

DISPO 4.0 - Simulationsgestützte Absatzprognoseoptimierung in der Investitionsgüterindustrie

Alexander Schmid^{1*,2}, Felix Kamhuber¹, Thomas Sobottka^{1,2}, Wilfried Sihn¹

¹Fraunhofer Austria Research GmbH, Theresianumgasse 7, 1040 Vienna, Austria; *alexander.schmid@fraunhofer.at

²TU Wien, Institute of Management Science, Theresianumgasse 27, 1040 Vienna, Austria

Abstract. This paper presents a demand forecasting approach that automatically selects optimal article specific forecasting methods and optimizes the method parameters, using deterministic simulation and a *Genetic Algorithm* (GA). For an efficient demand forecast, choosing the best forecasting method based on the item-specific historical requirements time series is key. The optimization of the forecast parameters is also crucial for efficient demand planning. Both decisions lack digital method support, leading to suboptimal forecasts in practice and thus inefficient material requirements planning. This paper investigates the optimization potential of an automatically optimizing forecasting approach, featuring a simulation-based comparison of six standard forecasting methods, evaluated using a case-study from the capital goods industry. The methodological core of the optimization is a GA, which improves the underlying, method-specific forecast parameters. The simulation-based optimization provides a rolling-horizon demand forecast for each item, and is determined through the application of a rule-based heuristic. The results show a significant improvement potential through this form of efficient item-specific demand planning.

Einleitung

„Daten und Informationen sind das Öl des digitalen Zeitalters“ [1] und Algorithmen sind der Schlüssel für eine effiziente Verwertung großer Datenmengen [1]. Dies betrifft insbesondere auch die Materialdisposition, die sich in einem volatilen, globalen Marktumfeld mit steigender Komplexität [2] und zunehmender Menge an Informationen und Daten [3] konfrontiert sieht. Disruptionen durch Digitalisierung, kleinere Losgrößen, schwankende Absatzmengen, globalisierte Supply Chains sowie Kostendruck sind wesentliche Komplexitätstreiber in der

Materialdisposition [4]. Materialdisposition umfasst das Koordinieren der Materialeingänge in das Unternehmen und des Lagerbestands, so dass die richtigen Artikel zeitgerecht sowie ortsgerecht in der richtigen Qualität vorhanden sind [5]. Das Themengebiet Materialdisposition gliedert sich in die Bedarfs-, Bestands- sowie Bestellrechnung [5], siehe *Abbildung 1*. Um in einem Umfeld, ständiger Schwankungen, einen Wettbewerbsvorteil erzielen zu können, müssen Unternehmen rechtzeitig Entscheidungen auf genauer Datengrundlage treffen können. Richtige Entscheidungen basieren dabei auf genauen Bedarfsprognosen [6]. Jedes Teilgebiet der Materialdisposition kann durch digitalisierte Prozesse, mit Nutzung optimierender Algorithmen, große Ersparnisse erzielen [7].



Abbildung 1: Teildisziplinen der Materialdisposition

Dieses Paper befasst sich mit der Bedarfsrechnung und speziell mit der Anwendung von Prognosealgorithmen in der verbrauchsgesteuerten Materialdisposition der Investitionsgüterindustrie. Wobei sich diese Arbeit auf Zeitreihenmodelle bezieht, die den quantitativen Prognosemethoden zugeordnet werden [8]. Zeitreihenanalysen basieren immer auf historischen Daten. Dabei wird die historische Nachfrage eines Artikels analysiert, um die zukünftige Nachfrage vorhersagen zu können [8].

Bei der verbrauchsgesteuerten Bedarfsrechnung bilden die Materialverbrauchsdaten der Vergangenheit die Grundlage, um mit Hilfe von Prognosealgorithmen die zukünftigen Bedarfe zu ermitteln [9]. Hierbei wird dann von einer kundenanonymen Absatzplanung gesprochen

[10]. Dabei geht es bei der Bedarfsrechnung darum, unter Berücksichtigung aller verfügbaren Informationen und der vorhandenen historischen Daten, die zukünftigen Bedarfe so genau wie möglich vorherzusagen [11]. Heute existieren in der verbrauchsgesteuerten Materialdisposition vielfältige Verfahren und komplexe Logiken, um die Materialdisposition effizienter zu gestalten. Im betrieblichen Alltag findet jedoch zumeist nur ein sehr geringer Anteil mathematischer Modelle Anwendung, da anwendungsbereite Methoden zur Auswahl und fallspezifischen Parametrierung fehlen [12]. Prognosesysteme erfordern die Entwicklung von Fachwissen über die Ermittlung von Prognoseproblemen, die Anwendung einer Reihe von Prognosemethoden, die Auswahl geeigneter Methoden für jedes Problem und die Bewertung und Verfeinerung von Prognosemethoden im Laufe der Zeit [11]. Die Anwendbarkeit von Prognoseverfahren hängt von den Eigenschaften der zu prognostizierenden Zeitreihen, den Eigenschaften der Prognoseverfahren, vom Verwendungszweck der Prognosen ab [2]. Durch Digitalisierung und Automatisierung eines Prognosesystems kann eine artikelgenaue Materialbedarfsplanung und Ersatzteilbevorratung generiert werden. Genaue Bedarfsvorhersagen führen in der verbrauchsgesteuerten Materialdisposition zu einer Erhöhung der Versorgungssicherheit, zur Reduktion von Lagerbeständen, Lagerhaltungs- und Kapitalbindungskosten sowie zu Verminderung von Verschrottungskosten [12]. Fehlmengen und daraus resultierende Gewinneinbußen lassen sich ebenfalls reduzieren und die Kundenbindung kann durch verbesserte Kundenzufriedenheit gesichert werden [2]. Dieser Anwendungsbeitrag stellt die Entwicklung einer digitalen Planungsmethode vor, die eine artikelspezifisch optimierte Bedarfsrechnung in der verbrauchsgesteuerten Materialdisposition ermöglicht. Dabei werden mittels statischer Simulation und einer regelbasierten Heuristik als Bewertungskriterium artikelspezifisch möglichst optimale Prognoseverfahren ausgewählt und diese automatisiert mittels *Genetischem Algorithmus* (GA) parametrisiert. Das Nutzenpotenzial einer Anwendung von quantitativen Prognosemethoden in der verbrauchsgesteuerten Materialdisposition zur teilautomatisierten Bedarfsrechnung wird in einer Fallstudie evaluiert.

