

Predictive Forecasting in volatilen Zeiten

Predictive Analytics als Ausgangsbasis für automatisierte Forecasts



Dr. **Leonhard Brinster** ist Head of Finance & Risk Advanced Analytics der BearingPoint GmbH in Frankfurt am Main. E-Mail: info@leonhard-brinster.de



Dr. **Frank Tiefenbeck** ist Partner des CFO-Bereichs der BearingPoint GmbH in Frankfurt am Main.



Philipp Stiehl, M. Sc., ist Senior Business Analyst im Bereich Advanced Analytics Finance & Risk der BearingPoint GmbH in Frankfurt am Main.

Neue Analytics-Lösungen wie die *SAP Analytics Cloud (SAC)* ermöglichen einen einfacheren Zugang zu statistischen Prognosemodellen. In diesem Artikel vergleichen wir die Prognosegüte von *SAP SAC* mit statistischen Machine-Learning-Algorithmen in *R* auf Basis von Umsatzdaten der DAX40-Unternehmen über den Zeitraum von 2010 bis 2022. Wir stellen fest, dass für das Forecasting in volatilen Zeiten die Verwendung von geeigneten Prognosemodellen ein erfolgsentscheidender Faktor ist.

Leonhard Brinster, Frank Tiefenbeck, Philipp Stiehl und Tobias Contala

1. Predictive Analytics für das Forecasting

Die Pandemiejahre und Post-Pandemie-Phase waren bzw. sind geprägt von hoher Unsicherheit und Volatilität. Bereits vorhandene Probleme bei Lieferketten wurden offensichtlich und teilweise noch weiter verstärkt. Als schließlich die Unsicherheiten durch die Eindämmung von COVID-19 abnahmen, verstärkte der Russisch-Ukrainische Krieg die Spannungen in der Welt wieder. Rasant steigende Energie- und Lebensmittelpreise waren die Folge, die Inflation und Zinsanhebungen schafften neue ökonomische Voraussetzungen.

Die Auswirkungen fehlender Planungssicherheit durch volatile Umweltzustände können weitreichend sein. Bei der Finanzplanung und Unternehmenssteuerung kann beispielsweise eine hohe Volatilität durch externe Umweltfaktoren die zielgerichtete und effiziente Entscheidungsfindung erschweren (vgl. *Wu et al., 2022*). Dies führt dazu, dass der bisherige Planungs- und Budgetierungsprozess oftmals nicht mehr den Anforderungen einer volatilen Umwelt genügt und Anpassungen an die veränderten Rahmenbedingungen notwendig sind (vgl. *Blackburn et al., 2015*). Auswirkungen ergeben sich hierbei auch für den Forecast als Steuerungsinstrument. Um mögliche Änderungen der Umweltzustände zu frühzeitig zu erkennen und darauf reagieren zu können, ist ein kontinuierlicher Forecast ein wichtiger Bestandteil in volatilen Zeiten (vgl. *Henttu-Aho, 2018*). Aufgrund des damit steigenden Ressourcenaufwandes, sollte deshalb auf neue Predictive-Analytics-Methoden zu-

rückgegriffen werden, welche die Ausgangsbasis für einen automatisierten Forecast bilden.

Aktuell basieren Prognosen in Unternehmen noch regelmäßig auf deskriptiven Methoden wie z. B. Treiberbäume, die wertmäßige Zusammenhänge zwischen Kennzahlen darstellen (vgl. *Rieg, 2021*). Die tatsächliche Prädiktion der Kennzahlen erfolgt – nachdem die notwendigen historischen Daten gesammelt wurden – meist auf Grundlage von expertenbasierten Schätzungen. Neben steuerungsrelevanten Kennzahlen können auch andere interne und externe Geschäftstreiber berücksichtigt werden. Dies ist jedoch mit Nachteilen verbunden, da einzelne Treiber erst identifiziert und wiederum geschätzt werden müssen (siehe **Abb. 1**). In einer volatilen Unternehmensumwelt eignen sich solche Ansätze allerdings nur bedingt. So wusste zur Anfangszeit der COVID-19-Pandemie im Jahr 2020 niemand, wie lange der wirtschaftliche Abschwung anhalten und welche Auswirkungen damit einhergehen würden. Daher ist es in diesen Zeiten umso schwieriger, die aktuelle Entwicklung objektiv zu beurteilen, und umso wichtiger, flexibel reagierende Prognosemodelle zu verwenden.

Die weiterentwickelten Forecastingansätze sind prädiktiv. Solche prädiktiven Prognoseansätze beruhen auf statistischen und mathematischen Modellen wie zum Beispiel „single exponential smoothing“ (SES), „autoregressive integrated moving average“ (ARIMA) oder komplexeren Machine-Learning-Ansätzen (ML-Modelle) und lassen sich grundsätzlich in univariate und multivariate Modelle unterscheiden. Rein univariate Modelle mo-

