exogenen Variablen)	0.691
Multilayer Perceptron (MLP)	0.977
Random Forest (RF)	1.010
Generalized MLP (gMLP)	0.961
Generalized RF (gRF)	1.065

Anhang 3: Eigene empirische Evaluation auf Basis univariater Beispieldaten

Modell	Langfristig 20 Wochen			Langfristig 10 Wochen			Kurzfristig 1 Woche		
	MSE	MAE	MAPE	MSE	MAE	MAPE	MSE	MAE	MAPE
Naive Prognose	88.50	7.50	26.24	87.70	6.90	21.94	576.00	24.00	70.59
Lineare Regression	69.51	7.00	22.84	82.91	7.55	21.40	82.65	9.09	26.74
Lineare Regression G	66.85	6.93	22.95	77.27	7.21	20.42	75.61	8.70	25.58
HW alpha=0.07	78.57	7.20	22.27	97.04	8.41	23.94	92.85	9.64	28.34
HW alpha=0.1 Beta=0.41	38.32	5.02	17.04	26.06	4.09	12.32	1.38	1.17	3.45
HW alpha=0.08 Beta=0.48 Gamma=0.35	55.94	6.37	22.67	48.68	5.44	15.83	0.97	0.99	2.90
HW alpha=0.12 G	61.76	6.49	21.10	69.12	6.85	19.45	59.08	7.69	22.61
HW alpha=0.01 Beta=0.45 G	40.65	5.46	20.15	26.67	4.13	12.78	1.60	1.26	3.72
HW alpha=0.06 Beta=0.35 Gamma=0.5 G	40.33	5.44	19.35	26.38	4.27	12.84	4.73	2.17	6.39
ARIMA(3,0,4)	151.16	10.26	30.94	191.93	12.71	37.28	258.12	15.91	46.79
ARIMA(2,0,1)	159.14	10.54	31.97	203.34	13.11	38.49	268.37	16.38	48.18
ARIMA(3,0,3) G	132.06	9.35	27.88	170.55	11.84	34.52	170.84	13.07	38.44
ARIMA(1,1,1)	113.33	8.52	25.36	147.80	10.78	31.09	167.80	12.95	38.10
ARIMA(3,3,5)	88.43	7.58	23.41	117.32	9.16	26.06	183.29	13.54	39.82
ARIMA(0,3,1)	3358.50	54.00	199.89	1371.21	35.89	114.76	361.67	19.02	55.93
ARIMA(0,0,1) G	356.66	17.52	56.62	439.83	20.23	61.15	367.76	19.18	56.40
ARIMA(1,1,0) G	164.82	10.81	32.73	212.23	13.51	39.83	202.09	14.22	41.81
SARIMA(0,1,2)(0,0,1)	145.63	10.07	30.48	191.78	12.71	37.27	280.93	16.76	49.30
SARIMA(1,1,0)(0,0,1)G	188.47	11.85	36.39	237.14	14.47	42.99	210.73	14.52	42.70
FFNN(10,10,1)	92.91	7.61	22.90	116.92	9.20	26.26	102.30	10.11	29.75
FFNN(10,10,1)G	67.92	6.60	20.86	81.68	7.35	20.76	63.64	7.98	23.46
FFNN(10,10,10,1)	85.64	7.37	22.48	106.87	8.78	25.10	99.63	9.98	29.36
FFNN(10,10,10,1) G	76.85	7.03	21.65	94.40	8.14	23.07	83.34	9.13	26.85
FFNN(10,10,10,10,1)	94.13	7.68	23.07	117.78	9.31	26.59	110.21	10.50	30.88
FFNN(10,10,10,10,1)G	71.57	6.71	20.86	87.61	7.62	21.47	67.94	8.24	24.24
FFNN(10,50,20,1)	71.07	6.81	21.70	86.96	7.67	21.92	71.50	8.46	24.87
FFNN(10,50,20,1)G	72.95	6.75	20.86	89.45	7.69	21.64	71.12	8.43	24.80
FFNN(10,10,20,1)	77.49	7.09	22.08	96.51	8.24	23.53	81.09	9.01	26.49
FFNN(10,10,20,1)G	63.67	6.51	21.08	75.23	7.02	19.89	53.80	7.34	21.57
RNN(10,R10,1)	94.26	7.66	24.12	119.52	8.83	25.42	97.05	9.85	28.98
RNN(10,R10,1)G	65.94	5.67	20.97	79.49	7.25	20.54	58.12	7.62	22.42
RNN(10,R10,R10,1)	116.32	8.94	26.94	129.98	10.51	30.95	117.00	10.82	31.81
RNN(10,R10,R10,1)G	171.57	11.15	45.03	68.16	7.56	24.11	26.20	5.12	15.06
RNN(10,R20,R10,1)	146.66	9.36	30.13	153.35	9.54	27.49	342.36	18.50	54.42
RNN(10,R20,R10,1)G	106.71	8.79	35.38	54.20	6.66	21.14	17.06	4.13	12.15
RNN(10,R30,1)	77.10	7.05	21.96	96.70	8.22	23.45	80.18	8.95	26.34