1 Zielsetzung

Zielsetzung dieses Beitrags ist es, mit der entwickelten Methode die artikelgenaue Bedarfsplanung von

verbrauchsgesteuert disponierten Artikeln zu generieren und zu automatisieren. Dabei gilt es, Fachwissen über Prognoseprobleme zur Auswahl einer geeigneten Prognosemethode sowie die Parametrisierung und Optimierung der Prognosemethoden zu berücksichtigen.

Die Forschungshypothese ist, dass die Entwicklung und der Einsatz einer digitalen Planungsmethode der verbrauchsgesteuerten Materialdisposition, mit statischer Simulation und einer regelbasierten Heuristik sowie einer Optimierung von Prognoseparametern mittels GA, unter Nutzung von State-of-the-art Verfahren der Prognoserechnung, eine artikelgenaue Materialbedarfsplanung in Unternehmen der Investitionsgüterindustrie deutlich verbessern kann.

2 Grundlagen Bedarfsermittlung

In einer Literaturanalyse wurden zunächst eine Übersicht der verfügbaren Prognoseverfahren ermittelt, die Algorithmen charakterisiert und die Einsatzmöglichkeiten im betrieblichen Umfeld der Investitionsgüterindustrie evaluiert. Die Analyse der Prognosealgorithmen wurde auf Zeitreihenmodelle der stochastischen Bedarfsrechnung eingeschränkt. Die Literaturanalyse zeigt auf, dass bei den Verfahren der *Exponentiellen* (Exp.) *Glättung* oft keine Unterscheidung hinsichtlich der Unterkategorien gemacht wird, obwohl andere Berechnungsalgorithmen dahinter liegen. **Abbildung 2** zeigt das Ergebnis der ermittelten Verfahren. Die dunkelgrau markierten Verfahren wurden nach einer Häufigkeitsanalyse in der Literatur als die gebräuchlichsten Verfahren ausgewählt und in der entwickelten Planungsmethode berücksichtigt. Diese sechs Algorithmen finden teilweise schon Anwendung in ERP (*Enterprise Resource Planning*)-Systemen. Jedoch fehlt VerantwortungsträgerInnen in den Unternehmen eine Entscheidungsgrundlage, welche der Prognoseverfahren für des Unternehmen die geeignetsten und wie diese optimal und artikelspezifisch zu parametrisieren sind. Die Eignung eines Prognoseverfahrens für einen konkreten Anwendungsfall kann anhand der artikelspezifischen Zeitreihe der historischen Absatzzahlen (Bedarfscharakteristik) eingeschätzt werden [10]. Zeitreihen aus den historischen Absatzzahlen können eine Vielzahl von artikelspezifischen Mustern aufweisen. Daher ist es hilfreich eine Zeitreihe in mehrere Komponenten zu unterteilen, die jeweils eine zugrunde liegende Musterkategorie (Trend, Saisonalität etc.) erfasst [11].

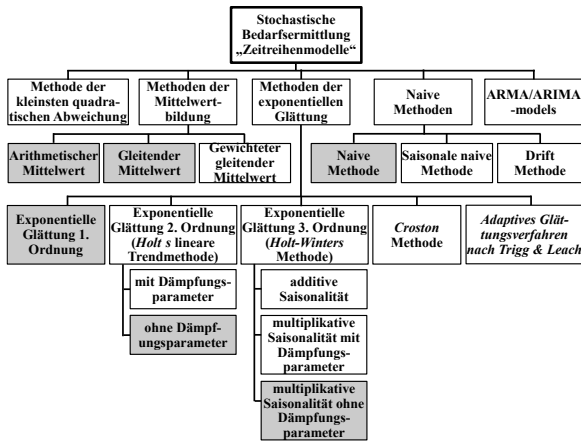


Abbildung 2: Übersicht Zeitreihenmodelle

Zeitreihentypen werden wie in **Abbildung 3** ersichtlich kategorisiert. Schwanken die Vergangenheitswerte um einen Durchschnittswert, nennt man diesen Bedarfsverlauf konstant. Der trendförmige Verlauf zeichnet sich durch einen stetig steigenden oder fallenden Bedarf mit zufälligen Schwankungen um diesen aus und der saisonale Bedarf erscheint regelmäßig in Perioden und schwankt auch stochastisch um den Durchschnittswert [10]. Der sporadische Bedarfsverlauf schwankt ohne erkennbare Regularität [13].




