

# Eine Prognose ist (noch) kein Plan

## Operative Planung in Zeiten von Predictive Analytics



Prof. Dr. **Robert Rieg** ist Professor für Controlling und Interne Unternehmensrechnung sowie Prodekan für Forschung an der Fakultät Wirtschaftswissenschaften der Hochschule Aalen. E-Mail: robert.rieg@hs-aalen.de

Predictive Analytics verspricht die Automatisierung von Prognosen und Planung. Der vorliegende Beitrag zeigt, welche Anforderungen dafür erfüllt sein müssten. Dabei ist weniger die schiere Datenmenge relevant, sondern ein Verständnis der Wirkungszusammenhänge, die hinter den Daten liegen. Weiterhin darf nicht vergessen werden, dass Planung auch andere Zwecke erfüllt als nur die Prognose.

**Robert Rieg**

### 1. Planungspraxis: Einwertige Planung und das Streben nach Planungsgenauigkeit

In der Unternehmenspraxis dominiert die sog. einwertige Planung, d. h., es wird ein einziger Planwert definiert und das trotz des Wissens um die hohe Unsicherheit in der Zukunft (vgl. *Behringer/Gleißner*, 2018). Dieser eine Planwert wird dann als Prognose interpretiert und mit der Realität verglichen, wobei mehr oder weniger unausgesprochen davon ausgegangen wird, dass eine „perfekte“ Prognose möglich sein muss. Empirische Studien zur Genauigkeit von Plänen und Prognosen liefern jedoch ein eher ernüchterndes Bild (vgl. **Abb. 1**).

Auch angesichts der typischen menschlichen Schwierigkeiten bei Prognosen und Planaufstellungen (vgl. bereits *Hogarth/Makridakis*, 1981) schlagen manche als Ausweg daher Predictive Analytics und maschinelles Lernen vor, mit Aussagen wie „Durch Big Data und Predictive Analytics werden

aus granularen Daten automatisiert Forecasts generiert, die eine höhere Treffsicherheit als traditionelle Vorhersagen haben“ (*Kieninger et al.*, 2016, S. 245). Versprechen nicht solche Methoden einen günstigen Weg zu genauen Prognosen und damit genauen Plänen? Der folgende Beitrag zeigt, dass eine „automatisierte Planung“ sich großen Hürden gegenüber sieht und das aus vier Gründen:

- Daten liegen nicht einfach so vor, sie müssen aufwändig und zweckabhängig aufbereitet werden;
- maschinelles Lernen und Analytics benötigen oft sehr große Datenmengen, die bei einer operativen Planung meist nicht vorliegen dürften;
- Prognosen benötigen ein operationales Planungsmodell, nicht nur eine Anhäufung von Variablen mit statistischen Assoziationen;
- die Zukunft ist nicht die Vergangenheit und Planung erschöpft sich nicht in der Prognose.

Ausgangspunkt dabei ist die Grundstruktur eines Planungs- und Prognosemodells (vgl. **Abb. 2**). Pro-

Studie	Methodik und Datengrundlage	Forschungsfrage	Wesentliche Erkenntnisse
<i>McCarthy/Davis/Golicic/Mentzer</i> , 2006	Eigene Befragung und Auswertung früherer Studien	Entwicklung der Verwendung von Prognoseinstrumenten sowie der Prognosegenauigkeit	Abnehmende Prognosegenauigkeit im Zeitablauf
<i>Pellens/Lehmann</i> , 2012	Analyse von Archivdaten Umsatz-, Ergebnisprognosen in Geschäfts- und Quartalsberichten HDAX 2006-2010	Prognosegenauigkeit von Management im Vergleich mit Finanzanalysten	Meist Unterschätzung der tatsächlichen Entwicklung, hohe Streuung der Schätzfehler, Finanzanalysten werden durch Managementprognosen beeinflusst.
<i>Rieg</i> , 2010	Analyse von Archivdaten Absatzprognosen eines Automobilherstellers 1991-2005	Prognosegenauigkeit im Zeitablauf	Oft hohe zweistellige Abweichungen, kaum Verbesserungen der Prognosegenauigkeit