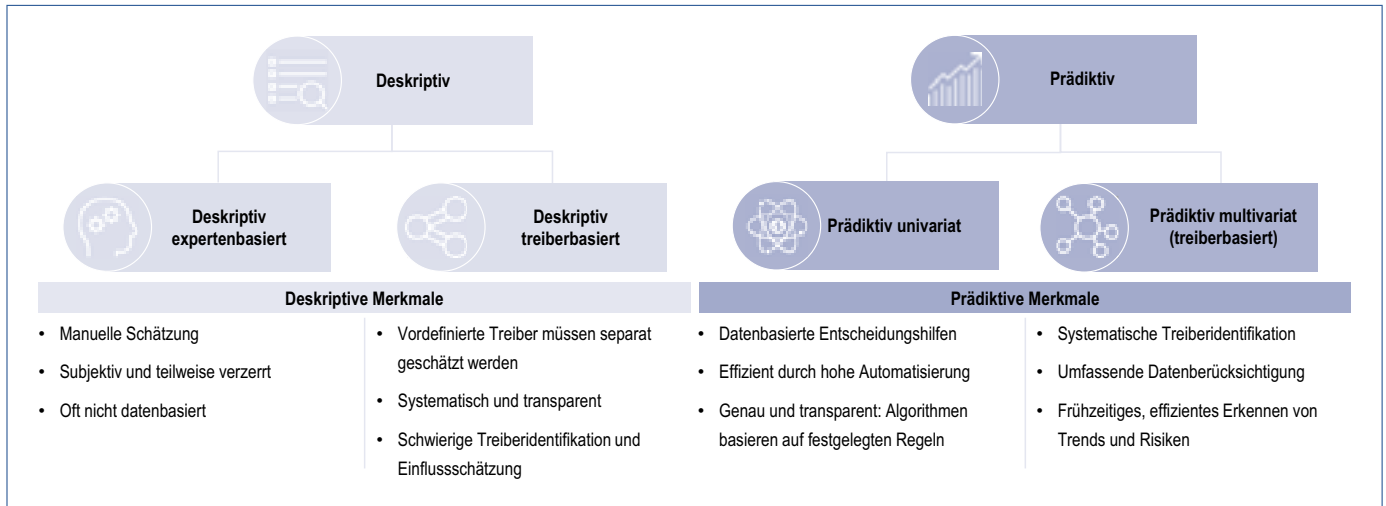


Abb. 1: Unterschied zwischen deskriptiven und prädiktiven Schätzungen

dellieren die abhängige Zielvariable (Prognosewert) anhand einer unabhängigen Variablen und erstellen daraus die zukünftige Prognose (vgl. Januschowski et al., 2019). Solche Modelle können dabei auch weit über eine reine Trendfortschreibung hinausgehen und beispielsweise versteckte Muster (Saisonalitäten) entdecken und für die Prognose berücksichtigen. Bei multivariaten Modellen werden mehrere erklärende Faktoren berücksichtigt, die Einfluss auf die Zielvariable nehmen können. In Bezug auf den Umsatz (Zielvariable) könnten dies etwa die gesamtwirtschaftliche Entwicklung und die Inflationsrate sein.

Viele Unternehmen in Deutschland nutzen Softwarelösungen von SAP, um Unternehmensprozesse in einer ERP-Landschaft abzubilden. So hat SAP mit der Analytics Cloud (SAC) ein mittlerweile häufig genutztes Tool auf den Markt gebracht, welches die Unternehmensplanung erleichtern soll. Auch für den Forecast kann auf SAC zurückgegriffen werden. Ein Vorteil dabei ist, dass SAC als sogenannte „No-Code“-Lösung angeboten wird, wodurch eine hohe Anwenderfreundlichkeit gewährleistet werden soll, da keine Programmiererfahrungen notwendig sind. Ein Nachteil, welcher damit einhergeht, ist allerdings, dass der Funktionsumfang für die Prädiktionsmodelle eingeschränkt ist. Beispielsweise ist die manuelle Anpassbarkeit von Parametern und die Auswahl an unterschiedlichen prädiktiven Modellen begrenzt. Da die Auswahl eines ML-Modells allerdings abhängig von der zugrundeliegenden Zeitreihe und der Skalierung der Daten ist, ist jedoch eine individuelle Anpassbarkeit der Modelle unabdingbar (vgl. Ge et al., 2017).


Abhilfe kann dabei eine eigenständige Entwicklung der Prognosemodelle schaffen. In den Datenwissenschaften sind Python und R hierfür gängige Programmiersprachen. Da es mittels einer implementierten Schnittstelle möglich ist, sich in R erstellte Analysen auch innerhalb der SAC-Applikation ausgeben lassen zu können, ist mit Hinblick auf die Unternehmenspraxis ein Vergleich beider

Ansätze von Interesse. Aufgrund der beschriebenen Limitationen von SAC entsteht die Erwartung, dass die Prognosemodelle mittels R ein genaueres Ergebnis liefern.

Ziel dieses Beitrags ist es demnach unterschiedliche Zeitreihenmodelle in R auf ihre Vorhersagefähigkeiten zu prüfen und die Ergebnisse anhand der Prognosegenauigkeit zwischen R und SAC zu vergleichen. Grundlage hierfür sind Umsatzdaten von Unternehmen aus dem DAX40 im Zeitraum von 2010 bis 2022. Des Weiteren wird – vor dem Hintergrund von volatilen Umweltzuständen – der Unterschied der Prognosegenauigkeit vor und nach Beginn der COVID-Pandemie zwischen R und SAC zu vergleichen. Eine Belastbarkeit des Vergleichs ergibt sich aus dem Umstand, dass nur univariate Zeitreihen-Modelle miteinander verglichen werden.

2. Systemlandschaft für Predictive Forecasting

Der Weg zur Nutzung statistischer Modelle für Forecasts umfasst mehrere Schritte. Neben der Wahl geeigneter Modelle gehören dazu auch die Auswahl und Beschaffung der zu nutzenden Daten. Diese Daten befinden sich in der Regel in ERP-Lösungen (z. B. in SAP S/4HANA) und bilden die Grundlage einer datengetriebenen Systemlandschaft (vgl. Wu et al., 2007). Eine Erweiterung der Datenbasis bilden zunehmend auch externe Daten. Solche externen Daten – beispielsweise makroökonomische Datenbanken – beinhalten Informationen über aktuelle Markteinflussfaktoren und können dementsprechend als Treiber für einzelne Kennzahlen berücksichtigt werden.



Tobias Contala, B. Sc., ist Praktikant im Bereich Advanced Analytics Finance & Risk der BearingPoint GmbH in Frankfurt am Main.

Eine Erweiterung der Datenbasis in ERP-Lösungen, wie z. B. S/4HANA, bilden zunehmend auch externe makroökonomische Daten.

Zentrale Aussagen

- Die Güte von Forecasts hängt unter anderem von ausgewählten Prognosemodellen ab.
- In Bezug auf die Glaubhaftigkeit der Prognose müssen ausgewählte Modelle und Einstellungen transparent dargelegt werden.