RNN(10,R30,1)G	60.20	6.58	22.38	68.94	6.66	19.09	38.87	6.23	18.34
LSTM(10,10,10,1)	174.24	11.11	34.02	195.92	12.25	35.22	199.34	14.12	41.53
LSTM(10,10,10,1)G	62.51	6.58	22.14	74.58	6.92	19.83	40.26	6.35	18.66
LSTM(10,10,10,10,1)	83.16	7.08	22.21	106.15	8.30	23.85	85.83	9.26	27.25
LSTM(10,10,10,10,1)G	60.02	6.59	22.51	67.96	6.61	18.96	38.23	6.18	18.19
GRU NN(10,G10,1)	128.10	9.44	29.66	151.30	10.27	29.58	136.10	11.67	34.31
GRU NN(10,G10,1)G	89.39	7.48	22.60	112.36	9.04	25.81	103.45	10.17	29.91
GRU NN(10,G10,10,1)	81.92	7.10	22.18	104.05	8.30	23.85	86.35	9.29	27.33
GRU NN(10,G10,G10,1)G	62.66	6.52	21.29	74.33	6.99	19.88	50.26	7.09	20.85

Modelle	Konstanter Absatz	Lineares Absatztrend			Nicht linearer Absatztrend			Gesättigtes Wachstum			Stabile Absatzwachstum mit Innovation			Sättelpunkt			Rapide Marktdurchdringung			Zyklischer Absatzverlauf			Saisonaler Absatzverlauf			Saisonale Absatzrufe			Zufälliger Absatzverlauf																																																																													
		5	4	3	2	1	0	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25	26	27	28	29	30	31	32	33	34	35	36	37	38	39	40	41	42	43	44	45	46	47	48	49	50	51	52	53	54	55	56	57	58	59	60	61	62	63	64	65	66	67	68	69	70	71	72	73	74	75	76	77	78	79	80	81	82	83	84	85	86	87	88	89	90	91	92	93	94	95	96	97	98	99
Konstanter Mittelwert Modell	5	4	3	2	1	0	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25	26	27	28	29	30	31	32	33	34	35	36	37	38	39	40	41	42	43	44	45	46	47	48	49	50	51	52	53	54	55	56	57	58	59	60	61	62	63	64	65	66	67	68	69	70	71	72	73	74	75	76	77	78	79	80	81	82	83	84	85	86	87	88	89	90	91	92	93	94	95	96	97	98	99	100
Linear Trend Modell	5	4	3	2	1	0	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25	26	27	28	29	30	31	32	33	34	35	36	37	38	39	40	41	42	43	44	45	46	47	48	49	50	51	52	53	54	55	56	57	58	59	60	61	62	63	64	65	66	67	68	69	70	71	72	73	74	75	76	77	78	79	80	81	82	83	84	85	86	87	88	89	90	91	92	93	94	95	96	97	98	99	100
Polynomialer Trend Modell	5	4	3	2	1	0	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25	26	27	28	29	30	31	32	33	34	35	36	37	38	39	40	41	42	43	44	45	46	47	48	49	50	51	52	53	54	55	56	57	58	59	60	61	62	63	64	65	66	67	68	69	70	71	72	73	74	75	76	77	78	79	80	81	82	83	84	85	86	87	88	89	90	91	92	93	94	95	96	97	98	99	100
Curvilinear Trend Modell	5	4	3	2	1	0	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25	26	27	28	29	30	31	32	33	34	35	36	37	38	39	40	41	42	43	44	45	46	47	48	49	50	51	52	53	54	55	56	57	58	59	60	61	62	63	64	65	66	67	68	69	70	71	72	73	74	75	76	77	78	79	80	81	82	83	84	85	86	87	88	89	90	91	92	93	94	95	96	97	98	99	100
Saisonales Komponentenmodell	5	4	3	2	1	0	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25	26	27	28	29	30	3																																																																					

Anhang 4: Übersicht über recherchierte Datenquellen

Datenquelle	Kategorie	Datenherkunft	Datenart	Geographie	min. Häufigkeit	Quelle Relevanz Literatur