Abbildung 3: Zeitreihen historischer Absatzzahlen (Eigendarstellung in Anlehnung an: [13,14])

Laut Literaturrecherche gibt es keine gemeingültige Zuordnung, die artikelspezifischen Zeitreihen geeignete Prognosealgorithmen eindeutig zuordnet, siehe **Abbildung 4**. Um in der Anwendungspraxis das bestgeeignete Verfahren artikelspezifisch effizient auswählen zu können und dabei auch auf Veränderungen der Bedarfscharakteristik im Zeitverlauf dynamisch reagieren zu können, wird die hierin vorgestellte Methode entwickelt.

Prognosealgorithmen	Zeitreihen historischer Absatzzahlen					
	konstant	trendförmig (linear)	trendförmig (progressiv)	saisonal	trendförmig saisonal	sporadisch
Arithmetischer Mittelwert	●					
Gleitender Mittelwert	●					
Gewogener gleitender Mittelwert	●	○				○
Exponentielle Glättung 1. Ordnung	●					○
Exponentielle Glättung 2. Ordnung (gedämpft)	●	●				
Exponentielle Glättung 2. Ordnung (ungedämpft)	●	●	●			
Exponentielle Glättung 3. Ordnung (additiv)	●	●	○	●		
Exponentielle Glättung 3. Ordnung (multiplikativ gedämpft)	●	●	○	●	●	
Exponentielle Glättung 3. Ordnung (multiplikativ ungedämpft)	●	●	○	●	●	
Croston-Methode						●
Adaptives Glättungsverfahren nach Trigg & Leach		○				●
ARIMA Modell	●	●	●	●	●	○

Legende: ● geeignet ○ bedingt geeignet

Abbildung 4: Zusammenhang Zeitreihen – Prognosealgorithmen (Eigendarstellung in Anlehnung an: [15,13,10,16])

3 Charakterisierung der Fallstudie

Die Fallstudie wurde anhand eines Unternehmens der Investitionsgüterindustrie betrachtet, welches die Ersatzteildisposition verbrauchsgesteuert abwickelt. Reale Ersatzteilverbräuche der vergangenen 36 Monate und weitere relevanten Unternehmensdaten wurden betrachtet. Von den identifizierten 17.600 aktiven Ersatzteilarikeln mit Absatzzahlen, wurden nur jene Artikel für die Fallstudie herangezogen, die im Betrachtungszeitraum (-36 Monate) zumindest in 24 der 36 Monate Ersatzteilabsätze aufwiesen. Daraus resultieren für die Betrachtung dieser Arbeit 2.002 unterschiedliche Ersatzteilarikel.

Das betrachtete mittelständische Unternehmen wird der Branche der Fahrzeugindustrie zugeordnet. Mit ca. 240 Mitarbeitern erwirtschaftet das Unternehmen einen Jahresumsatz von ca. 89 Mio. € mit 38.800 Kunden aus 22 Ländern. Das jährliche Einkaufsvolumen von ca. 59 Mio. € wird mit 1.260 aktiven Lieferanten aus 28 Ländern umgesetzt. Als zentrales IT-System wird *Infor M3* verwendet. Die Input-Daten werden aus den IT-Systemen des Unternehmens via Schnittstelle eingelesen.

4 Digitale Planungsmethode

In der vorliegenden Arbeit wird ein auf MS (*Microsoft*)-Excel und VBA (*Visual Basic for Applications*) basierende digitale Planungsmethode für eine optimierte Bedarfsrechnung der verbrauchsgesteuerten Materialdisposition in der Investitionsgüterindustrie entwickelt. Mit

dieser Methode soll das Prognostizieren zukünftiger artikelspezifischer Bedarfe von den Erfahrungen einzelner gelöst, bewährte Verfahrensweisen allgemein nutzbar gemacht und die Nachvollziehbarkeit von Entscheidungen bis auf Articlebene auf Basis eines Simulationsmodells erleichtert werden. **Abbildung 5** zeigt den Ablauf des digitalen Planungsmethode im Überblick.

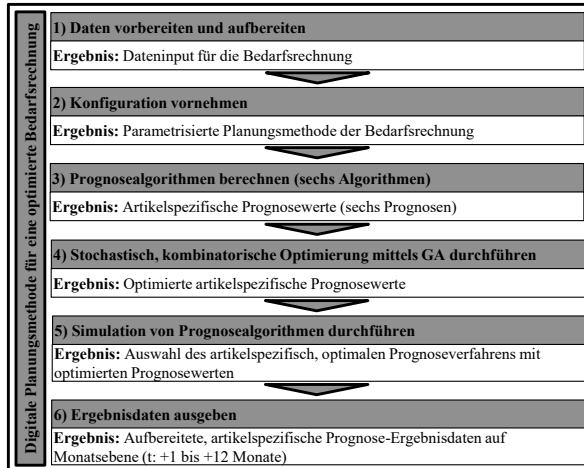


Abbildung 5: Schrittfolge der digitalen Planungsmethode

Die Planungsmethode umfasst sechs Arbeitsschritte, wobei die Rechenzeit v.a. in Schritt vier anfällt. Bis auf diesen werden alle anderen Arbeitsschritte, je nach Umfang des Datensatzes (bis zu ~1 Mio. Artikel), ohne relevanten Zeitverzug ausgeführt.

