

Effektiv und effizient steuern mit Predictive Analytics

Die Umsetzung der Planung und der Prognose bedeutet häufig einen hohen Zeit- und Ressourcenaufwand. Predictive Analytics bietet einen Stellhebel, die Prozesse deutlich zu verkürzen, Ressourcen zu schonen und gleichzeitig die Prognosequalität signifikant zu erhöhen. Ein Pilotprojekt der Bayer AG in Zusammenarbeit mit der Management-Beratung CTcon zeigt dies deutlich.

Lothar Burow, Yvonne Gerards, Matthias Demmer

Operative und strategische Planungs- und Prognoseprozesse sind in vielen Unternehmen ressourcenintensiv und komplex. Alleine im Controlling entfallen circa 32 Prozent der Tätigkeiten auf diesen Bereich (vergleiche Schäffer/Weber 2015). Aufwendige, unternehmenspolitisch gefärbte Abstimmungsrunden können sich über Monate ziehen und liefern am Ende oftmals nur scheingenaue Werte.

Eine Trendwende leitet hier derzeit Predictive Analytics ein. Grundlage dafür sind die durch die Digitalisierung explosionsartig wachsenden Datenmengen. Sie werden dazu verwendet, Muster, Strukturen und Trends mithilfe moderner statistischer Algorithmen zu finden und diese für die Prognose in der Unternehmenssteuerung zu nutzen. Predictive Analytics kann dabei nicht nur die Effizienz der Prozesse, sondern ebenso die Qualität der Planung erhöhen. Ein Projekt-Team, bestehend aus Mitarbeitern der Bayer AG und der Management-Beratung CTcon, hat im Rahmen eines Pilotprojekts analysiert, welche Möglichkeiten Predictive Analytics für unternehmensinterne Steuerungsprozesse der Bayer AG bietet.

Projektziel: Erste Ergebnisse in vier Wochen

Die Erschließung des enormen Potenzials der rasant fortschreitenden digitalen Transformation wird bei Bayer nicht nur im Bereich der Forschung, Entwicklung oder Produktion verfolgt, sondern ebenso in den administrativen und Service-Fachabteilungen des Konzerns. Der Bereich Corporate Business Intelligence verfolgt das Ziel, nutzbringende Anwendungen zu identifizieren und zur Verfügung zu stellen. Immer leistungsfähigere Instrumente sollen dazu beitragen, konzernweit die Informationsgrundlage der Entscheidungsträger im Unternehmen weiter zu verbessern. Die dafür notwendige Basis wurde über die letzten Jahre gelegt, indem Finanzdaten konzernweit durch das Projekt data.one harmonisiert und in einem Data Warehouse zusammengeführt wurden. Um die Möglichkeiten von Big Data zunehmend zu nutzen, wurden zudem neue Stellen mit neuen Profilen geschaffen, zum Beispiel für Data Scientists. Im Bereich „Controlling Operations“ der Bayer AG werden Controller bereits heute auf die daraus erwachsenden neuen Anforderungen vorbereitet.

„Die mit Predictive Analytics erstellten Kostenprognosen lagen im Pilotprojekt signifikant näher an den eingetretenen Ist-Werten als die Planwerte.“

Für die Potenzialanalyse von Predictive Analytics für die Bayer-Steuerung war es projektentscheidend, zeitnah Vorschläge für konkrete Anwendungsfälle zu generieren. Das Team wählte als ein erstes Untersuchungsobjekt den Forecast von Kostenstellen, da diese Prozesse besonders ressourcen- und zeitintensiv sind. Dementsprechend bot eine Unterstützung durch Predictive Analytics hier einen großen Stellhebel, um einerseits Aufwände zu reduzieren und um andererseits auf Basis objektiver statistischer Methoden neutrale Schätzwerte zu liefern.



Dr. Lothar Burow

ist Head of Corporate Business Intelligence bei der Bayer AG.



Yvonne Gerards

ist Principal bei CTcon Management Consultants.



Dr. Matthias Demmer

ist Projektleiter bei CTcon Management Consultants.