Auftragsfortschritt / Offene Aufträge	Absatzdaten	intern	quantitativ	beliebig	täglich	Kim 2023
Historische Absatzdaten ähnliche Produkte	Absatzdaten	intern	quantitativ	beliebig	täglich	Schuh und Stich 2012 Tarallo et al 2019
Historische Absatzdaten Produkt	Absatzdaten	intern	quantitativ	beliebig	täglich	Schuh und Stich 2012 Tarallo et al 2019 Verstreate et al 2020
Experteneinschätzung	Experten	intern	hybrid	beliebig	sporadisch	J. K. Ord, R. Fildes, and N. Kourentzes, Principles of business forecasting, 2nd ed. New York, NY: Wessex Press Inc, 2017 Osadchiy et al 2013
Arbeitskostenindex	Konjunkturdaten	extern	quantitativ	national/ regional/global	monatsweise	Weichel und Herrmann 2016 (Indikatoren unkonkret) Mir et al 2021 (Materialpreis Prognose) Sagaert et al 2018a (genaue Indikatoren unklar) Lopez et al 2023 (Konjunktur unkonkret) Verstreate et al 2020
Arbeitslosenquote	Konjunkturdaten	extern	quantitativ	national/ regional/global	monatsweise	Weichel und Herrmann 2016 (Indikatoren unkonkret) Kim 2023 Mir et al 2021 (Materialpreis Prognose) Sagaert et al 2018a (genaue Indikatoren unklar) Shiha et al 2022 (Stahl- und Zementpreis Prognose) Lopez et al 2023 Sagaert et al 2018b Verstreate et al 2020
Auftragseingangsindex	Konjunkturdaten	extern	quantitativ	national/ regional/global	monatsweise	Weichel und Herrmann 2016 (Indikatoren unkonkret) Sagaert et al 2018a (genaue Indikatoren unklar) Lopez et al 2023 (Konjunktur unkonkret) Verstreate et al 2020
Baugenehmigungen	Konjunkturdaten	extern	quantitativ	national/ regional/global	monatsweise	Weichel und Herrmann 2016 (Indikatoren unkonkret) Kim 2023 Mir et al 2021 (Materialpreis Prognose) Sagaert et al 2018a (genaue Indikatoren unklar) Lopez et al 2023 (Konjunktur unkonkret) Verstreate et al 2020
Beschäftigte Baugewerbe	Konjunkturdaten	extern	quantitativ	national/ regional/global	monatsweise	Weichel und Herrmann 2016 (Indikatoren unkonkret) Mir et al 2021 (Materialpreis Prognose) Sagaert et al 2018a (genaue Indikatoren unklar) Lopez et al 2023 (Konjunktur unkonkret) Verstreate et al 2020
Beschäftigte Dienstleistungen	Konjunkturdaten	extern	quantitativ	national/ regional/global	monatsweise	Weichel und Herrmann 2016 (Indikatoren unkonkret) Sagaert et al 2018a (genaue Indikatoren unklar)

						Lopez et al 2023 (Konjunktur unkonkret) Verstreate et al 2020
Beschäftigte in der Industrie	Konjunkturdaten	extern	quantitativ	national/regiona l/global	monatsweise	Weichel und Herrmann 2016 (Indikatoren unkonkret) Sagaert et al 2018a (genaue Indikatoren unklar) Lopez et al 2023 (Konjunktur unkonkret) Verstreate et al 2020
Bruttoanlageinvestitionen	Konjunkturdaten	extern	quantitativ	national/regiona l/global	monatsweise	Weichel und Herrmann 2016 (Indikatoren unkonkret) Sagaert et al 2018a (genaue Indikatoren unklar) Lopez et al 2023 (Konjunktur unkonkret) Verstreate et al 2020