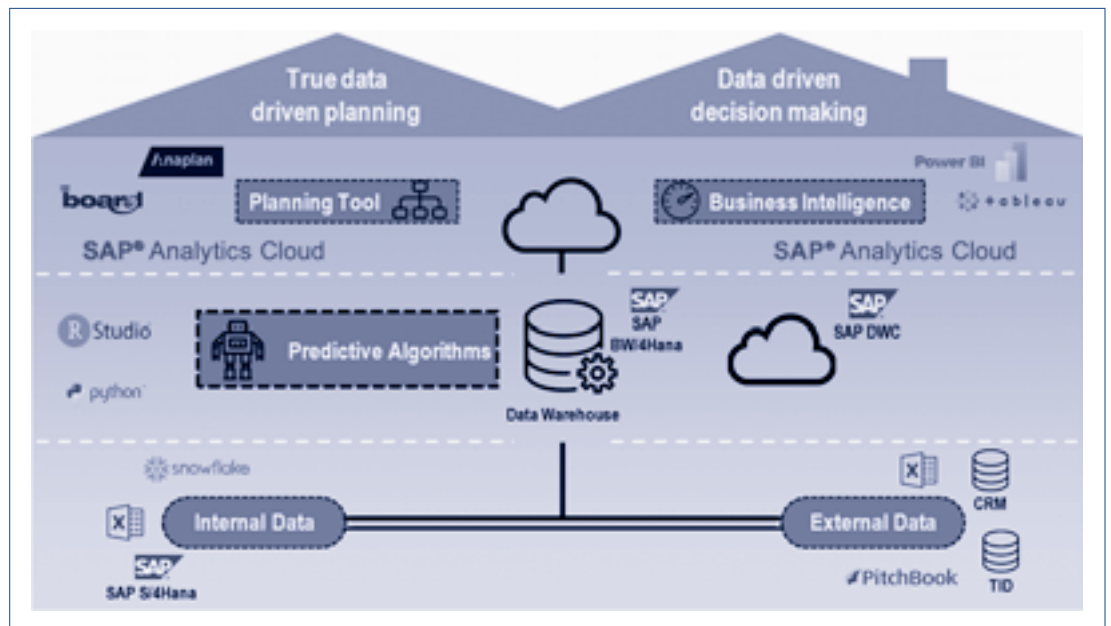


Abb. 2: Predictive Forecasting – Vorgeschlagene Architektur für Predictive Analytics mit R

Da interne und externe Daten in Unternehmen zumeist in einer unstrukturierten Art vorliegen, müssen diese in einem zweiten Schritt durch sog. ETL-Prozesse („extract“, „transform“ und „load“) in eine einheitliche Struktur gebracht werden. Die für den Forecast verwendeten Daten besitzen zum Beispiel unterschiedliche Dateiformate (xlsx, xml, etc.) und sollten demnach von einem Quellformat in ein Zielformat überführt werden. Des Weiteren müssen Daten oftmals erst aus unterschiedlichen Systemen konsolidiert werden. Die bereinigten Daten können anschließend in einem Data Warehouse (DW) gespeichert werden (siehe Abb. 2).

Innerhalb der Planungsfunktion von SAC bietet SAP die Möglichkeit via „Live Connection“ auf unterschiedliche interne und externe Datenquellen direkt zugreifen zu können. Für eine eigenentwickelte Predictive-Lösung empfiehlt es sich jedoch ein DW als „single source of truth“ einzusetzen. SAP bietet hierzu aktuell zwei Lösungen an: zum einen das SAP BW/4HANA als On-Premise-Lösung und zum anderen SAP DWC als Cloud-Lösung. Beide Lösungen stellen eine Datenbank dar, die einem bestimmten Datenbankschema („Star-Schema“) folgt und auf die darauffolgenden Analyse Zwecke abgestimmt ist (vgl. Mukherjee/Kar, 2017). Die Daten des DW können im Anschluss für die prädiktiven Algorithmen in R verwendet werden, um Prognosewerte zu generieren. Diese Prognosewerte können wiederum in das DW zurückgeführt werden und im Anschluss mit Hilfe einer gängigen Business Intelligence-Lösung (BI) in Form eines visuell aufbereiteten Dashboards angezeigt werden. SAC als BI- und Planungs-Tool bietet hierbei auch die Möglichkeit, sich in R erstellte Prognosen anzeigen lassen zu können. Dies ermöglicht es, SAC an individuelle Prognosebedürfnisse anzupassen.

3. Ein Vergleich der Genauigkeit von R und SAC

Datengrundlage und Training der Modelle

Unsere Analyse beruht auf Daten der Gewinn- und Verlustrechnung von Unternehmen aus dem DAX40 (Stand: Oktober 2022). Dies ermöglicht einen Vergleich der Zeitreihenmodelle für unterschiedliche Branchen, um branchen- bzw. zeitreihenabhängige Einflussfaktoren wie z. B. Saisonalität ebenfalls berücksichtigen zu können. Für die Ergebnisse konzentrieren wir uns auf den Prognoseunterschied zwischen R und SAC pro Unternehmen. Wir beziehen die Werte von PitchBook Data. Die Stichprobe enthält die Umsätze für alle Quartale der Periode Q1 2010 bis Q1 2022, umfasst insgesamt also 49 Quartale (Beobachtungen). Für die selbsterstellten Prognosemodelle bedienen wir uns des Pakets *fable* in R, da es eine Sammlung der meistgenutzten Zeitreihenmodelle beinhaltet. So ist es mit Hilfe der `model()`-Funktion des *fable-tools*-Pakets möglich, zwölf unterschiedliche univariate ML-Prognosemodelle zu nutzen (ARIMA, ETS, MEAN, RW, NAIVE, SNAIVE, THETA, CROSTON, AR, VAR, NNETAR, und TSLM).

Aufgrund der Verwendung von ML-Modellen, bereiten wir die Daten in einem ersten Schritt so auf, dass wir eine Kreuzvalidierung (engl.: cross-validation) durchführen können. Dabei wird das Prognosemodell auf Basis des Trainingsdatensatzes geschätzt und anschließend auf Basis des Evaluierungsteils bewertet. Wiederholt man diese Schritte mehrmals, kann festgestellt werden, ob die Performance des Prognosemodells aufgrund der unterschiedlich verwendeten Trainingsätze variiert (vgl. Wong/Ye, 2020).

So werden aus den vorhandenen Umsatzdaten zunächst Zeitscheiben erstellt, die je eine unter-

Die SAC als BI- und Planungs-Tool bietet die Möglichkeit, sich in R erstellte Prognosen anzeigen zu lassen.