**Abb. 1: Ausgewählte empirische Studien zur Prognosegenauigkeit von Unternehmen**

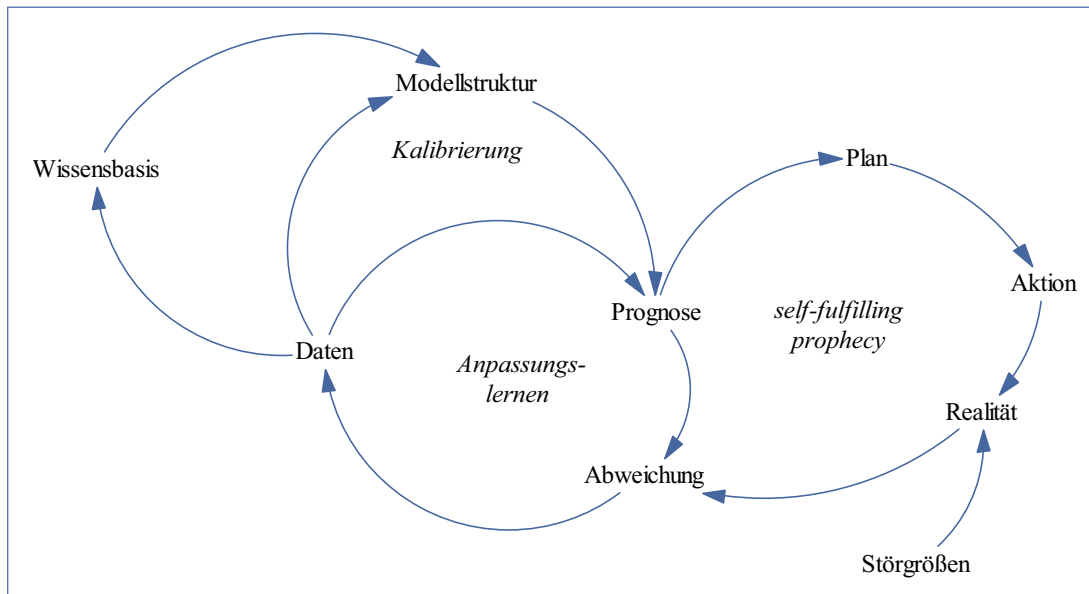


Abb. 2: Grundzusammenhang Modell, Prognose und Planung

gnosen entstehen aus Daten (bisherigen, sowie Einschätzungen) und einem dahinterliegenden Modell, sei es explizit wie in einem Software-Algorithmus oder implizit als mentales Modell. Die Prognose kann zu einem Plan führen, der – umgesetzt – die Realität verändert. Die Abweichung zwischen Prognose und Realität ist der Ausgangspunkt des Lernprozesses der im Zeitablauf sowohl die Modellstruktur als auch die künftigen Prognosen so ändert, dass die Abweichung möglichst klein wird. Modelle benötigen darüber hinaus eine Wissensbasis, aus der heraus sie aufgebaut werden. Stochastisch sind solche Modelle, da viele Größen mit Unsicherheit behaftet sind.

## 2. Daten als Basis für Entscheidungen

Viel wird über „Daten als das neue Öl“ geschrieben. Daten seien dabei eine Ressource wie etwa Rohstoffe und Mitarbeiter (so bspw. Otto/Legner, 2016, S. 551). Dabei dürfte im Grunde klar sein, dass es keine Daten oder Informationen an sich gibt, die es einfach zu sammeln und auszuwerten gilt (vgl. Olhede/Rodrigues, 2017). Daten und Informationen gibt es nur aufgrund einer vorab existierenden Vorstellung und einem Zweck (vgl. bereits ausführlich Steinmüller, 1993, S. 198 ff.). Ohne einen klaren Zweck kann nicht entschieden werden, welche Daten benötigt werden, um eine entsprechende Prognose durchzuführen. Man müsste „alles“ sammeln, dokumentieren, verifizieren und speichern. So ist das, was unter „Umsatz“ fällt, nicht einfach fix gegeben, was schon an den ausführlichen und sich ändernden Regelungen zur Rechnungslegung, wie bspw. IFRS 15, ersichtlich ist. Nicht zuletzt deshalb hat sich eine Reihe von Beiträgen in dieser Zeitschrift mit Datenqualität beschäftigt. Das Datenmanagement wird auch von der Praxis als eines der Top-Themen der Controlling-

Zukunft angesehen (vgl. Schäffer/Weber, 2018, S. 43). Der Fokus liegt dabei auf der Bereinigung von Daten. Die Gefahr bei diesem Vorgehen ist es, nicht nach dem Zweck zu fragen.