Lothar Burow
Bayer AG, Leverkusen, Deutschland
E-Mail: lothar.burow@bayer.com

Yvonne Gerards
CTcon Management Consultants, München, Deutschland
E-Mail: y.gerards@ctcon.de

Matthias Demmer
CTcon Management Consultants, München, Deutschland
E-Mail: m.demmer@ctcon.de

Die Digitalisierung und das exponentiell wachsende Datenaufkommen sind die Grundlage für Predictive Analytics.

Zusammenfassung

- Ein Pilotprojekt der Bayer AG in Zusammenarbeit mit der Management-Beratung CTcon hat gezeigt, wie Predictive Analytics die Planungseffizienz und -qualität erhöhen kann.
- Um die für Zeitreihenanalysen geeigneten Modelle auswählen zu können, wurde eine von CTcon konzipierte Model Factory eingesetzt. Sie kombiniert etablierte Analyse-Modelle mit modernen Machine-Learning-Algorithmen.
- Die Umsetzung einer Machbarkeitsstudie und der erste operative Einsatz einer Predictive-Analytics-Model Factory sind innerhalb von kurzer Zeit möglich und bilden die Grundlage für weitere Digitalisierungsinitiativen.

Mit einer agilen Projektsteuerung sollten Predictive-Analytics-Modelle zeitnah konzipiert und das Potenzial für den repräsentativen Datenausschnitt analysiert werden, um in einem zweiten Schritt die Modelle für weitere Untersuchungsobjekte sukzessive auszubauen. Das Projekt-Team hatte sich selbst den Meilenstein gesetzt, erste Ergebnisse und Einschätzungen innerhalb von vier Wochen zu liefern. Als Datengrundlage für den ersten Projektschritt dienten die monatlichen Kostendaten der letzten vier Jahre von rund 3.400 Kostenstellen eines ausgewählten Landes.

Konzeption von Predictive-Analytics-Modellen

Gegenstand von Predictive Analytics ist die Übertragung von quantitativ-statistischen Methoden in einen unternehmerischen Kontext. Der Begriff ist wissenschaftlich nicht einheitlich definiert. Das Gartner Institut charakterisiert Predictive Analytics wie folgt (vergleiche Gartner, Inc. 2017):

- Primäres Ziel ist die Generierung von Prognosen (keine deskriptiven Auswertungen).
- Zur Anwendung kommen hauptsächlich ergebnisorientierte, explorative Verfahren.
- Im Fokus steht die Erstellung von erfolgsrelevanten Prognosen im Unternehmenskontext.
- Die Methoden sollen im Zielzustand einem breiten Anwenderkreis zur Verfügung stehen.

Für eine schnelle und effiziente Entwicklung von agilen und anwendungsorientierten Predictive-Analytics-Modellen wurde im Projekt ein systematisches Verfahren verwendet, das sogenannte CRISP-DM-Modell (Cross Industry Standard Process for Data Mining, vergleiche Nabati/Thoben 2016). In einem kontinuierlichen Prozess werden die notwendigen Schritte des Daten-Managements und der Modellentwicklung sukzessive erarbeitet. Anstelle eines starren Projektplans, der eine chronologische Fertigstellung von Arbeitspaketen vorsieht, werden so komplexe Fragestellungen in überschaubarere Module zerlegt. Durch eine kontinuierliche Wiederholung dieser Module werden die Predictive-Analytics-Modelle iterativ verbessert.

Das Vorgehen umfasst folgende Schritte (vergleiche **Abbildung 1**):

1. **Business Understanding:** Zunächst wird ein Zielbild erarbeitet, das kontinuierlich geschärft wird. Im Mittelpunkt steht immer die Frage, wie Predictive Analytics Mehrwert in Forecast-Prozessen und im gesamtunternehmerischen Kontext liefern kann.
2. **Data Understanding:** Es folgen explorative und deskriptive Analysen relevanter Daten im Data Warehouse, um das Datenverständnis zur Lösung des vorliegenden Problems zu erhöhen.
3. **Data Preparation:** Die vorhandenen Daten werden aufbereitet und bereinigt. So entsteht eine solide und verlässliche Basis für die Predictive-Analytics-Modelle.
4. **Modeling:** Steht die Datenbasis, werden geeignete Predictive-Analytics-Modelle entwickelt, mit denen möglichst akkurate Prognosen berechnet werden können.