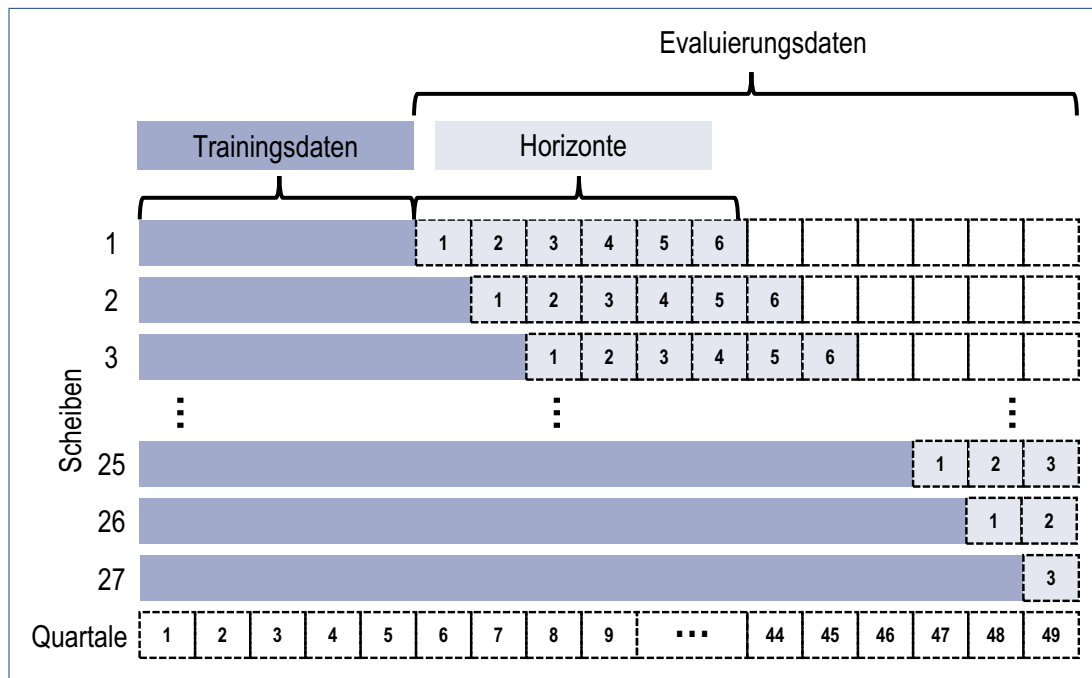


Abb. 3: Verfahren zur Evaluierung der Prognosegenauigkeit

schiedliche Anzahl an Beobachtungen enthalten. Die erste Scheibe (engl.: slice) enthält 22 Beobachtungen und umfasst alle Quartale in der Periode Q1 2010 bis Q2 2015. Die zweite Scheibe enthält eine weitere Beobachtung, Q3 2015, und somit ein Quartal mehr. Dies wird fortgeführt bis hin zur Scheibe Nummer 27, die 48 Quartale von Q1 2010 bis Q4 2021 umfasst, d. h. alle Beobachtungen bis auf die Letzte. Die einzelnen Zeitscheiben werden anschließend als Trainingsdaten für die Prognosemodelle verwendet. Dieses Verfahren des expandierenden Zeitfensters (engl.: expanding window approach) eignet sich gut, um die Prognosegenauigkeit der Modelle zu evaluieren, da wir diese mit einer unterschiedlichen Anzahl an Beobachtungen trainieren können. **Abb. 3** veranschaulicht das Verfahren.

Der Rest der vorhandenen Daten bildet jeweils die Menge der Evaluierungsdaten. Da eine Vorhersage zu weit in die Zukunft jedoch ungenau und in der Praxis unrealistisch ist, berechnen wir für jede Scheibe sechs Prognosewerte (engl.: forecast horizons). Beispielsweise erstellen wir für die erste Scheibe auf Basis der Trainingsdaten bis einschließlich Q2 2015 Prognosen für die sechs Quartale Q3 2015 bis Q4 2016. Aus den Evaluierungsdaten wählen wir in diesem Fall die ersten sechs aus und vergleichen für diese Horizonte unsere Prognosen mit den tatsächlichen Werten. Nur für die letzten Scheiben bleiben weniger als sechs Werte zum Vergleichen übrig. Beispielsweise verwendet die letzte Scheibe alle vorhandenen Beobachtungen außer das Quartal Q1 2022 zum Trainieren der Modelle. Die Evaluierungsdaten werden in diesem Fall vollständig zum Vergleich genutzt und bestehen entsprechend aus nur einem Horizont.

Um robuste Ergebnisse zu bekommen, ist es nötig, die gleiche Anzahl an Beobachtungen für jedes Unternehmen zu verwenden. Weil sich die Zusammensetzung des *DAX* im Zeitverlauf ändert und wir auf eine gemeinsame Datenquelle (*PitchBook*) zurückgreifen, sind manche Datenhistorien unvollständig und wir entfernen 13 Unternehmen aus der Analyse. Aufgrund von Datenqualitätsproblemen bei *PitchBook* schließen wir zusätzlich 3 Unternehmen aus der Analyse aus. Nach der abschließenden Bereinigung der Daten sind somit jeweils 49 Beobachtungen für 24 Unternehmen in der finalen Stichprobe enthalten: *Adidas, Airbus, BASF, Bayer, BMW, Brenntag, Continental, Deutsche Boerse, Deutsche Telekom, DHL, Fresenius, Fresenius Medical Care, Hannover Re, Infineon, Linde, Mercedes-Benz, Merck, Muenchener Re, Puma, Qiagen, SAP, Sartorius, Siemens, Volkswagen*.

Um die Ergebnisse auch getrennt für die Perioden vor und nach Beginn der COVID-Pandemie auszuwerten, haben wir zwei weitere Teilstichproben erstellt. Die Teilstichprobe pre-COVID enthält die Prognosen bis einschließlich Q4 2019. Die Teilstichprobe post-COVID enthält die Prognosen für die Zeit ab Q1 2020. Somit können wir die Vorhersagegenauigkeit in volatilen Zeiten noch besser analysieren.

MAPE als Gütemaß der Prognose

Für jede Horizont-Scheibe berechnen wir sechs Prognosewerte (engl.: forecast horizons). Anschließend berechnen wir die absolute prozentuale Abweichung (engl.: absolute percentage error) vom prognostizierten zum tatsächlichen Umsatz. Der Durchschnittswert über alle Scheiben und für jeden Horizont ist unser Benchmark für die Evaluie-

Um die Ergebnisse getrennt für die Perioden vor und nach Beginn der COVID-Pandemie auszuwerten, haben wir zwei weitere Teilstichproben erstellt.

Um die Vergleichbarkeit zu gewährleisten, erfolgt die Kreuzvalidierung der Prognosefähigkeit von SAC in einem aufwändigen manuellen Verfahren.

rung der Modelle. Schließlich wählen wir individuell für das jeweilige Unternehmen das Prognosemodell mit dem insgesamt niedrigsten Durchschnittswert aus, welches für den Vergleich zu SAC herangezogen wird. Durch die Berechnung der absoluten Abweichung spielt die Richtung der Varianz (unterschätzt oder überschätzt) keine Rolle. Dieses Maß wird als MAPE bezeichnet (für engl.: mean absolute percentage error) und ist ein Standardmaß in der Bewertung von Prognosemodellen (vgl. *De Myttenaere et al., 2016*). Außerdem definieren wir eine kurze und eine lange Frist für die Analyse. Die kurze Frist entspricht dem durchschnittlichen Fehler der Prognosen für die Horizonte 1, 2 und 3. Die lange Frist bezieht sich auf die Horizonte 4, 5 und 6.