Die Modellierung der Planungsmethode zielt auf eine möglichst hohe Prognosequalität ab. Dabei sollen sich ändernde Marktbedingungen berücksichtigt werden. Zielsetzung ist eine zukünftige Digitalisierung bzw. Automatisierung der Bedarfsrechnung in der verbrauchsgesteuerten Materialdisposition.

Der methodische Kern der Optimierung ist ein GA, der die jeweils zugrundeliegenden, methodenspezifischen Prognoseparameter im Zuge von Schritt vier optimiert wählt. Die simulationsgestützte Optimierung liefert für jede der sechs Methoden eine rollierende Absatzprognose auf Monatsbasis für die mittlere Zukunft sowie den sich daraus in Summe ergebenden Prognosefehler, je betrachteten Artikel. Durch Anwendung einer regelbasierten Heuristik wird das für den Artikel optimale mathematische Prognosemodell ausgewählt. Das Bewertungskriterium ist der, in Bezug auf den Referenzzeitraum, geringste Prognosefehler. Für diese Arbeit wird konkret der *Mean Squared Error* (MSE) herangezogen.

4.1 Daten vorbereiten und aufbereiten

Die in dieser Arbeit angewendeten Verfahren zur Bedarfsermittlung (siehe **Abbildung 2**) unterstellen einen Zusammenhang zwischen dem Verbrauch in der Vergangenheit und dem Bedarf in zukünftigen Perioden. Die Grundlage der stochastischen Bedarfsermittlung bilden effektive Verbrauchsdaten aus der Vergangenheit [9]. Der erste Schritt ist die Aufbereitung und Formatierung der Daten. Dieser Prozess beinhaltet einen standardisierten Bezug historischer Datensätze, das Erkennen fehlender Werte, das Filtern der artikelspezifischen Zeitreihen sowie weitere Vorverarbeitungsaufgaben [11]. Dabei werden unterschiedliche Datenquellen aus dem ERP-System eingespielt und automatisiert aufbereitet. Folgend werden artikelspezifische, tagesaktuelle Verbrauchswerte zu Monatsabsätzen aggregiert.

4.2 Konfiguration vornehmen

Dieser zweite Arbeitsschritt bestimmt die Parametrisierung und Start-Konfiguration der einzelnen Algorithmen und berücksichtigt dabei die Einstellung der folgenden prognose- und optimierungsrelevanten Parameter:

- Überdeckung: Prognosewert in Periode $x >$ Absatzhistorie in Periode x
- Unterdeckung: Prognosewert in Periode $x <$ Absatzhistorie in Periode x
- Einstellung der Startwerte bei den Prognoseparametern α , β und γ : 0,3; 0,5; 0,5
- Einstellung der Grenzwerte je Methode als Nebenbedingung für die anschließende Prognoseparameteroptimierung mittels GA
- Maximale Optimierungs-Laufzeit: drei [s]

Für das Verhältnis von Unter- zu Überdeckung wird für alle Prognosemethoden 2:1 festgelegt. Unterdeckung ist also, aufgrund der negativen Effekte (Pönalen, entgehendes Geschäft), entsprechend stärker gewichtet als Überdeckung. Umfangreiche Datentests haben zur Einstellung der genannten Startwerte für die Prognoseparameter geführt. Folgende weitere Parameter werden gesetzt:

- Anzahl Perioden Absatzhistorie: -36 Perioden
- Anzahl Prognoseperioden: +12 Perioden

Ein längerer Prognosehorizont ist in den meisten Fällen nicht sinnvoll, da veraltete Daten nicht mehr aussagekräftig sind und ein zu langer Prognosezeitraum die

Planungsqualität verringert. In einem separaten Arbeitsblatt je Prognosemethode werden die Monatsabsätze je Artikel als Basis für die folgenden Schritte gespeichert.

4.3 Prognosealgorithmen berechnen

Im Zuge der Berechnung bzw. Optimierung des Prognosefehlers, in diesem Fall der Prognosefehler MSE , wird für alle sechs Verfahren artikelweise die Absatzhistorie in die Berechnung übernommen. Für jeden Artikel, für den eine Absatzhistorie vorliegt, werden die folgenden formalisierte sechs Prognoseverfahren berechnet und das artikelspezifische Prognoseergebnis sowie der entsprechende Prognosefehler im Arbeitsblatt je Methode gespeichert.

Die **Naive Methode**, oder *Random Walk*, ist die einfachste Methode der stochastischen Bedarfsermittlung [9]. Aber auch einfache Verfahren können sich als effektiv erweisen, falls die Absatzhistorie ein für die komplexeren Verfahren nicht erkennbares Muster aufweist [11]. Bei der *Naiven Methode* ergeben sich die zukünftigen Prognosewerte direkt aus den Vorperioden-Werten.

