

Digital Reporting

Arbeitskreis Internes Rechnungswesen der Schmalenbach-Gesellschaft

2023

ISBN 978-3-8006-7032-1

Vahlen

schnell und portofrei erhältlich bei
beck-shop.de

Die Online-Fachbuchhandlung beck-shop.de steht für Kompetenz aus Tradition. Sie gründet auf über 250 Jahre juristische Fachbuch-Erfahrung durch die Verlage C.H.BECK und Franz Vahlen.

beck-shop.de hält Fachinformationen in allen gängigen Medienformaten bereit: über 12 Millionen Bücher, eBooks, Loseblattwerke, Zeitschriften, DVDs, Online-Datenbanken und Seminare. Besonders geschätzt wird beck-shop.de für sein umfassendes Spezialsortiment im Bereich Recht, Steuern und Wirtschaft mit rund 700.000 lieferbaren Fachbuchtiteln.

während bei Prognosen zum Umsatz von Neuprodukten oder bei grundlegenden Veränderungen im Wettbewerbsumfeld aufgrund mangelnder historischer Daten stets die Einschätzung von Experten benötigt wird.

Weiterhin ist die Qualität historischer Daten von besonderer Bedeutung. So können bei mangelhafter Datenqualität keine validen Prognoseergebnisse erwartet werden. Dies unterstreicht die besondere Notwendigkeit eines umfassenden Datenmanagementkonzepts, um die Voraussetzung für eine erfolgreiche Anwendung von Predictive Analytics zu schaffen.*

Eine zusätzliche Herausforderung besteht in der Auswahl und dem Einbezug unternehmensexterner Daten, die einen Einfluss auf Prognoseergebnisse haben können, wie beispielsweise makroökonomische oder branchenspezifische Indikatoren. Hier gilt es zu beachten, dass der Einbezug externer Daten in der Regel mit Erhebungsaufwand verbunden ist, beispielsweise aufgrund einer gegebenenfalls notwendigen manuellen Erhebung. Es gilt daher sorgfältig abzuwägen, welche externen Indikatoren einen theoretischen Einfluss haben könnten und diesen Einfluss anschließend empirisch zu validieren.

Zudem wird häufig die notwendige IT-Systemarchitektur zur Etablierung automatisierter Prognosen unterschätzt. Gerade bei der Verarbeitung großer Datenmengen (Big Data) stoßen etablierte IT-Systeme an ihre Grenzen, was dazu führen kann, dass die Erstellung von automatisierten Prognosen einen überproportional langen Zeitraum erfordert. Abhilfe kann hier die Inanspruchnahme von sogenannten Hyperscalern wie Microsoft Azure, Amazon AWS oder Google Cloud schaffen, die eine kosteneffiziente und skalierbare IT-Infrastruktur in einer virtuellen, cloudbasierten Umgebung bereitstellen.

Während heute eine Vielzahl an frei verfügbaren Open-Source Anwendungen zur Verfügung steht, um Predictive Analytics für unterschiedliche Anwendungszwecke zu nutzen, lässt sich feststellen, dass diese regelmäßig auf unternehmensspezifische Erfordernisse anzupassen sind. Zudem führt die Heterogenität eines unternehmensspezifischen Produktportfolios in der Regel dazu, dass unterschiedliche Prognoseansätze kombiniert werden müssen, um valide Prognosen zu erhalten. Auch wenn es zunehmend sogenannte *low code/no code*-Anwendungen gibt, die auch ohne vertiefte statistische Kenntnisse eine schnelle Validierung einzelner Prognoseansätze ermöglichen, verdeutlichen die zuvor genannten Beispiele, dass es in der Regel eigene Teams oder externe Dienstleister mit entsprechenden Fachkenntnissen erfordert, um Predictive Analytics unternehmensweit erfolgreich zu implementieren und auf die unternehmensspezifischen Bedürfnisse gezielt anzupassen.

4. Erfolgsfaktoren und Lösungsvorschläge

Wie kann diesen zuvor skizzierten Herausforderungen nun umfassend begegnet werden? Für die erfolgreiche Implementierung von Predictive Analytics im Rahmen von Planungs- und Prognoseprozessen ist zunächst zu empfehlen, mit einem möglichst einfachen exemplarischen Anwendungsfall zu starten, beispielsweise der Umsatzpro-

* Vgl. hierzu den abschließenden Beitrag „Ausblick: Sechs Thesen zur Transformation des Controllerbereichs beim Einsatz neuer digitaler Technologien“ des Arbeitskreises Digital Reporting im vorliegenden Sammelband.

gnose eines bestimmten Produkts oder einer Produktgruppe. So zeigen sich bei diesem Vorgehen unmittelbar systematische Schwachpunkte im Bereich Datenverfügbarkeit und -qualität, die gezielt adressiert werden können. Zudem können grundsätzliche Vorteile weitgehend automatisierter Prognosen für einen exemplarischen Anwendungsfall illustriert werden, bevor eine Entscheidung bezüglich der weiteren Skalierung oder der Übertragung auf andere Anwendungsfälle erfolgt.