Im Anschluss wiederholen wir diese Analyse nach der gleichen Logik mit SAC. Da die SAC eine anwenderorientierte Lösung ist und somit in erster Linie auf den fachlichen Mitarbeiter ausgerichtet ist, können keine Einstellungen in Bezug auf die Trainings-Vorgehensweise der Daten vorgenommen werden. Um die Vergleichbarkeit zu gewährleisten, erfolgt die Kreuzvalidierung der Prognosefähigkeit in einem manuellen Verfahren. Nach dem Upload der Umsatzdaten erfolgt die Prognose mit der „Smart Predict“-Funktion von SAC. Welche Regeln oder Modelle zur Berechnung der Prognosen in SAC verwendet werden, wird auf der offiziellen Webseite durch SAP nicht angegeben. Durch Recherchen lässt sich immerhin aus einem SAP-Blogbeitrag erfahren, dass verschiedene univariate Modelle verwendet werden, die unter anderem auf Trends in den Daten und Saisonalitäten eingehen.

Performance-Unterschiede der Prognosemodelle entstehen demnach nicht durch eine höhere Anzahl an Features, sondern durch eine passende Auswahl des Prognosemodells (in Abhängig der Zeitreihen-Eigenschaften des jeweiligen Unternehmens).

Für die Kreuzvalidierung erstellen wir ein neues SAC-„Modell“ und setzen für das erste Trainingsintervall die Trainingsperiode auf die Quartale, die der jeweiligen Scheibe entsprechen. Anschließend wiederholen wir dieses Verfahren für alle Scheiben und alle Unternehmen. Wiederum werden dann die erstellten Prognosen mit den tatsächlichen, im Training nicht verwendeten Evaluierungsdaten verglichen. SAC zeigt einen „expected“ MAPE an, dessen Berechnung jedoch ebenfalls nicht nachvollzogen werden kann. Die Berechnung der SAC-MAPEs wurde deshalb ebenfalls in R ausgeführt.

Ergebnisse

Abb. 4 zeigt die Ergebnisse der Prognosen und den Vergleich zwischen dem jeweils besten der 12 Modelle in R je Unternehmen mit der Prognose in SAC. Wir berechnen den durchschnittlichen MAPE über die gesamte Periode, d. h. über alle Scheiben und alle Prognosehorizonte. Ein grauer Balken markiert das Ergebnis aus R und ein blauer Balken das Ergebnis aus SAC. Die Abbildung ist sortiert nach aufsteigendem MAPE der Ergebnisse aus R. Auf der horizontalen Achse sind die enthaltenen Unternehmen abgetragen. Das bedeutet, dass für jedes Unternehmen zwei Informationen vorhanden sind: die Prognosegenauigkeit aus R und aus SAC. Ein niedrigerer MAPE bedeutet eine höhere durch-




Abb. 4: Vergleich der Prognosegenauigkeit von R und SAC über alle Horizonte

schnittliche Genauigkeit. Ein höherer MAPE bedeutet, dass der Wert entweder schwieriger zu prognostizieren ist oder ein falsches Prognosemodell gewählt wurde. Eine Fokussierung auf univariate Modelle welche nur den Umsatz als erklärende Variablen berücksichtigen, bedeutet aber nicht per se, dass dies zu höheren MAPEs führt. Auch univariate Modelle können z. B. Saisonalitäten bei der Schätzung berücksichtigen.

Für manche Unternehmen, wie z. B. *SAP*, *Volkswagen*, und *Deutsche Telekom* ist die Genauigkeit von *R* und *SAC* nahezu identisch. Für andere Unternehmen ist die Abweichung deutlich höher. Beispielsweise hat man für *Siemens* einen durchschnittlichen MAPE von 12,2 % aus *R*, wobei *SAC* einen durchschnittlichen MAPE in Höhe von 25,7 % erzeugt. Dies entspricht einer Differenz von 13,5 %-Prozentpunkten. **Abb. 5** fasst die Ergebnisse zusammen. In den Spalten 2 und 3 kann man zusätzlich die durchschnittlichen MAPEs für die kurzen Prognosehorizonte, d. h. für die Horizonte 1, 2 und 3, ablesen. Die Spalten 4 und 5 beinhalten die Ergebnisse für die lange Frist, d. h. für die Horizonte 4, 5 und 6. Die letzten beiden Spalten korrespondieren zu **Abb. 4**. Insgesamt werden die Umsätze von 19 der 24 Unternehmen (79 % der Fälle) in der kurzen Frist mit *R* genauer prognostiziert als mit *SAC*. In der langen Frist ist dies bei 23 Unternehmen (96 %) der Fall. Insgesamt über alle Horizonte sind die durchschnittlichen MAPEs bei 23 Unternehmen (96 %) niedriger mit *R* als mit *SAC*. Die durchschnittliche Differenz zwischen beiden beträgt 1,6 %-Punkte zugunsten von *R* in der kurzen Frist, 3,0 %-Punkte in der langen Frist, und 2,7 %-Punkte über alle Horizonte.

Für die Auswertung nutzen wir die zuvor erstellten Teilstichproben mit den jeweilig passenden Scheiben. Die letzte für pre-COVID verwendete Scheibe ist Scheibe 18, die Trainingsdaten bis Q3 2019 enthält. Somit ist mit Q4 2019 noch genau ein letztes Quartal zum Vergleichen mit den Evaluierungsdaten vorhanden, das nicht unter dem Einfluss von COVID stand. Dementsprechend wird in der Teilstichprobe für Scheibe 18 nur ein Prognosehorizont verwendet. Post-COVID verwendet hingegen alle späteren Scheiben, startet also mit Scheibe 19, die die Trainingsdaten Q1 2010 bis Q4 2019 nutzt und Prognosen für die COVID-Zeit ab 2020 erstellt. Daher können in dieser Teilstichprobe jeweils alle bis zu 6 berechneten Prognosehorizonte ausgewertet werden.