Bruttoinlandsprodukt	Konjunkturdaten	extern	quantitativ	national/regiona l/global	monatsweise	Kim 2023 Weichel und Herrmann 2016 (Indikatoren unkonkret) Mir et al 2021 (Materialpreis Prognose) Sagaert et al 2018a (genaue Indikatoren unklar) Shiha et al 2022 (Stahl- und Zementpreis Prognose) Lopez et al 2023 (Konjunktur unkonkret) Verstreate et al 2020
Erzeugerpreisindex	Konjunkturdaten	extern	quantitativ	national/regiona l/global	monatsweise	Weichel und Herrmann 2016 (Indikatoren unkonkret) Mir et al 2021 (Materialpreis Prognose) Sagaert et al 2018a (genaue Indikatoren unklar) Shiha et al 2022 (Stahl- und Zementpreis Prognose) Lopez et al 2023 (Konjunktur unkonkret) Verstreate et al 2020
Exporte	Konjunkturdaten	extern	quantitativ	national/regiona l/global	monatsweise	Weichel und Herrmann 2016 (Indikatoren unkonkret) Kim 2023 Sagaert et al 2018a (genaue Indikatoren unklar) Shiha et al 2022 (Stahl- und Zementpreis Prognose) Lopez et al 2023 (Konjunktur unkonkret) Verstreate et al 2020
Förder- und Subventionsausgaben je Wirtschaftsbereich	Konjunkturdaten	extern	quantitativ	national/regiona l/global	monatsweise	Im weitesten Sinne Quelle Konjunkturindikatoren??? Schnelle Keyword Recherche hat keine Ergebnisse aus der Literatur gebracht
Geschäftserwartungsindex Deutschland	Konjunkturdaten	extern	quantitativ	national	monatsweise	Weichel und Herrmann 2016 (Indikatoren unkonkret)
Geschäftsclimaindex Deutschland	Konjunkturdaten	extern	quantitativ	national	monatsweise	Weichel und Herrmann 2016 (Indikatoren unkonkret) Fritsch et al 2017 Lopez et al 2023 Verstreate et al 2020
Importe	Konjunkturdaten	extern	quantitativ	national/regiona l/global	monatsweise	Weichel und Herrmann 2016 (Indikatoren unkonkret) Kim 2023 Sagaert et al 2018a (genaue Indikatoren unklar) Lopez et al 2023 (Konjunktur unkonkret) Verstreate et al 2020

Konsumklimaindex	Konjunkturdaten	extern	quantitativ	national/region/global	monatsweise	Kim 2023 Sagaert et al 2018a (genaue Indikatoren unklar) Lopez et al 2023 (Konjunktur unkonkret) Verstreate et al 2020
Leitzinsen Wichtig Zentralbank des Marktlandes (EZB, BoE, FED, BoJ, ...)	Konjunkturdaten	extern	quantitativ	national/region/global	monatsweise	Shiha et al 2022 (Stahl- und Zementpreis Prognose) Lopez et al 2023 Kim 2023 Sagaert et al 2018a (genaue Indikatoren unklar) Weichel und Herrmann 2016 (Indikatoren unkonkret) Lopez et al 2023 (Konjunktur unkonkret) Verstreate et al 2020
Population	Konjunkturdaten	extern	quantitativ	national/region/global	jährlich	Kim 2023 Sagaert et al 2018a (genaue Indikatoren unklar) Weichel und Herrmann 2016 (Indikatoren unkonkret) Lopez et al 2023 (Konjunktur unkonkret) Verstreate et al 2020
Private Konsumausgaben	Konjunkturdaten	extern	quantitativ	national/region/global	monatsweise	Weichel und Herrmann 2016 (Indikatoren unkonkret) Sagaert et al 2018a (genaue Indikatoren unklar) Lopez et al 2023 (Konjunktur unkonkret) Verstreate et al 2020