5. **Evaluation:** In der Evaluierungsphase wird die Schätzgüte der Modelle beurteilt. Wichtig hierbei ist, dass die Auswertung der Prognosegüte nicht nur mit einem Abgleich gegen die Ist-Werte erfolgt, sondern dass ein Benchmark für die Beurteilung gegenüber der bisherigen Methode herangezogen wird, beispielsweise manuell erstellte Planwerte.
6. **Deployment:** Wurde das konzipierte Predictive-Analytics-Modell positiv evaluiert, ist es bereit für die Anwendung im operativen Geschäft. Die Planung und Überwachung der Einführung sind hierbei die wichtigsten Prozessschritte.


Konstruktion einer Model Factory

Herausforderung bei der Prognose von echten Unternehmensdaten, wie etwa in diesem Fall Kostenverläufe, ist deren strukturelle Heterogenität. Materielle Kostenpositionen weisen oftmals stabile Strukturen, Muster und Kontinuitäten auf. Demgegenüber stehen kleinere Kostenpositionen, die teilweise auf den ersten Blick keinem klaren Muster folgen.

Die Strukturen der Zeitreihen beeinflussen die Wahl der Prognosemethodik, da statistische Verfahren unterschiedliche Anforderungen an die Datengrundlage stellen. Modelle, die beispielsweise auf die Erfassung von saisonalen Schwankungen ausgelegt sind, sind darauf angewiesen, dass die Daten einem solchen Zyklus folgen. Sind solche Schwankungen nicht

Financials werden in Predictive-Analytics-Modellen mit Non-Financials verknüpft.

Abb. 1 Projektvorgehen nach CRISP-DM



Quelle: Nabati/Thoben 2016

Die Model Factory der CTcon ermöglicht die schnelle Integration von Predictive Analytics in Planungs- und Prognoseprozesse.

vorhanden, könnten sich andere Modelle besser eignen. Ureigene Aufgabe des Statistikers ist es daher, das passende Modell für die jeweilige Zeitreihe zu wählen. Da die Anzahl und Heterogenität der Zeitreihen im Projektkontext sehr hoch waren, war eine automatisierte Modellauswahl für die Analyse unumgänglich. Das Projekt-Team hat hierfür eine sogenannte Model Factory konzipiert. Diese enthält eine Vielzahl unterschiedlicher Algorithmen aus der klassischen Zeitreihenanalyse sowie moderne Methoden aus dem Bereich des Machine Learnings (selbstlernende Modelle). Mithilfe der Model Factory wurde es möglich, für jede Zeitreihe automatisch eine möglichst passende Methodik auszuwählen, um die jeweilige Zeitreihe zu beschreiben und anschließend akkurat prognostizieren zu können.

Vereinfacht lässt sich das Vorgehen der Model Factory wie folgt beschreiben:

1. Zu Beginn wird die zu prognostizierende Datenreihe aus dem Enterprise-Resource-Planning-System (ERP-System) ausgewählt und abgefragt.
2. Daten werden automatisiert in die Model Factory geladen.
3. Innerhalb der Model Factory werden alle Predictive-Analytics-Modelle für die jeweilige Zeitreihe berechnet. Im sogenannten Modell-Training werden die unterschiedlichen Ausprägungen bestimmt, die jedes dieser Modelle für jede Zeitreihe aufweist (In-sample Training).
4. Rückwirkend wird die Passgenauigkeit jedes Modells für die jeweilige Zeitreihe evaluiert (Backtesting). Dafür werden bekannte Datenpunkte absichtlich von dem Modell-Training ausgeschlossen, um in einem fairen Abgleich die Genauigkeit der berechneten Prognosen mittels Vergleich mit dem Ist-Wert zu bestimmen (Out-of-sample Backtest).
5. Abschließend werden die Modelle nach ihrer Prognosegüte ausgewertet. Das beste Modell (Champion-Verfahren) beziehungsweise eine Kombination aus den besten Modellen (Ensemble) wird für die Prognose verwendet.

Die vorgestellte Methodik sowie der große Fortschritt in der Hard- und Software-Technik ermöglichen die Bearbeitung rechenintensiver Prozesse auch für große Datenmengen. In dem Pilotprojekt wurde für die Umsetzung der Model Factory die statistische Programmiersprache R verwendet. Als Open-Source-Software ermöglicht R die Verwendung modernster Methoden und Erkenntnisse und bietet ein hohes Maß an Anpassungsfähigkeit. Dank der hohen Kompatibilität von R kann die Model Factory schnell in die bestehende IT-Landschaft integriert werden.