Abb. 5 zeigt die Ergebnisse für die Zeit vor und nach Beginn der COVID-Pandemie. Der obere Abschnitt ist geordnet nach der Differenz zwischen den durchschnittlichen MAPEs aus *R* und *SAC* vor Beginn der COVID-Pandemie. Man sieht deutlich, dass die Unterschiede für manche Unternehmen nicht hoch sind. So werden beispielsweise die Umsätze von *Qiagen*, *SAP*, und der *Deutschen Börse* nahezu gleich gut mit *R* und *SAC* prognostiziert.

Implikationen für die Praxis

- Die Einbindung ML-basierter Prognosemodelle in die S/4HANA Architektur ist möglich und sollte in der Praxis Verwendung finden.
- Durch die Anpassbarkeit der Modelle wird eine erhöhte Prognosegüte im Rahmen des Forecastings ermöglicht.
- Das Controlling kann als Bindeglied zwischen Data Scientists und Management fungieren.

Der untere Abschnitt ist nach denselben Unternehmen geordnet. Somit wird der Unterschied nach Beginn der COVID-Pandemie erkennbar. Die Unterschiede in der Prognosegenauigkeit sind für fast alle Unternehmen gestiegen. Wenn zuvor für *Qiagen* der Unterschied bei 0,2 Prozentpunkten lag, ist er post-COVID bei 9,7 %-Punkten. Zusammenfassend sind die Ergebnisse in **Abb. 7** dargestellt. Pre-COVID waren die Unterschiede im MAPE bei 2,3 %-Punkten durchschnittlich über alle Unternehmen, zugunsten von *R*. Für 22 Unternehmen (92 %) konnte *R* durchschnittlich eine bessere Prognose liefern. Post-COVID konnte *R* zwar nur für 20 Un-

MAPEs	Kurz (H = 1,2,3)		Lang (H = 4,5,6)		Alle Horizonte	
	R	SAC	R	SAC	R	SAC
<i>Adidas</i>	9,1%	7,9%	11,9%	12,7%	10,9%	11,4%
<i>Airbus</i>	13,8%	15,3%	16,2%	18,5%	15,5%	17,4%
<i>BASF</i>	10,3%	15,6%	14,6%	25,8%	13,3%	22,9%
<i>Bayer</i>	9,9%	10,2%	12,3%	14,6%	11,5%	13,4%
<i>BMW</i>	7,4%	7,1%	7,8%	8,4%	7,7%	8,1%
<i>Brenntag</i>	6,6%	7,8%	10,6%	11,3%	9,3%	10,2%
<i>Continental</i>	8,0%	9,9%	12,0%	17,9%	10,9%	15,6%
<i>Deutsche Boerse</i>	2,1%	2,4%	4,5%	5,1%	3,8%	4,3%
<i>Deutsche Telekom</i>	3,7%	4,1%	9,6%	9,4%	7,9%	7,9%
<i>DHL</i>	1,7%	4,0%	5,3%	6,7%	4,2%	5,9%
<i>Fresenius</i>	2,9%	4,1%	4,5%	6,7%	4,0%	5,9%
<i>Fresenius Medical Care</i>	4,0%	7,1%	4,8%	12,0%	4,5%	10,6%
<i>Hannover Re</i>	4,3%	5,0%	6,8%	8,2%	6,0%	7,3%
<i>Infineon</i>	5,7%	7,7%	10,5%	10,8%	9,1%	9,8%
<i>Linde</i>	14,3%	19,0%	38,0%	43,8%	31,2%	36,7%
<i>Mercedes-Benz</i>	6,3%	6,8%	9,7%	11,3%	8,7%	10,1%
<i>Merck</i>	4,5%	5,9%	7,2%	8,8%	6,4%	7,9%
<i>Muenchener Re</i>	5,2%	6,8%	6,6%	8,5%	6,2%	7,9%
<i>Puma</i>	10,8%	9,7%	13,6%	15,5%	12,9%	13,8%
<i>Qiagen</i>	5,8%	6,9%	10,0%	12,1%	8,8%	10,6%
<i>SAP</i>	3,7%	3,6%	4,6%	4,7%	4,3%	4,3%
<i>Sartorius</i>	6,2%	9,1%	14,3%	21,3%	12,0%	17,9%
<i>Siemens</i>	8,7%	19,1%	13,7%	27,9%	12,2%	25,7%
<i>Volkswagen</i>	7,7%	6,6%	7,5%	7,8%	7,6%	7,5%
In wie vielen Fällen ist <i>R</i> besser als <i>SAC</i> ?	19 (79%)		23 (96%)		23 (96%)	
Durchschnittliche Abweichung im MAPE <i>R</i> vs. <i>SAC</i>	-1,6%-Punkte		-3,0%-Punkte		-2,7%-Punkte	

Abb. 5: Auswertung der durchschnittlichen Prognosegenauigkeit (MAPE) für die kurzen, langen und alle Horizonte der gesamten Stichprobe