Der **Arithmetische Mittelwert** ist die einfachste Form der Berechnung aus den drei Methoden der Mittelwertbildung. Mit diesem Prognosealgorithmus lassen sich konstante Bedarfsverläufe ohne Trend darstellen [17]. Durch die stetige Erhöhung der in die Mittelwertberechnung miteinbezogenen Werte sinkt der Einfluss der aktuellen Perioden immer weiter, was einen entscheidenden Nachteil dieser Methode darstellt [18].

Der **Gleitende Mittelwert** bezieht sich im Gegensatz zum *Arithmetischen Mittelwert* nur auf die letzten m aktuellen Perioden und verwirft die älteren Aufzeichnungen, um besser auf den aktuellen Bedarfsschwankungen reagieren zu können [18]. Alle m Werte sind gleich gewichtet wie auch beim *Arithmetischen Mittelwert*. Je nachdem, wie viele Perioden für die Berechnung verwendet werden, reagiert der Prognosewert träger oder sensibler. Bei einer hohen Anzahl an betrachteten Perioden reagiert der *Gleitende Mittelwert* nur langsam auf Veränderungen und bei einer geringen Anzahl reagiert er hingegen äußerst sensibel [13].

Die **Exponentielle Glättung 1. Ordnung**, auch *Exponential Smoothing* und *Brown's Model* benannt [19], ist ähnlich den Methoden der Mittelwertbildung. Jedoch wird zusätzlich der Fehler der vergangenen Periode mit einem Glättungsfaktor α multipliziert. Der Fehler der vergangenen Periode ergibt sich durch die Differenz von dem tatsächlich eingetretenen Wert der Vorperioden

X_t mit dem geschätzten Prognosewert X_t^* derselben Periode. Der Glättungsfaktor kann alle Werte zwischen 0 und 1 annehmen, wobei ein hoher Glättungsfaktor die aktuellen Daten höher wertet, als die alten Daten [17]. Basierend auf einer Trendbildung wird bei der *Exp. Glättung 1. Ordnung* die Absatzhistorie der jüngeren Vergangenheit charakteristisch höher gewichtet, siehe **Abbildung 6**. Das Risiko des Verfahrens besteht darin, dass dem Trend verzögert nachgelaufen wird, während sich dieser evtl. bereits abbaut.

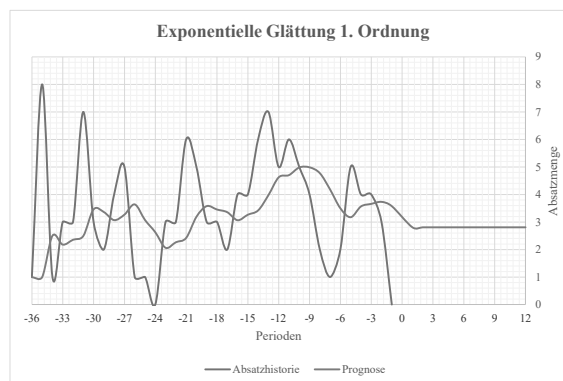


Abbildung 6: Absatzhistorie und Prognose (*Exp. Glättung 1. Ordnung* - Artikel 455 Scheibenwaschbehälter)

Die **Exponentielle Glättung 2. Ordnung** wurde von *Holt* durch Erweiterung der *Exp. Glättung 1. Ordnung* entwickelt, um Daten mit einem Trendverlauf prognostizieren zu können. Den Glättungsparameter α kann man mit dem der *Exp. Glättung 1. Ordnung* gleich setzen, aber der Trend-Glättungsparameter β legt die Steigung fest. Die beiden Glättungsparameter sind unabhängig voneinander und auch β muss einen Wert zwischen 0 und 1 annehmen. Wenn $\beta = 0$ gesetzt wird, ergibt sich die *Exp. Glättung 1. Ordnung* [10]. Durch die nochmalige Glättung der Vorhersagewerte der *Exp. Glättung 1. Ordnung* über sogenannte Trendkorrekturwerte reagiert die *Exp. Glättung 2. Ordnung* je nach α entsprechend schneller auf Trendänderungen. **Abbildung 7** zeigt exemplarisch die rasche (und angesichts der Historie notwendige) Anpassung der Prognose dieser Methode bei $\alpha = 0,40$.

Die **Exponentielle Glättung 3. Ordnung**, auch *Holt-Winter* Methode ist eine Erweiterung der *Exp. Glättung 2. Ordnung*, um auch die saisonale Abhängigkeit von Daten erfassen zu können. Sie kann additive oder multiplikative Saisonalität einbeziehen [20]. Das Verfahren von *Holt-Winter*, berücksichtigt zusätzlich zum Trend einen (multiplikativen) Saison-Anteil in der Prognose.




Abbildung 7: Absatzhistorie und Prognose (*Exp. Glättung 2. Ordnung* – Artikel 1181 Set: Heugabel, Schaufel, Stallbesen)

Dieser Anteil berücksichtigt das Verhalten der vergangenen Saison je nach Parametrierung entsprechend stark, siehe **Abbildung 8**. Zu beachten ist, dass die klassischen additiven und multiplikativen *Holt-Winters*-Methoden unzuverlässig werden können, wenn das Rauschen der historischen Zeitreihe die Trend-Komponente β und Saisonale-Komponente γ dominiert [20].