Was kann Predictive Analytics leisten?

Durch die bereits erfolgte konzernweite Harmonisierung der Finanzdaten bei der Bayer AG war der Aufwand für die Datenaufbereitung in dem Pilotprojekt deutlich reduziert. Um einen realistischen Forecast-Prozess zu simulieren, wurden die Daten ohne weitere Bereinigungen, wie zum Beispiel Ausschluss von Ausreißern oder extrem volatilen Zeitreihen, in die Untersuchung aufgenommen.

Die Basis für die Bewertung der Prognosegüte von Predictive Analytics wurde durch einen fairen Abgleich mit den Plan- und Ist-Werten aus vergangenen Perioden gewährleistet. Die einzelnen Kostenstellen wurden in ei-

nem Bottom-up-Verfahren prognostiziert und anschließend summiert. Dabei stellte sich heraus, dass die mit Predictive Analytics erstellten Kostenprognosen signifikant näher an den eingetretenen Ist-Werten lagen als die Planwerte: Während die Planwerte der Kostenstellen mit insgesamt 13 Prozent Überschätzung auffällig konservativ prognostiziert wurden, wiesen die Predictive-Analytics-Prognosen insgesamt nur eine Überschätzung von rund drei Prozent auf. Eine mögliche Erklärung für das bessere Abschneiden der Predictive-Analytics-Prognosen kann zum Beispiel darin begründet sein, dass in der Kostenplanung keine Puffer eingebaut werden, wodurch das sogenannte „Sandbagging“ unterbleibt (vergleiche **Abbildung 2**).


Die Box-Plot-Darstellung in **Abbildung 3** zeigt anhand der Auswertung der Prognosefehler für unterschiedliche Modelle, dass die Genauigkeit der Prognosemodelle ungleich verteilt ist. Es ist festzuhalten, dass moderne Machine-Learning-Methoden durchschnittlich bessere Prognosen abgeben als klassische Modelle der Zeitreihenanalyse. Die besten Verfahren sind die robusten Champion- und Ensemble-Modelle, welche auf Basis aller anderen Modelle eine intelligente Auswahl der jeweils heranzuziehenden Prognosewerte treffen.

Weitergehende Analysen bestätigen, dass eine Differenzierung der Modellauswahl für unterschiedliche Zeitreihenarten nutzbringend ist. Insbesondere bei Datenreihen, die über einen stochastischen Charakter verfügen und wenig Struktur aufweisen, ist das Hinzuziehen moderner Algorithmen vorteilhaft.

Das Projekt hat gezeigt, dass der Einsatz von Predictive Analytics zu einer signifikanten Verbesserung der Steuerung führen kann, insbesondere in der Unternehmensplanung und Vorschau. Folgende Vorteile sind hervorzuheben:

Die Rolle des Controllers in der operativen Geschäftssteuerung wird gestärkt.


Abb. 2 Vergleich der Gesamtkostenprognose von Plan/Predictive gegenüber Ist-Werten



Quelle: eigene Darstellung

1. **Verbesserung der Prognosequalität:** Durch den Einsatz einer Model Factory konnte eine höhere Prognosegüte realisiert werden als mit traditionellen, manuellen Planungsprozessen. Predictive-Analytics-Modelle identifizieren Muster, Trends und Strukturen in Daten, welche für akkuratere Prognosen herangezogen werden können. In Summe liefert Predictive Analytics eine objektive und unternehmensweit uniforme Basis für Planungs- und Prognoseprozesse.
2. **Steigerung der Effizienz:** Predictive Analytics zieht durch die Automatisierung von Planungs- und Prognoseprozessen eine Reduzierung des Aufwands nach sich. Wo sich früher ressourcenintensive Planungs- und Prognoserunden noch über Monate erstreckt haben, benötigt eine Model Factory deutlich weniger Zeit. Auch damit erhöht sich die Prognosegüte, da die zugrunde liegenden Prognoseannahmen zeitlich viel enger mit dem Planungszeitpunkt zusammenfallen, als dies bei einem mehrmonatigen Prozess der Fall wäre. Stellt man die einmaligen Aufwände der Konzeption der Model Factory gegen jene bisheriger Planungsrounden, kann transparent abgeschätzt werden, wie schnell sich die Projektausgaben amortisieren.
3. **Erhöhung der Prognosefrequenz:** Durch die beschriebene Effizienzsteigerung eröffnen sich durch den Einsatz von Predictive Analytics neue