Purchasing Manager Index	Konjunkturdaten	extern	quantitativ	national/region/global	monatsweise	Weichel und Herrmann 2016 (Indikatoren unkonkret) Wand und Gu 2022 Sagaert et al 2018a (genaue Indikatoren unklar) Lopez et al 2023 (Konjunktur unkonkret) Verstreate et al 2020
Umsätze Baugewerbe	Konjunkturdaten	extern	quantitativ	national/region/global	monatsweise	Weichel und Herrmann 2016 (Indikatoren unkonkret) Kim 2023 Sagaert et al 2018a (genaue Indikatoren unklar) Lopez et al 2023 (Konjunktur unkonkret) Verstreate et al 2020
Umsätze Dienstleistungen	Konjunkturdaten	extern	quantitativ	national/region/global	monatsweise	Weichel und Herrmann 2016 (Indikatoren unkonkret) Sagaert et al 2018a (genaue Indikatoren unklar) Lopez et al 2023 (Konjunktur unkonkret) Verstreate et al 2020
Umsätze Industrie	Konjunkturdaten	extern	quantitativ	national/region/global	monatsweise	Weichel und Herrmann 2016 (Indikatoren unkonkret) Sagaert et al 2018a (genaue Indikatoren unklar) Lopez et al 2023 (Konjunktur unkonkret) Verstreate et al 2020
Verbraucherpreisindex	Konjunkturdaten	extern	quantitativ	national/region/global	monatsweise	Weichel und Herrmann 2016 (Indikatoren unkonkret) Mir et al 2021 (Materialpreis Prognose) Kim 2023 Sagaert et al 2018a (genaue Indikatoren unklar) Shiha et al 2022 (Stahl- und Zementpreis Prognose)

						Lopez et al 2023 (Konjunktur unkonkret) Sagaert et al 2018b Verstreate et al 2020
Verfügbares Einkommen	Konjunkturdaten	extern	quantitativ	national/region/global	monatsweise	Kim 2023 Mir et al 2021 (Materialpreis Prognose) Sagaert et al 2018a (genaue Indikatoren unklar) Weichel und Herrmann 2016 (Indikatoren unkonkret) Lopez et al 2023 (Konjunktur unkonkret) Verstreate et al 2020
Zinsstruktur (Kurz gegen Langfristige Zinsen) Wichtig Zentralbank des Marktlandes (EZB, BoE, FED, BoJ, ...)	Konjunkturdaten	extern	quantitativ	national/region/global	monatsweise	Shiha et al 2022 (Stahl- und Zementpreis Prognose) Lopez et al 2023
Marktumfrage	Kundenmeinung	intern	hybrid	beliebig	sporadisch	Weichel und Herrmann 2016
Sentimentanalyse (Reviews, Kommentare, Social Media -> Textmining)	Kundenmeinung	extern	qualitativ	beliebig	täglich	Weichel und Herrmann 2016 Kim 2023
(Website) Traffic	Kundenverhalten	intern	quantitativ	beliebig	täglich	Saura et al 2017 Weichel und Herrmann 2016 -> Marketing nicht näher spezifiziert Assmus et al 1984 (allgemeine Wichtigkeit Marketing on Sales) Kim 2023
Clickstream/Webpfad bzw. Flow-of-Users	Kundenverhalten	extern	quantitativ	beliebig	täglich	Huang und Mieghem 2014 Saura et al 2017
Kundennotizen und Interaktionen CRM Könnte man das ggf. in die Sentimentanalyse fassen?	Kundenverhalten	intern	qualitativ	beliebig	sporadisch	keine Quelle
Kundenumfragen	Kundenverhalten	intern	hybrid	beliebig	sporadisch	J. K. Ord, R. Fildes, and N. Kourentzes, Principles of business forecasting, 2nd ed. New York, NY: Wessex Press Inc, 2017 Saura et al 2017