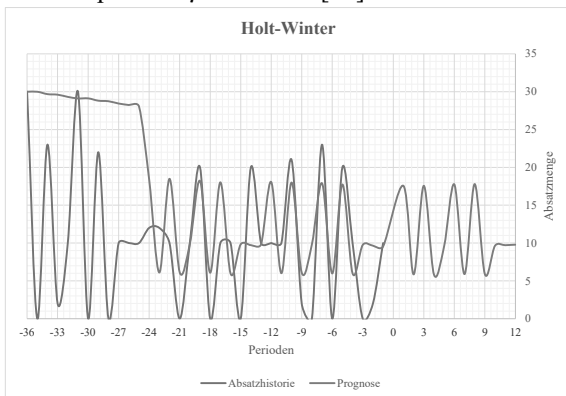


Abbildung 8: Absatzhistorie und Prognose (*Holt-Winter* – Artikel 3 Klemmschelle mit Schraube)

4.4 Optimierung mittels GA durchführen

Bei den Methoden der *Exp. Glättung* handelt es sich um weit verbreitete und vielfach genutzte Verfahren zur Erstellung von Prognosen, indem ein instationärer Prozess abgebildet wird. Dabei erhalten aktuelle Beobachtungen eine höhere Gewichtung als die älteren Beobachtungen. Die Gewichtung der früheren Beobachtungen nimmt exponentiell ab [2], [21]. Die Grundformel der *Exp. Glättung* lautet: Neue Vorhersage = Alte Vorhersage + (Glättungsfaktor x Prognosefehler). Die richtige Wahl des Glättungsfaktors spielt daher bei den Verfahren der *Exp.*

Glättung eine entscheidende Rolle. In der Praxis haben sich folgende Werte bewährt [10]:

- $0,05 \leq \alpha \leq 0,3$ für annähernd konstanten Verlauf
- $0,3 \leq \alpha \leq 0,5$ für stark schwankenden Bedarfsverlauf
- $\alpha \geq 0,5$ nicht empfehlenswert

Die Randwerte der Prognoseparameter bei den anderen *Exp. Glättungsverfahren* liegen für α , β und γ im Intervall [0;1]. Die Startlösung basiert auf den Optimierungsergebnisse eines Datensatzes (> 17.000 Artikel) und wird für $\alpha = 0,2$; $\beta = 0,5$; $\gamma = 0,5$ initialisiert.

Die Optimierung der (1 bzw. 3) Prognoseparameter erfolgt für die drei Verfahren der *Exp. Glättung* (1. bis 3. Ordnung). Die anderen drei Methoden verfügen über keine zu optimierenden Prognoseparameter. Für die Parameteroptimierung wird der *GA* von MS-Excel genutzt, der über einen *VBA*-Code aufgerufen wird. Darin erfolgt die Übergabe der Zielfunktion mit Minimierung des Prognosefehlers, der Variablenzellen und der Nebenbedingungen, inklusive der dazugehörigen Einstellungen für den Algorithmus, z.B. der Laufzeit/Abbruchkriterien. Die **Abbildung 9** zeigt exemplarisch die Verteilung der Optimierungsparameter (Glättungs-Komponente α , die Trend-Komponente β und Saisonale-Komponente γ) der 506 Artikel der Methode *Exp. Glättung 3. Ordnung*, die in diesem Fallbeispiel Anwendung finden.

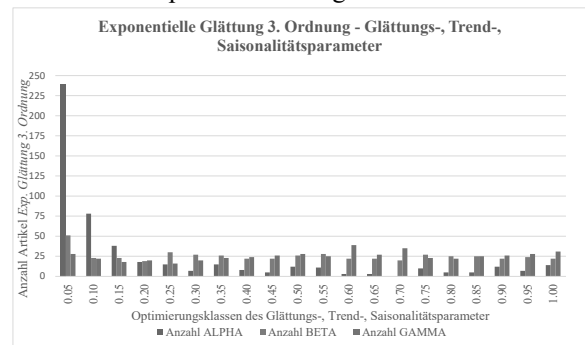


Abbildung 9: *Exp. Glättung 3. Ordnung* - Ergebnis der Parametertoptimierung von Alpha, Beta und Gamma [0,00-1,00]

4.5 Simulation von Prognosealgorithmen

Ein wichtiger Punkt ist die Prognosequalität, welche die mit der entsprechenden Methode berechneten Prognosewerte mit den tatsächlich eingetretenen historischen Verbrauchswerten vergleicht, um somit auf eine Aussagekraft über die jeweilige Prognosegüte schließen zu können [22]. Aus den möglichen Prognosefehlern wurde der *MSE* im Rahmen dieser Arbeit zur Bewertung

herangezogen, da durch Quadrieren jene Werte mit größeren Prognoseabweichung eine stärkere Gewichtung bekommen [23]. Ermittelt wird der MSE wie folgt [10]:

$$MSE = \frac{1}{n} * \sum_{t=1}^n (y_t - \hat{y}_{t+h|t})^2 \quad (1)$$

$\hat{y}_{t+h|t}$ Prognosewert für die Periode t

y_t Realer Bedarfswert

n Anzahl der Stichproben des Periodenverlaufs

Im Zuge der Simulation werden pro Artikel die sechs Prognoseverfahren verglichen und die Methode mit dem geringsten Prognosefehler *MSE* für den konkreten Artikel als geeignetste Prognosemethode ausgewählt. **Tabelle 1** stellt eine Übersicht der entsprechend pro Artikel zur Anwendung gewählten Verfahren für den Datensatz dar. Die am häufigsten selektierten Verfahren sind die Verfahren der *Exp. Glättung 1. bis 3. Ordnung*.