Für eine nachhaltige Etablierung von Predictive Analytics ist es zudem wichtig, die richtigen organisationalen Rahmenbedingungen zu schaffen. Als besonders vorteilhaft erweisen sich hierbei interdisziplinäre Teams, zum Beispiel aus den Bereichen Finanzen, IT und Data Science. Diese Teams müssen nicht notwendigerweise in einer gemeinsamen Abteilung zusammengefasst werden, sondern können auch im Rahmen eines Projektteams oder einer virtuellen Organisationseinheit zusammenarbeiten. Wichtig ist hierbei vor allem der gemeinsame Austausch bezüglich notwendiger Anforderungen und Möglichkeiten zur effektiven Umsetzung über die Grenzen von Funktionsbereichen hinaus.

Für Mitarbeiter des Finanzbereichs ist zudem eine Aneignung von Grundkenntnissen im Bereich statistischer Datenanalyse unerlässlich, um die Aussagekraft automatisierter Prognosen beurteilen zu können. Ein grundlegendes Verständnis der Wirkungs- und Funktionsweise von Prognosealgorithmen hilft zudem dabei, etwaige Vorbehalte abzubauen und den Black Box-Charakter automatisierter Prognosen zu reduzieren (Holthoff und Decher, 2020).

Für die Akzeptanz von Predictive Analytics im Rahmen von Planungs- und Prognoseprozessen ist es zudem wichtig, schon bei der Entwicklung und initialen Einführung diejenigen Experten zu involvieren, die bisher eine klassische, manuelle Planung verantwortet haben. Hier bieten sich vor allem agile Entwicklungsschleifen an, die einen kontinuierlichen Austausch gewährleisten. Zur Beurteilung der Effektivität automatisierter Prognosen können dabei im Rahmen eines sogenannten Backtestings manuelle Planungen der Vergangenheit mit den Ergebnissen von Prognosealgorithmen gegenübergestellt und deren Abweichungen zu Ist-Werten diskutiert werden. Dieses Vorgehen stellt dabei eine Möglichkeit bereit, mit konkreten Daten und Fakten die Vorteilhaftigkeit von Predictive Analytics zu evaluieren.

Es ist weiterhin zu beachten, dass die erfolgreiche Nutzung von automatisierten Prognoseansätzen regelmäßige Anpassungen und Weiterentwicklungen erfordert, um die Genauigkeit der Prognoseergebnisse im Zeitablauf stetig zu verbessern. Wichtig ist dabei stets die bewusste Auseinandersetzung mit Prognosen und das Hinterfragen von Ergebnissen gemeinsam mit den für die Planung zuständigen Experten.

Zu guter Letzt sollte die Nutzung von Predictive Analytics möglichst einfach gestaltet werden. So können die Ergebnisse automatisierter Prognosen beispielsweise in Dashboards intuitiv dargestellt werden (zum Beispiel mittels PowerBI oder SAP Analytics Cloud) und einen einfachen Zugang schaffen, was insbesondere in Phasen der initialen Evaluierung als vorteilhaft erscheint. Für eine nachhaltige Nutzung von Predictive Analytics müssen solche Ansätze jedoch in bereits existierende Planungs- und Prognosesysteme integriert werden.

5. Fazit

Abschließend lässt sich festhalten, dass technische Herausforderungen im Rahmen der Implementierung von Predictive Analytics in der Regel erfolgreich adressiert werden können. Entscheidend für die effektive Nutzung und den nachhaltigen Erfolg sind vielmehr unternehmenskulturelle Aspekte. Die Einführung von Predictive Analytics im Finanzbereich ist gerade in initialen Phasen oft durch explorative Vorgehensweisen gekennzeichnet, die einen finanziellen und zeitlichen Zusatzaufwand erfordern. Hier ist eine entsprechende Unterstützung seitens des Top Managements unerlässlich. Es gilt zudem, die mit Predictive Analytics verbundenen Effizienzpotenziale konsequent zu demonstrieren, um einen Wandel und eine Optimierung etablierter Prozesse bestmöglich zu unterstützen. Besteht des Weiteren eine realistische Zielsetzung bezüglich der Vorteile und geeigneter Anwendungsgebiete von Predictive Analytics, steht einer erfolgreichen Implementierung im Finanzbereich nichts mehr im Wege.