Suchmaschinendaten ProSuma Projekt - nicht nur Produkt selbst sondern auch Kontext Suchen sinnvoll	Kundenverhalten	extern	quantitativ	beliebig	täglich	Kim 2023 Saura et al 2017 Choi und Varian 2012 Fritzsche et al 2017
Type of Sources (Art woher die User/Kunden herkommen)	Kundenverhalten	intern	qualitativ	beliebig	täglich	Saura et al 2017 Weichel und Herrmann 2016 -> Marketing nicht näher spezifiziert Assmus et al 1984 (allgemeine Wichtigkeit Marketing on Sales)
Type of Users (Art der Nutzer/Kunden - Neu/Bestand, Kaufkraft, ...)	Kundenverhalten	intern	qualitativ	beliebig	täglich	Saura et al 2017 Weichel und Herrmann 2016 -> Marketing nicht näher spezifiziert Assmus et al 1984 (allgemeine Wichtigkeit Marketing on Sales)
Click-Through-Rate	Marketing	intern	quantitativ	beliebig	täglich	Saura et al 2017 Weichel und Herrmann 2016 -> Marketing nicht näher spezifiziert Assmus et al 1984 (allgemeine Wichtigkeit Marketing on Sales)

Goals Conversion Rate (Konvertierungsrate auf Zielgröße/Bestellung)	Marketing	intern	quantitativ	beliebig	täglich	Saura et al 2017 Weichel und Herrmann 2016 -> Marketing nicht näher spezifiziert Assmus et al 1984 (allgemeine Wichtigkeit Marketing on Sales)
Impressionen	Marketing	intern	quantitativ	beliebig	täglich	Saura et al 2017 (Weichel und Herrmann 2016 -> Marketing nicht näher spezifiziert) Assmus et al 1984 (allgemeine Wichtigkeit Marketing on Sales)
Lead (Potentieller Kunde mit Kontaktdata)	Marketing	intern	quantitativ	beliebig	täglich	Saura et al 2017 (Weichel und Herrmann 2016 -> Marketing nicht näher spezifiziert) Assmus et al 1984 (allgemeine Wichtigkeit Marketing on Sales)
Marketingstrategie search marketing (SEO or SEM), social media marketing, affiliate marketing or content marketing	Marketing	intern	qualitativ	beliebig	täglich	Fildes et al 2022 Weichel und Herrmann 2016 -> Marketing nicht näher spezifiziert Assmus et al 1984 (allgemeine Wichtigkeit Marketing on Sales)
Marketingumsätze je Strategie	Marketing	intern	quantitativ	beliebig	täglich	Fildes et al 2022 Weichel und Herrmann 2016 -> Marketing nicht näher spezifiziert Assmus et al 1984 (allgemeine Wichtigkeit Marketing on Sales) Kim 2023
Produktpreis	Marketing	intern	quantitativ	beliebig	täglich	Kim 2023 Fildes et al 2022 Weichel und Herrmann 2016 -> Marketing nicht näher spezifiziert Assmus et al 1984 (allgemeine Wichtigkeit Marketing on Sales) Lopes et al 2023
Rabatte	Marketing	intern	quantitativ	beliebig	täglich	Fildes et al 2022 Weichel und Herrmann 2016 -> Marketing nicht näher spezifiziert Assmus et al 1984 (allgemeine Wichtigkeit Marketing on Sales)
Return on Investment	Marketing	intern	quantitativ	beliebig	täglich	Saura et al 2017 Weichel und Herrmann 2016 -> Marketing nicht näher spezifiziert Assmus et al 1984 (allgemeine Wichtigkeit Marketing on Sales)