Implementierte Prognosealgorithmen	# Artikel	%-Anteil
<i>Arithmetischer Mittelwert</i>	174	8,7 %
<i>Exponentielle Glättung 1. Ordnung</i>	404	20,2 %
<i>Exponentielle Glättung 2. Ordnung ohne Dämpfungsparemeter</i>	743	37,1 %
<i>Exponentielle Glättung 3. Ordnung multiplikative Saisonalität ohne Dämpfungsparemeter</i>	506	25,3 %
<i>Gleitender Mittelwert</i>	48	2,4 %
<i>Naive Methode</i>	118	5,9 %
Nicht prognostizierbar	9	0,4 %
Summe	2.002	100,0%

Tabelle 1: Ergebnisdaten

Das Optimierungspotential des jeweiligen Prognosefehlers beträgt anhand einer Auswertung für den Datensatz aus der Fallstudie im Mittel 32%. Der Wert ist groß, in Anbetracht des Umstands, dass nur drei von sechs Verfahren die Prognoseparameter optimieren. Die drei parameteroptimierten Verfahren werden für 82,6% der Artikel empfohlen. Die detaillierte Auswertung der Optimierungsergebnisse ergibt, dass der Prognosefehler mittels der Prognoseparameter optimierten Methoden wie folgt ggü. der jeweiligen Startlösung reduziert werden konnte:

- *Exp. Glättung 1. Ordnung*: 28,1%
- *Exp. Glättung 2. Ordnung*: 39,6%
- *Holt-Winter-Methode*: 45,6%

Trotz des nicht vorhandenen Optimierungspotentials bei den Methoden *Arithmetischer Mittelwert* und *Gleitender Mittelwert* sowie der *Naiven Methode* wird eine dieser Methoden lt. **Tabelle 1** in ~17% aller Fälle zur Anwendung als Prognosemethode empfohlen. Dies trifft v.a. auf Artikel zu, die keinem Trend bzw. keiner Saisonalität unterliegen. Der Unterschied im Prognosefehler beträgt zwischen der besten und schlechtesten Methode 72,8%. Die Wahl des „richtigen“ Verfahrens für einen bestimmten Artikel zur Prognose ist demnach wirkungsvoll. Der Unterschied zwischen der aktuell zur Prognose angewendeten *Naiven Methode* und der aus der Optimierung resultierenden Prognosemethode beträgt 68,5%.

4.6 Ergebnisdaten ausgeben

Am Ende erfolgt eine, an die Fallstudie angepasste, artikelspezifische Ausgabe der Optimierungsergebnisse. Diese beinhalten insbesondere die Absatzprognose der jeweils geeignetsten Prognosemethode sowie den dazugehörigen Prognosefehler *MSE*. Die ergänzende Prognosefehler *Mean Absolute Deviation*, *Mean Absolute Percentage Error* sowie die Standardabweichung der Prognose werden für eine weiterführende Bestandsrechnung [24] ebenfalls je Artikel berechnet. Außerdem werden die Ergebnisse mit den artikelspezifischen, dispositiven Daten verknüpft und zur weiteren Verwendung ausgegeben.

5 Diskussion

Die zentrale Schlussfolgerung ist, dass die Parameteroptimierung einen signifikanten Einfluss auf die Güte der Absatzplanung hat, weil der Prognosefehler im Mittel um 32% reduziert werden konnte. Die Differenz zwischen der *Naiven Methode* und der durch die Optimierung als geeignetste ermittelte Methode, inklusive Parameteroptimierung, beträgt 68,5%. Die Simulation ermöglicht je Artikel einen Vergleich mehrerer Verfahren und identifiziert je Artikel das bestgeeignete Verfahren. Die Herausforderung für die Materialdisposition besteht darin, für viele zu prognostizierende Artikel das jeweils bestgeeignete Verfahren mit der dazugehörigen Parametrisierung zu wählen. Das vorgestellte digitale Planungsmethode automatisiert diese beiden Entscheidungsfindungsprozesse. Die Auswertung der meistgewählten Verfahren zeigt: Der *Gleitende Mittelwert* wird selten gewählt, da die Verfahren der *Exp. Glättung 1. bis 2. Ordnung* mit optimierten Prognoseparametern deutlich überlegen sind. Die Verfahren mit integrierter Parameteroptimierung

sind in der Fallstudie den einfacheren Verfahren insgesamt überlegen. Das große Optimierungspotential der Methode von *Holt-Winter* (45,6%) lässt sich mit der Parametrisierung der Startlösung erklären, die einer realistischen pauschalen Parametrierung in der Praxis entspricht. Es ist wesentlich schwieriger, eine gute Startlösung für einen Artikel mit drei Prognoseparametern zu ermitteln als für Verfahren mit einem bzw. keinem Prognoseparameter. Die Durchführung der Absatzplanung lediglich mit einer Planungsmethode, wie in der Praxis häufig genutzt, resultiert in suboptimaler Planungsqualität. Dies lässt sich mit der in diesem Beitrag vorgestellten digitalen Planungsmethode für die Investitionsgüterindustrie in Zukunft optimieren. Im Ausblick ist zum einen eine Analyse weiterer Anwendungsfälle zu sehen, um ggf. allgemeingültige Muster der Zuordnung zu erkennen. Zum anderen kann die Möglichkeit untersucht werden, auch über die bislang genutzten Standard-Prognoseverfahren hinaus, intelligente Prognosemethoden zu entwickeln, bspw. Verfahren des *Machine-Learning* nutzend. Forschungsziel ist die Entwicklung einer integrierten, übergreifenden Methode (umfasst Bedarfs-, Bestands- und Bestellrechnung), und damit das Überwinden der sequenziellen Planung der drei Teilplanungen.