Predictive Forecasting: Entwicklungsperspektiven für den Einsatz von Predictive Analytics im Controlling

Björn Reitzenstein / Sabine Kösling-Guse / Barbara E. Weißenberger*

„Das Ziel von Predictive Analytics-Technologien besteht darin, den Prognoseprozess zu automatisieren und ein fortlaufendes Forecasting mit Echtzeit-Daten zu ermöglichen. Dabei gilt: Das volle Potenzial kann nur in Zusammenspiel der Expertise von Data Science und Controlling erreicht werden.“

1. Forecasting als Controllingaufgabe

Seit jeher stehen Unternehmen vor der Herausforderung, sich so zu organisieren, dass alle aus dem Unternehmenszweck abgeleiteten Ziele bestmöglich erreicht werden. Die damit verbundenen Entscheidungs- und Steuerungsaufgaben werden durch ein ergebnisverantwortliches Management umgesetzt. Die erforderliche Unterstützung wird durch das Controlling als spezialisierter Führungsteilfunktion geleistet.

Als Business Partnern des Managements besteht eine wichtige Aufgabe von Controllern darin, die Prognose zukünftiger Ereignisse zu ermöglichen und damit in dreifacher Hinsicht zum Unternehmenserfolg beizutragen. Zunächst erlauben Prognosen überhaupt erst, die künftige Entwicklung wichtiger, vom Management aber nicht unmittelbar beeinflussbarer Größen in Entscheidungen zu berücksichtigen, wie beispielsweise Kundennachfrage oder Wechselkurse. Weiterhin werden Prognosen genutzt, um operative und strategische Zielvorgaben z.B. für Gewinn, Produktionsmengen oder Marktanteile festzulegen, die als Richtschnur für die Entscheidungsfindung und damit auch als Beurteilungsgröße des Managements dienen. Und schließlich schaffen Prognosen als vergemeinschaftete Erwartungshaltung die Grundlage für die Koordination des ziel- und erfolgsorientierten Handelns aller Führungskräfte. Der Prozess der Erstellung solcher Prognosen wird auch als Forecasting bezeichnet. Der folgende Beitrag beschäftigt sich damit, wie automatisierte KI-basierte digitale Technologien, sogenannte Predictive Analytics-Systeme, die Leistungsfähigkeit des Forecasting verbessern können.

2. Herausforderungen für das Forecasting

Viele Märkte, in denen sich Unternehmen heute bewegen, sind im Vergleich zur Vergangenheit dynamischer, komplexer und von größeren Schwankungsbreiten geprägt. Die permanente Unsicherheit über die Entwicklung des bestehenden Geschäfts wird durch vielfältige Krisen und politische Instabilität weiter genährt. Hinzu kommt, dass

* Björn Reitzenstein ist Head of Finance Transformation im Corporate Office Finance, Reporting and Treasury – Finance Principles and Finance Transformation bei der Robert Bosch GmbH. Sabine Kösling-Guse ist Vice President Corporate Office Finance, Reporting and Treasury – Finance Principles and Finance Transformation beim gleichen Unternehmen. Prof. Dr. Barbara E. Weißenberger ist Arbeitskreisleiterin (Wissenschaft), Inhaberin des Lehrstuhls für Betriebswirtschaftslehre, insbes. Controlling und Accounting, an der Heinrich-Heine-Universität Düsseldorf sowie Affiliate Professor of Accounting an der Bucerius Law School, Hamburg.

die digitale Transformation viele Märkte grundlegend verändert. All diese Faktoren haben direkten Einfluss auf die Relevanz von Prognosen.

Zur vorausschauenden Unternehmensplanung sind gute Einschätzungen zukünftiger Entwicklungen deshalb mehr denn je von hoher Bedeutung. KI-basierte Business Intelligence-Technologien stellen ein Mittel dar, um Unsicherheiten im Forecasting-Prozess zu reduzieren.