So sollte jedoch für eine Umsatzprognose der dahinterliegende Prozess verstanden werden, der zum Umsatz führt (data generating process). Es sollte also eine operationale Vorstellung davon bestehen, wie und wodurch Umsatz generiert wird. Mit anderen Worten, neben dem Zweck wird auch ein Modell benötigt, bevor mit der Definition, Suche, Aufbereitung sowie Auswertung von Daten begonnen werden kann.

Die Auswahl und Qualität der Daten hat darüber hinaus teils subtile Wirkungen auf die Modellergebnisse und über diesen Weg auf die Realität im Sinne einer self-fulfilling prophecy. Predictive Analytics basiert zunächst einmal auf der Analyse von Mustern von Ist-Daten und der Fortschreibung in die Zukunft. Für eine Umsatzprognose bedeutet dies, dass bspw. anhand der Daten über vorhandene Kunden deren künftige Käufe vorhergesagt werden, unter der Voraussetzung, dass sich wesentliche Eigenschaften und Strukturmerkmale nicht ändern. Da aus der Prognose regelmäßig Pläne entstehen, die wieder Ziele und Vorgaben für Mitarbeiter bilden, richten sich die Ressourcen des Unternehmens nicht zu Unrecht auf bestehende Kundenbeziehungen. Was der Algorithmus nicht „sehen“ kann ist, dass es auch neue Kunden geben kann. Wird jedoch dem eben genannten Algorithmus gefolgt, wären dafür keine Ziele und Ressourcen vorhanden. Ebenso kann nicht aus denjenigen Interessenten gelernt werden, die nicht zu Kunden geworden sind, da sie nicht im Kundenstamm sind. Solche Verzerrungen durch die unumgängliche Entscheidung über die Datenauswahl sind gut bekannt und treffen auch Prognose- und Planungsmodelle in Unternehmen (vgl. Lazer et al., 2014).

**Daten existieren nicht einfach so. Ihre Nützlichkeit und Aussagekraft hängen von davorliegenden Zwecken ab.**

### Zentrale Aussagen

- Maschinelle Prognosen sind möglich, erfordern jedoch ein operationales Prognosemodell, ausreichend viele und qualitativ gute Daten sowie eine stabile Umwelt.
- Kein Prognose- und Planungsmodell kann die Unsicherheit der Zukunft eliminieren. Unsicherheit ist vielmehr Voraussetzung für künftigen Erfolg.
- Planung ist Zukunftsgestaltung und damit mehr als die Fortschreibung der Vergangenheit. Sie dient auch der Koordination, Motivation und Verhaltenssteuerung

Zunehmende Datenmengen gehen oft mit abnehmendem Zusatznutzen einher.

### 3. Datenbedarf für maschinelle Prognosen und Pläne

Die modernen Verfahren der Predictive Analytics arbeiten mit statistischen Verfahren unter Unsicherheit und benötigen für ihre Schlussfolgerungen eine ausreichende Datenmenge. Betrachtet man zum Beispiel den eigenen Kundenstamm als Grundgesamtheit und möchte für diesen eine aus Statistiken abgeleitete Prognose herleiten, so lässt sich die Frage beantworten, wie groß die Stichprobe mindestens sein sollte, um eine bestimmte Genauigkeit zu erhalten. **Abb. 3** zeigt, dass bei hoher gewünschter Präzision und kleiner Grundgesamtheit fast alle Daten der Grundgesamtheit einbezogen werden müssten. Bei sehr großen Grundgesamtheiten nimmt der zusätzliche Nutzen von Daten ab, wie an den relativen Anteilen zu sehen ist. Kurz gefasst: „bigger is not always better in Big Data“.