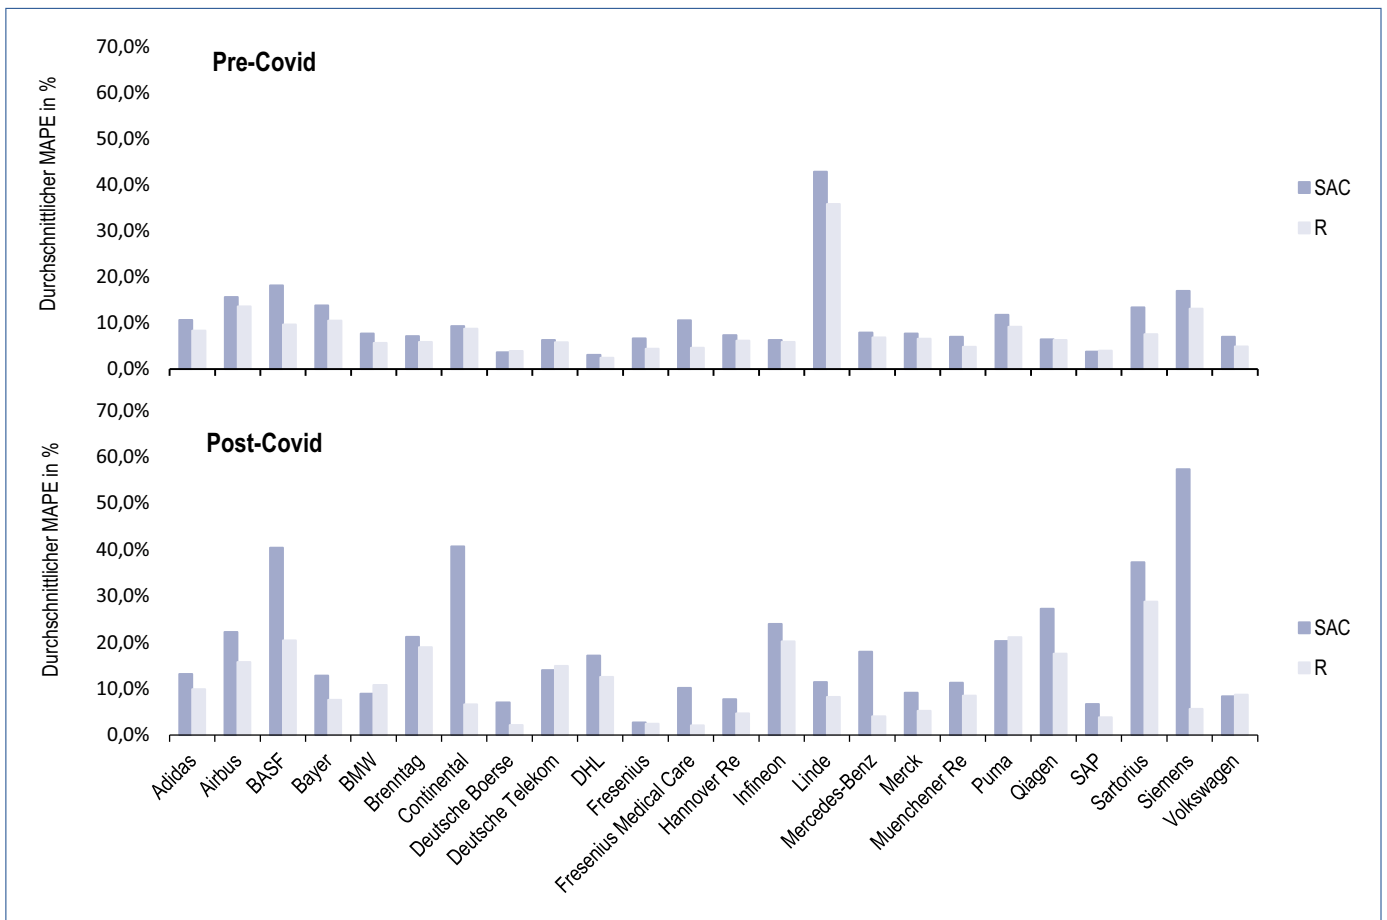


Abb. 6: Vergleich der Prognosegenauigkeit von R und SAC Pre- und Post-COVID über alle Horizonte

ternehmen (82 %) insgesamt eine bessere Prognose erzeugen. Allerdings lag die Verbesserung im MAPE mit durchschnittlich 7,8 %-Punkten recht hoch.

4. Fazit

Mit der Verwendung von multivariaten Modellen könnte der Informationsgehalt des Modells in Bezug auf Einflussfaktoren weiter erhöht werden.

Für das Forecasting in volatilen Zeiten ist die Verwendung von geeigneten Prognosemodellen ein erfolgsentscheidender Faktor. So zeigen die vorgestellten Ergebnisse, dass durch die Auswahl der Prognosemodelle und deren Parametereinstellungen unterschiedliche Ergebnisse in Bezug auf die Prognosequalität erreicht werden können. Die Ergebnisse zeigen auch, dass man mit *R* durchschnittlich genauere Prognosen erzeugen kann als mit den aktuellen (Stand Okt. 2022) in *SAC* fest implementierten Modellen. Unsere Analyse stützt sich dabei auf die Standardmodelle aus dem Paket *fable* in *R*, wobei für den Vergleich nur univariate Modelle verwendet wurden. Mit der Verwendung von multivariaten Modellen könnte der Informationsgehalt des Modells in Bezug auf Einflussfaktoren weiter erhöht werden.

Viele Software-Hersteller bieten für das Forecasting mittlerweile sog. „No-Code“ bzw. „Low-Code“-Lösungen an. Diese ermöglichen es Advanced Analytics für das Controlling salonfähig zu machen. Mit der Nutzung von *Predictive Scenarios* in *SAP SAC* besteht zum aktuellen Zeitpunkt jedoch

keine Auswahlmöglichkeit für das verwendete Prognosemodell. Des Weiteren können keine Einstellungen des für die Evaluierung benötigten Gütemaßes vorgenommen werden. Da die Auswahl des Modells und der verwendeten Gütemaße einen entscheidenden Einfluss auf die Performance des Modells haben, ist eine eigenständige Entwicklung des Prognosemodells durch einen Data Scientist ratsam. Darüber hinaus ist eine transparente Darstellung der verwendeten Treiber, Modelle und Gütemaße ein wichtiger Faktor, um die Akzeptanz der Prognosewerte innerhalb der Fachabteilung zu erhöhen. Um eine valide Beurteilung abgeben zu können, sollte sich demnach Controllerinnen und Controller als Informationslieferanten des Managements mit diesen Themen zukünftig auseinandersetzen und Kompetenzen im Bereich Advanced Analytics aufbauen.

Auf Planungs- und Analysetools wie *SAC* muss dennoch nicht verzichtet werden. *SAC* bietet mit der Einbindung von externen Webseiten die Möglichkeit, in *R* oder *Python* implementierte Schnittstellen einzubinden. Dadurch können Berechnungen und statistische Analysen verschiedener interner und externer Zeitreihen ausgelagert und innerhalb *SAC* visualisiert werden. Bei der Verwendung oder Einführung von *SAP S/4HANA* schlagen wir deshalb eine Architektur vor, die sich auf *SAP* als ERP- und BW-System stützt und mit *SAC* als Pla-

nungs- und BI-Tool eine optimale Ergänzung darstellt. So können Predictive Analytics Methoden an individuelle Begebenheiten angepasst und eine weitreichende Automatisierung erlangt werden.