Forecasting bedeutet „Vorhersage“ und ist eine Technik, die den Zukunftswert ausgewählter Daten vorhersagt, indem bestimmte Trends betrachtet werden. Dies erfolgt traditionell mithilfe der detaillierten Fachexpertise von Controllern und Führungskräften. Ziel ist es, die Unsicherheit bezüglich des Eintritts von zukünftigen Ereignissen zu minimieren, um dem Management in möglichst kurzen Zyklen verlässliche Informationen zur Entscheidungsfindung und -steuerung bereitzustellen. Idealerweise sollen Aussagen zur Erreichbarkeit der vorhandenen Ziele gegeben und notwendige Handlungsbedarfe aufgezeigt werden.

3. Business Intelligence im Controlling

Die Arbeit im Controlling unterliegt seit ihrem Bestehen zahlreichen Veränderungen. In den Anfängen des Controllings standen noch keine Computer zur Verfügung. Informationen wurden deshalb vielfach zunächst mündlich kommuniziert, bevor sie anschließend in umfangreichen (Papier-)Berichten dokumentiert wurden. Mit der Einführung digitaler Technologien etablierten sich im Controlling Business Intelligence-Systeme, in denen Transaktionsdaten zunehmend breit und digital erfasst, gesichert und ausgewertet wurden.

Große Datenmengen („Big Data“) sowie heterogenere Datenstrukturen wurden durch die Einführung von Data Warehouse-Konzepten handhabbar gemacht. So wurde es möglich, interne und vor allem finanzielle Geschäftsdaten mit weiteren, auch unstrukturierten, nichtfinanziellen Informationen für hochwertige interne Analysen zu kombinieren. In der aktuellen Entwicklung der Business Intelligence im Controlling wächst die Menge der Daten immer weiter an, z.B. aus der Erfassung realwirtschaftlicher Produktionsprozesse mittels Sensoren. Dies erlaubt eine noch bessere und zunehmend ganzheitliche Abbildung des Geschäfts.

4. Traditionelles Forecasting versus Predictive Forecasting

Forecasts lassen sich prinzipiell mittels qualitativer und quantitativer Methoden erstellen. Der qualitative Ansatz beruht auf Expertenwissen und wird in Unternehmen in der Regel über viele Management-Einheiten hinweg erstellt. Beim quantitativen Ansatz dienen historische Daten bzw. Echtzeitanalysen kausaler Zusammenhänge, sogenannter Treiber, als Grundlage, um mittels statistischer Verfahren Datenmuster zu erkennen und Prognosen zu erstellen. Voraussetzung ist dabei, dass gefundene Muster auch für die Zukunft aufrechterhalten werden können.

Trotz der begrifflichen Ähnlichkeit handelt es sich beim Predictive Forecasting um eine Erweiterung des traditionellen Forecasting: Zukünftige Entwicklungen werden nicht mehr durch menschliche Analysen, sondern automatisiert und mittels KI-basierter digitaler Technologien vorhergesagt. So kann Predictive Forecasting Eingaben, Wer-

ten, Trends, Zyklen und Schwankungen der Daten viel umfassender als bisher für eine breite Menge an Prognoseobjekten und Unternehmensbereichen berücksichtigen und gleichzeitig schnellere und auch eine größere Zahl von Vorhersagen erstellen.

5. Kombination von Prognosemodellen

Durch seine Effizienz erleichtert Predictive Forecasting außerdem die Kombination mehrerer Prognosemodelle. Dies ist vorteilhaft, da statistisch unabhängige Prognosefehler sich gegenseitig ausgleichen. Liegen mehrere Prognosen für dasselbe Ereignis vor, kann ihre (lineare) Kombination gegenüber jeder einzelnen in gewisser Weise „überlegen“ sein. Wird dies z. B. über den mittleren quadratischen Fehler gemessen und sind die (Ko-)Varianzen der Vorhersagen bekannt, dann können theoretisch optimale Gewichte abgeleitet werden, mit denen einzelne Prognosemodelle in ein kombiniertes Modell einfließen.

In der Praxis wird – da die „wahren“ Fehler- und Schwankungswerte in der Regel unbekannt sind – oft mit Schätzungen gearbeitet. Hinzu kommt, dass es im Fall von Predictive Analytics immer darum geht, die Beziehungen zwischen Vorhersage- und Ergebnisdaten zu erfassen. Ohne diese beiden Arten von Daten kann kein Predictive-Analytics-Modell erstellt werden. Für Ergebnisdaten wird außerdem eine repräsentative Stichprobe der möglichen Ergebnisse benötigt. Für die Aufstellung eines Predictive-Analytics-Modells wird dann geprüft, wie die Vorhersage-Daten eingesetzt werden können, um die Ergebnisse möglichst genau vorherzusagen.