Danksagung

Diese Forschung wurde von der Österreichischen Forschungsförderungsgesellschaft (FFG), Förderungsnummer 872787, finanziert. Die Autoren danken den Fallstudienpartnern für ihren Beitrag.

Literatur

- [1] Barton, T., Müller, C., et al., 2018. Digitalisierung in Unternehmen. Springer Fachmedien, Wiesbaden.
- [2] Claus, T., Herrmann, F., et al., 2015. Produktionsplanung und -steuerung: Methoden und deren Anwendungen. Springer, Berlin, Heidelberg.
- [3] Bienhaus, F., Haddud, A., 2018. Procurement 4.0: factors influencing the digitisation of procurement and supply chains. BPMJ 24 (No. 4), S. 965–984.
- [4] Arnolds, H., Heege, F., et al., 2016. Materialwirtschaft und Einkauf. Springer Fachmedien, Wiesbaden.
- [5] Jacob, M., 2013. Management und Informationstechnik: Eine kompakte Darstellung. Springer, Wiesbaden.
- [6] Kolade, O.J. Demand Forecasting and Measuring Forecast Accuracy in a Pharmacy, in: OECONOMICA, AU-DOE, Vol. 15, No. 3/2019, S. 157–169.
- [7] Heiserich, O.-E., Helbig, K., et al., 2011. Logistik: Eine praxisorientierte Einführung, 4. Aufl. Gabler, Wiesbaden.
- [8] Gasparian, M.S., Karmanov, M.V., et al., Modeling of the demand forecasting, in: International Journal of Civil Engineering (IJCIET), Vol. 9, Issue 12, 2018, S. 163–173.
- [9] Pfohl, H.-C., 2018. Logistiksysteme. Springer, Berlin, Heidelberg.
- [10] Schuh, G., Schmidt, C., 2014. Produktionsmanagement. Springer, Berlin, Heidelberg.
- [11] Hyndman, R.J., Athanasopoulos, G., 2021. Forecasting: Principles and Practice: A comprehensive introduction to the latest forecasting methods using R. Learn to improve your forecast accuracy using dozens of real data examples., 3rd edition ed. OTexts, Melbourne (Australia).
- [12] Wischmann, S., Hartmann, E.A. 2018. Zukunft der Arbeit: Eine praxisnahe Betrachtung. Springer, Berlin, Heidelberg.
- [13] Schönsleben, P., 2020. Integrales Logistikmanagement: Operations und Supply Chain Management innerhalb des Unternehmens und unternehmensübergreifend, 8. Aufl. ed. Springer, Berlin, Zürich.
- [14] Waters, D., 2008. Inventory Control and Management. John Wiley & Sons Ltd, West Sussex.
- [15] Lasch, R., 2021. Strategisches und operatives Logistikmanagement: Beschaffung, 3. Aufl. Springer Gabler, Wiesbaden.
- [16] Wannenwetsch, H., 2014. Integrierte Materialwirtschaft, Logistik und Beschaffung, 5. Aufl. Springer, Berlin, Heidelberg.
- [17] Magerhans, A., 2016. Marktforschung: Eine praxisorientierte Einführung. Springer Gabler, Wiesbaden.
- [18] Koether, R., 2018. Distributionslogistik: Effiziente Absicherung der Lieferfähigkeit, 3. Aufl. Springer Gabler, Wiesbaden.
- [19] Babai, M.Z., Tsadiras, A., et al., 2020. On the empirical performance of some new neural network methods for forecasting intermittent demand. Journal of Management Mathematics (IMA) 31 (No. 3), S. 281–305.
- [20] Ferbar Tratar, L., Mojškerc, B., et al., 2016. Demand forecasting with four-parameter exponential smoothing. International Journal of Production Economics 181, S. 162–173.
- [21] Speckenbach, J., 2017. Prognose sporadischer Nachfrage: Ein Vergleich. Josef Eul Verlag GmbH, Ingolstadt, Lohmar - Köln.
- [22] Kellner, F., Lienland, B., et al., 2018. Produktionswirtschaft: Planung, Steuerung und Industrie 4.0. Springer Gabler, Berlin, Heidelberg.
- [23] Feindt, M., Kerzel, U., 2015. Prognosen bewerten: Statistische Grundlagen und praktische Tipps. Springer Gabler, Berlin, Heidelberg.
- [24] Schmid, A., Sobottka, T., et al., DISPO 4.0 | Digitalization Of Inventory Calculation In Consumption-Based Material Requirements Planning In The Capital Goods Industry, in: Conference on Production Systems and Logistics, 3rd Conference CPSL 2022, Vancouver, 17.-20. May 2022.