Abb. 3 Verteilung von Prognosefehlern in unterschiedlichen Modellen



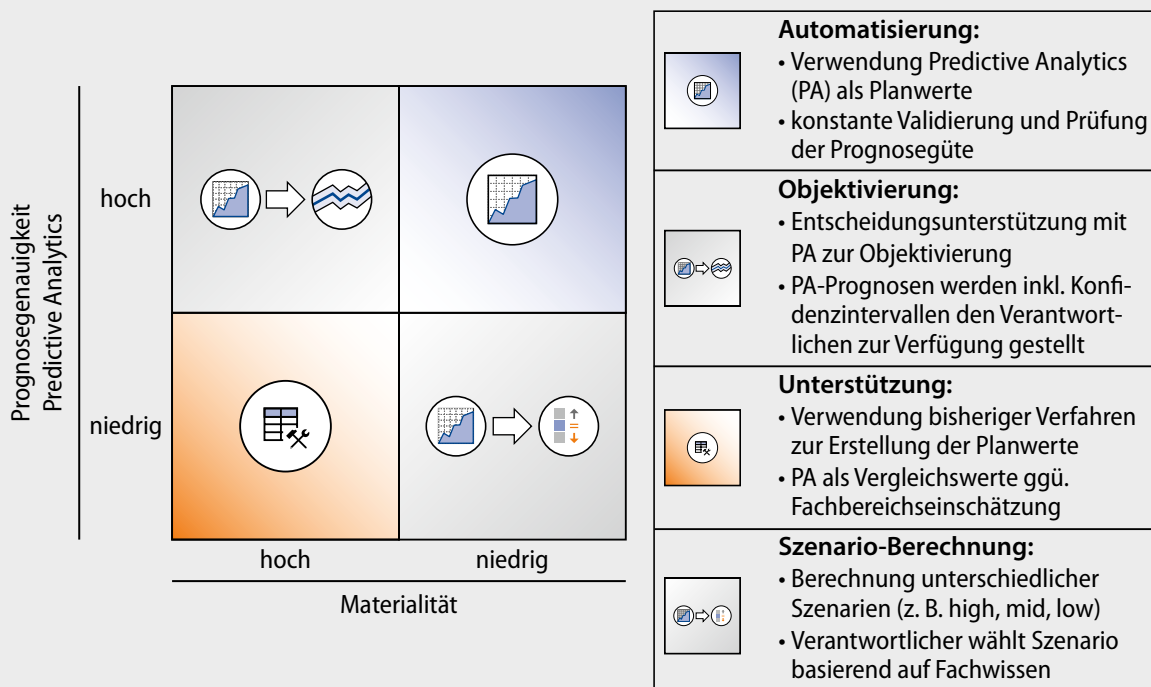
Quelle: eigene Darstellung

Einsatzmöglichkeiten mit neuen Steuerungsimpulsen. Durch die Verkürzung der Prognoseintervalle können Prognosen mittels Predictive Analytics monatlich auf die aktuelle Geschäftsentwicklung angepasst werden. Dafür muss die Model Factory auf Basis der hinzugewonnenen Informationen ihre Einschätzungen einfach erneut kalkulieren. Somit können die Jahresendprognosen sowie die rollierende Zwölf-Monats-Vorschau monatlich oder in noch kürzeren Intervallen die im unternehmerischen Umfeld veränderten Parameter aufnehmen und Prognosen entsprechend aktualisieren. Damit entstehen eine dynamisch-adaptive Realtime-Planung und Prognose.

Don't plan what you can predict

Auf Grundlage der Projektergebnisse hat das Projekt-Team einen Vorschlag erarbeitet, wie Predictive Analytics als Steuerungsinstrument in Planungs- und Prognoseprozesse integriert werden kann (vergleiche **Abbildung 4**): Für Zeitreihen mit geringer Materialität und sehr guter Predictive-Analytics-Prognosegüte empfiehlt sich eine weitgehende Automatisierung der Planung. Bei großer Materialität sowie niedrigerer Prognosegüte von Predictive Analytics können die automatisch generierten Werte als Vergleichsbasis oder Ausgangspunkt für die weitere Planung genutzt werden.