6. Predictive Forecasting kann Wert für Unternehmen schaffen

Während traditionelle Forecasts auf Basis menschlicher Expertise zwar nützlich für die interne Meinungsbildung sind, aber immer auch Verzerrungen, Fehlinterpretationen oder Irrtümern unterliegen können, erlaubt die automatisierte Generierung von Prognosen mittels Predictive Forecasting, den Anwendern in Controlling und Management unvoreingenommene Vorhersagen bereitzustellen, um ex post- oder what-if-Analysen und Szenariobetrachtungen zu fundieren. Die Nutzer können den automatisch generierten Forecast dann mit ihrer qualitativen Einschätzung über erwartete Entwicklungen, z. B. mögliche Sondereffekte oder Trendbrüche, vergleichen, auf diesem Weg Abweichungen oder Risiken schneller erkennen und sie erhalten so einen besseren Überblick über die Geschäftslage und anstehende Handlungsbedarfe.

Praktische Tests zeigen, dass Predictive Forecasting auch in einem schwierigen, weil sich dynamisch rasch verändernden, Umfeld in der Lage ist, mit einem breiten Set an prognostizierten Einflussgrößen wichtige Kennzahlen, wie beispielsweise den erwarteten Jahresumsatz des Unternehmens oder eines Geschäftsbereichs, frühzeitig und mit hoher Qualität vorherzusagen (vgl. hierzu auch Abschnitt 8 dieses Beitrags). Durch die beschleunigte Erstellung von Prognosen mittels Predictive Forecasting entstehen außerdem Zeitersparnisse, die es erlauben, auch rollierende Forecasts mit höherer Frequenz bzw. sogar kontinuierliches Forecasting zu etablieren.

Eine Herausforderung für die praktische Umsetzung des automatisierten Predictive Forecasting kann allerdings der Mangel an Vertrauen in derart maschinell generierte Ergebnisse sein (sogenannte *algorithm aversion*) – beispielsweise weil die verwen-

deten Prognosemodelle im Fall neuronaler KI bzw. bereits bei einfacheren Formen maschinellen Lernens für die Nutzer nicht hinreichend nachvollziehbar sind. Eine Möglichkeit, Vertrauen und Akzeptanz zu fördern, besteht dann darin, die Qualität bzw. Genauigkeit der Prognosen beispielsweise im Vergleich zu den später tatsächlich realisierten Istwerten transparent zu machen.

7. Digitalisierung der menschlichen Expertise

Perspektivisch sollte das Ziel von Predictive Forecasting darin bestehen, unternehmensinterne Prognoseprozesse komplett zu automatisieren, um für entscheidungs- und steuerungsrelevante Größen ein fortlaufendes Forecasting mit Echtzeit-Daten zu ermöglichen. Dies muss durch die Erfassung und Digitalisierung von menschlichem Fachwissen geleistet werden, d. h. das verwendete KI-System muss lernen, beispielsweise bezogen auf die Treibergrößen einer Umsatzvorhersage wie ein menschlicher Vertriebsplaner zu „denken“. Dieses Wissen wird dann mit zusätzlichen internen Daten des Unternehmens sowie externen Daten angereichert.

Die dafür erforderliche Modellentwicklung braucht Zeit, da der Einfluss verschiedener Eingangsinformationen, z. B. über Wettbewerber, Marktentwicklungen und Trends, in das Planungsmodell integriert werden müssen. Das volle Potenzial von Predictive Forecasting kann deshalb nur im Zusammenspiel von Data-Analytics- bzw. Data-Science-Experten und Controllern erreicht werden. Im Ergebnis müssen die Forecasting-Ergebnisse für die Nutzer verständlich und leicht anwendbar sein, ohne dass sie die Spezifika der einzelnen Modelle kennen oder für die Interpretation der Forecasts einen Data Scientist konsultieren müssen.

Sobald das Predictive Forecasting qualitativ hochwertige, automatisierte und idealerweise sogar rollierende oder kontinuierliche Forecasts für interessierende Bereiche liefern kann, hat das Controlling einen entscheidenden Schritt in Richtung digitaler Transformation der Führungsunterstützung getan. Führungskräfte wie Controller sind besser gerüstet, um Frühwarnsignale oder neue Chancen zu erkennen. Durch die Entlastung von den für das traditionelle Forecasting notwendigen Routinearbeiten wird Zeit z. B. für die Simulation zukünftiger Geschäftsentwicklungen frei, was Agilität und Reaktionsfähigkeit weiter erhöht. Auch bei der Vereinbarung von Zielen können automatisierte Prognosen verwendet werden, um beispielsweise einerseits im Falle günstiger Werte realistische und gleichzeitig ambitionierte Vorgaben zu formulieren, und andererseits bei ungünstigen Prognosen den Fokus auf die Entwicklung der erforderlichen Maßnahmen zu lenken, mit denen sich der Status Quo aus Unternehmens- oder Geschäftsbereichsperspektive verbessern lässt.