Literatur

- Blackburn, R./Lurz, K./Priese, B./Göb, R./Darkow, I. L., A predictive analytics approach for demand forecasting in the process industry, in: International Transactions in Operational Research, 22. Jg. (2015), H. 3, S. 407–428.
- De Myttenaere, A./Golden, B./Le Grand, B./Rossi, F., Mean absolute percentage error for regression models, in: Neurocomputing, 192. Jg. (2016), S. 38–48.
- Ge, Z./Song, Z./Ding, S. X./Huang, B., Data mining and analytics in the process industry: The role of machine learning, in: Ieee Access, 5. Jg (2017), S. 20590–20616.
- Henttu-Aho, T., The role of rolling forecasting in budgetary control systems: Reactive and proactive types of planning, in: Journal of Management Control, 2018, 29. Jg., H. (3–4), S. 327–360.
- Januschowski, T./Gasthaus, J./Wang, Y./Salinas, D./Flunkert, V./Bohlke-Schneider, M./Callot, L., Criteria for classifying forecasting methods, in: International Journal of Forecasting, 36. Jg. (2020), H. 1, S. 167–177.
- Mukherjee, R./Kar, P., A comparative review of data warehousing ETL tools with new trends and industry insight, in: 2017 IEEE 7th International Advance Computing Conference (IACC). IEEE, (2017) S. 943–948.
- Rieg, R., Unternehmensplanung in der Praxis – Ergebnisse einer Online-Studie Studienserie „Erfolgsfaktoren der Unternehmensführung“, 2021, https://opus-htw-aalen.bsz-bw.de/frontdoor/deliver/index/docId/1275/file/AAUF_Band11_Planungsheuristik.pdf, Stand: 20.02.2023.
- Wong, T. T./Yeh, P. Y., Reliable accuracy estimates from k-fold cross validation, in: IEEE Transactions on Knowledge and Data Engineering, 32. Jg. (2019), H. 8, S. 1586–1594.
- Wu, L./Barash, G./Bartolini, C., A service-oriented architecture for business intelligence, in: IEEE international conference on service-oriented computing and applications IEEE, (2007), S. 279–285.
- Wu, D./Olson, D. L./Lambert, J. H., Data analytics and decision-making systems: Implications of the global outbreaks, in: Decision Support Systems, 161. Jg. (2022), S. 113847–113847.

MAPEs	Pre-COVID		Post-COVID	
	R	SAC	R	SAC
Adidas	8,4%	10,6%	9,9%	13,1%
Airbus	13,6%	15,6%	15,8%	22,2%
BASF	9,7%	18,2%	20,4%	40,4%
Bayer	10,5%	13,8%	7,6%	12,8%
BMW	5,7%	7,7%	10,8%	8,9%
Brenntag	5,9%	7,1%	19,0%	21,2%
Continental	8,7%	9,3%	6,7%	40,7%
Deutsche Boerse	3,9%	3,7%	2,2%	7,0%
Deutsche Telekom	5,8%	6,3%	14,9%	14,0%
DHL	2,5%	3,1%	12,5%	17,1%
Fresenius	4,4%	6,6%	2,4%	2,7%
Fresenius Medical Care	4,6%	10,6%	2,1%	10,2%
Hannover Re	6,2%	7,3%	4,7%	7,7%
Infineon	5,8%	6,3%	20,2%	23,9%
Linde	35,9%	42,8%	8,2%	11,4%
Mercedes-Benz	6,9%	7,9%	4,1%	17,9%
Merck	6,6%	7,7%	5,2%	9,1%
Muenchener Re	4,8%	7,0%	8,5%	11,3%
Puma	9,1%	11,8%	21,1%	20,3%
Qiagen	6,3%	6,4%	17,5%	27,2%
SAP	4,0%	3,7%	3,9%	6,7%
Sartorius	7,6%	13,4%	28,7%	37,3%
Siemens	13,1%	16,9%	5,6%	57,3%
Volkswagen	4,9%	7,0%	8,7%	8,3%
In wie vielen Fällen ist R besser als SAC?	22 (92%)		20 (83%)	
Durchschnittliche Differenz im MAPE R vs. SAC	-2,3%-Punkte		-7,8%-Punkte	

Abb. 7: Auswertung der durchschnittlichen Prognosegenauigkeit (MAPE) für die über alle Horizonte für die Zeit vor und nach Beginn der COVID-Pandemie (pre- und post-COVID)

Literaturtipps aus dem Online-Archiv <http://elibrary.vahlen.de>



- Gero Holthoff, René Decher, Implementierung von Predictive Analytics im Forecasting, Ausgabe 6/2020, S. 52–58
- Ansgar Heidemann, Pilotprojekte für Predictive Planning mit moderner Planungssoftware unterstützen, Ausgabe 2/2021, S. 80–82
- Daniel Schlatter, Christopher Stoll, Klaus Möller, Predictive Analytics erfolgreich implementieren, Ausgabe 1/2020, S. 58–64

Stichwörter

Analytics # Forecasting # Predictive # R # SAC

Keywords

Analytics # Forecasting # Predictive # R # SAC

Mit offener Strategiearbeit erfolgreich managen.



beck-shop.de/33736224

Matzler/Stadler/Hautz/
Friedrich von den Eichen/Anschober
Open Strategy

2022. 292 Seiten. Gebunden € 34,90
ISBN 978-3-8006-6942-4

Open Strategy

bietet eine Sammlung von Tools und »Schritt für Schritt Anleitungen«, wie Open Strategie zur Strategieformulierung und -umsetzung in den einzelnen Phasen des Strategie- und Geschäftsmodellentwicklungsprozesses eingesetzt werden kann.

Das Buch bietet

- einen neuen Ansatz zur Entwicklung disruptiver Geschäftsmodelle
- eine praxisorientierte Darstellung mit vielen Beispielen von kleinen und großen Unternehmen z.B. Barclays, IBM, Adidas, Gallus, Voest, Nato, US Navy, NASA u.v.m.
- viele Methoden, wie Schritt für Schritt Open Strategy in Unternehmen umgesetzt werden kann

Erhältlich im Buchhandel oder bei: beck-shop.de |

Verlag Franz Vahlen GmbH · 80791 München | kundenservice@beck.de |

Preise inkl. MwSt. | 174741 | [linkedin.com/company/vahlen](https://www.linkedin.com/company/vahlen)

Vahlen

Summary

New user-friendly analytics solutions such as *SAP Analytics Cloud (SAC)* provide access to statistical forecasting models to a wide audience. However, the question arises as to how well these models perform compared to self-developed forecasts. In this article, we therefore compare the forecasting performance of *SAP SAC* with statistical machine learning algorithms in *R*. The comparison is based on sales data of DAX40 companies over a period from 2010 to 2022. In addition, we look at the forecasting results before and after the COVID-19 pandemic and find that for forecasting in volatile times, the use of appropriate forecasting models is a critical factor for success.