Abb. 4 Integration von Predictive Analytics in die Unternehmenssteuerung



Quelle: eigene Darstellung

Handlungsempfehlungen

- Führen Sie eine Machbarkeitsstudie mit einem klar definierten Ziel durch, um das Potenzial von Predictive Analytics mit echten Unternehmensdaten initial zu quantifizieren.
- Der Pilot sollte häufig auftretende Problemstellungen aufgreifen, wie zum Beispiel die Erstellung von Jahresendprognosen, und somit fachlich und prozessual repräsentativ sein.
- Vergleichen Sie die Ergebnisse von Predictive Analytics gegen Planwerte bestehender Verfahren, um Transparenz und Akzeptanz der neuen Methodik zu erzeugen.
- Gehen Sie aktiv auf Fachbereiche zu, um Predictive Analytics methodisch zu erläutern und mögliche Einsatzszenarien gemeinsam zu diskutieren.

Eine weitere Ausbaustufe für den Einsatz von Predictive Analytics ist zum Beispiel die zusätzliche Berücksichtigung von externen Daten, wie zum Beispiel makroökonomische Parameter, Rohstoffpreise oder Wettbewerbsinformationen. Insbesondere Machine-Learning-Modelle sind geeignet, eine Vielzahl an Informationen gleichzeitig zu verarbeiten und für ihre Prognosen zu verwenden. Somit können die meist auf unternehmensinternen Daten basierenden Planungs- und Prognoseprozesse um externe Faktoren angereicht werden, um die Prognosequalität zusätzlich zu erhöhen. Im Zuge dessen wird ebenso ermöglicht, Ursache-Wirkung-Zusammenhänge akkurat zu identifizieren. Diese Zusammenhänge können sowohl unternehmensintern (zum Beispiel zeitlicher Versatz: Kosten A treiben Kosten B im Folgemonat) als auch eine Verbindung zwischen externen und internen Faktoren (beispielsweise Einfluss Rohstoff A auf Kostenposition B) sein.

Durch die Verbindung von Financials mit Non-Financials, also durch das Hinzuziehen weiterer steuerungsrelevanter Informationen, können Controller die Möglichkeit nutzen, stärker in die operative Geschäftssteuerung vorzudringen und damit ihre Rolle als Business-Partner zu stärken. Zuletzt kann festgestellt werden, dass Predictive Analytics leicht auf andere Fachbereiche außerhalb des Controllings übertragen werden kann. Somit ist zu erwarten, dass die Potenzialerschließung von Predictive Analytics gerade erst begonnen hat und der Einfluss auf Unternehmenssteuerung rasant wachsen wird.

Literatur

Gartner Inc. (2017): Gartner IT Glossary: Predictive Analytics, <http://gtnr.it/2dmgUDQ> (letzter Abruf: 01.08.2017).

↓* Gholamzadeh Nabati, E./Thoben K. (2016): On Applicability of Big Data Analytics in the Closed-Loop Product Lifecycle: Integration of CRISP-DM Standard, in: Harik R. et al. (eds): Product Lifecycle Management for Digital Transformation of Industries. Proceedings of the 13th International Conference on Product Lifecycle Management (PLM). IFIP Advances in Information and Communication Technology, Vol. 492, Cham, S. 457-467.

www.springerprofessional.de/link/12140838

Schäffer, U./Weber, J. (2015): Controlling – Trends & Benchmarks, Vallendar.

* Abonnenten von Springer Professional haben kostenfrei Zugriff.



Weitere Empfehlungen der Verlagsredaktion aus www.springerprofessional.de zu:

Predictive Analytics

Schäffer, U. (2017): „Predictive Analytics macht Planung und Steuerung flexibler“ – Jörg Ehlken im Dialog mit Utz Schäffer, in: Controlling & Management Review, 61 (4), S. 34-40.
www.springerprofessional.de/link/12268762

Schön, D. (2016): Planung und Reporting – Grundlagen, Business Intelligence, Mobile BI und Big-Data-Analytics, Wiesbaden.
www.springerprofessional.de/link/4329876