8. Praktische Integration von Predictive Forecasting in das Controlling

In vielen Unternehmen ist das Controlling durch die Anwendung digitaler Technologien zu einem wichtigen Motor für die Digitalisierung von unternehmensweiten Prozessen oder ganzen Geschäftsmodellen geworden. Typische Applikationen betreffen im Controlling das Berichtswesen durch den Einsatz von Self-Service-Dashboards, in denen sich Controller und Führungskräfte für ihre eigenen Bedarfe relevante Key Performance Indicator visualisieren lassen können. Hier bietet sich an, z. B. neben

traditionellen Informationen aus dem Monatsabschluss auch die Vorhersagen aus automatisierten Predictive Forecasts zu zeigen. Gerade bei zunehmender Volatilität und wachsender Wettbewerbsintensität im Unternehmensumfeld liegt der Vorteil derart erweiterter Dashboards darin, ein traditionell eher retrospektiv ausgerichtetes Reporting so zu verändern, dass Führungskräfte und Controller schneller und vor allem proaktiv auf sich verändernde Umweltbedingungen reagieren können.

Abbildung 10 zeigt schematisch zunächst, wie die in den vorangegangenen Abschnitten beschriebene Implementierung einer kontinuierlichen Modellierung bzw. Weiterentwicklung von Predictive Forecasts für diese Zwecke aussehen kann. Dabei geht es gerade nicht um die Etablierung eines neuen Prognoseprozesses, sondern vielmehr eine Verbesserung bestehender Prozesse, da Zeitreihen eingesetzt werden, die einer kontinuierlichen Logik folgen.




Abbildung 10: Schematischer Ablauf der Entwicklung von Predictive Forecasting-Modellen

Ausgangspunkt für die praktische Implementierung sind historische Daten aus mehreren zurückliegenden Zeitperioden für die interessierenden Prognosegrößen. Dabei können neben traditionellen Zeitreihen auch hybride Modelle oder *space state models* zum Einsatz kommen. Diese Daten umfassen sämtliche interessierende Prognosegrößen bzw. deren Treiber. Eine Vielzahl unterschiedlicher Algorithmen kann dann über Back-Testing-Verfahren auf ihre Prognosequalität hin evaluiert werden, um z. B. zu beantworten, wie gut auf Basis der länger zurückliegenden Vergangenheitsdaten ein bereits bekannter Ist-Wert vorhergesagt worden wäre.

Auf Basis dieser Evaluation kann im nächsten Schritt mit Hilfe eines sogenannten Meta Learners eine festgelegte Anzahl der statistisch besten Algorithmen selektiert werden. Wie bereits in Abschnitt 5 ausgeführt, ist zu erwarten, dass eine Kombination mehrerer leistungsfähiger Prognosemodelle auf Dauer zu robusteren Forecasts führt als die Verwendung nur eines Modells. Die Forecast-Werte setzen sich am Ende aus den mit Wahrscheinlichkeiten gewichteten Ergebnissen der ausgewählten Modelle zusammen.

Um bei den Führungskräften bzw. Controllern eine höhere Akzeptanz und auch ein besseres Verständnis für die vorhergesagten Größen zu erzielen, ist es sinnvoll, die bereitgestellten Forecast-Werte als Zeitreihen mit Informationen zu Trend bzw. saisonalen Einflüssen, aber auch einer Zufallskomponente („Rest“) aufzugliedern. Letztere unterstützt vor allem das Erkennen von einmaligen Ereignissen und Ausreißern. Praktische Tests in dieser Hinsicht ergeben, dass sich das beschriebene Vorgehen eignet, um automatisierte Predictive Forecasts zu erstellen, die traditionellen Forecasts auf rein menschlicher Expertise tatsächlich überlegen sind.

Abbildung 11 zeigt dies am Beispiel der Umsatzprognose. In diesem Versuch erwies sich der automatisierte Predictive Forecast im Vergleich zum traditionellen Forecast