Die Berechnung in **Abb. 3** berücksichtigt nicht, dass bei Predictive Analytics oft Wirkungszusammenhänge von Variablen betrachtet werden: so mögen die Verkaufsanstrengung und die Konkurrenzsituation den Umsatz beeinflussen. Werden solche Variablen in ein Modell aufgenommen, müssen bei der Ermittlung der mindestens benötigten Datenmenge weitere Faktoren beachtet werden. Dazu zählen (vgl. *Eid et al.*, 2011, S. 199 ff.):

A) Die erwartete Effektstärke zwischen den Variablen: Eine Effektstärke ist in statistischen Analy-

sen bspw. die Korrelation zweier Variablen. Korrelationsanalysen werden auch bei Big Data-Anwendungen sehr häufig verwendet. Empirische Studien liefern meist nur niedrige Korrelationskoeffizienten von etwa +/- 0,2 (vgl. *Ellis*, 2010, S. 77 m. w. N.). Es gibt keinen Grund anzunehmen, dass diese Effekte größer werden. Eher ist es realistisch, anzunehmen, dass in immer größeren Datenmengen eher kleinere Effekte zu finden sind (vgl. *Apgar*, 2015). Kleinere Effekte benötigen generell mehr Daten.

B) Das Signifikanzniveau  $\alpha$  als Maß für den Stichprobenfehler (identisch mit der Präzision in **Abb. 3**): Wie dort ersichtlich, benötigen präzisere Messungen auch mehr Daten.

C) Die Streuung der Daten in der Grundgesamtheit: Unmittelbar einleuchtend ist auch der Einfluss der Streuung auf die statistische Schlussfolgerung: Je höher die Streuung, desto mehr Daten sind nötig, um aus „noise“ ein „signal“ zu erhalten.

D) Die erwartete Teststärke (power) als Wahrscheinlichkeit, einen Effekt zu finden, sofern er existiert: Die erwartete Teststärke ist eine zentrale Größe für die Beurteilung der Aussagekraft einer Analyse: wenn die Wahrscheinlichkeit gering ist, einen Effekt zu finden, sind auf jeden Fall viele replizierende Analysen nötig, um sich sicherer zu sein, dass etwas gefunden wurde. Bedauerlicherweise ist die Teststärke vieler Studien oft nur auf dem Niveau eines Münzwurfs oder noch geringer (vgl. *Ellis*, 2010, S. 47 ff.).

E) Die Zuverlässigkeit der Messung der Daten (Reliabilität): Werden wichtige Größen nur ungenau gemessen, was die Regel sein dürfte, steigt der Datenbedarf weiter an.

F) Das verwendete statistische Verfahren mit der Zahl und Messkala der Variablen: Es leuchtet ein, dass komplexere statistische Verfahren, die mehr Variablen und mehr Annahmen über Verteilungen verwenden, auch mehr Daten benötigen.

Die Zusammenhänge können an zwei extremen Szenarien dargestellt werden: Operative Planung

Grundgesamtheit	Benötigter Stichprobenumfang bei		in % der Grundgesamtheit	
	95% Präzision	99% Präzision	95% Präzision	99% Präzision
10	10	10	100%	100%
50	44	50	88%	100%
100	80	99	80%	99%
150	108	149	72%	99%
200	132	198	66%	99%
250	152	246	61%	98%
500	217	485	43%	97%
1.000	278	943	28%	94%
10.000	370	6239	4%	62%
100.000	383	14227	0,38%	14%
1.000.000	384	16317	0,04%	2%

Annahmen: Chi<sup>2</sup>-Verteilung, Freiheitsgrad=1, p=0,5

**Abb. 3: Stichprobenumfang als Funktion von Grundgesamtheit und Präzision (Krejcie/Morgan, 1970)**

## SCHWERPUNKT

und Prognose mit (1) wenigen Variablen und (2) auf Basis sehr großer Datenmengen.

Zu (1): Viele Unternehmen verwenden aggregierte Daten für die operative Prognose und Planung, so etwa Gesamtabsatzzahlen eines Markts oder gesamte Verwaltungskosten. Damit begrenzt sich die vorhandene Datenmenge oft auf eine nur zweistellige Anzahl. Es leuchtet ein, dass damit eine hohe Unsicherheit bei der Schätzung und Prognose von Kenngrößen einhergeht. Die Teststärke wird deutlich unter 50 % liegen, d. h., aus den Daten tatsächliche Zusammenhänge ableiten zu können, ist dann sehr zufällig: Findet man einen Zusammenhang kann man nicht sicher sein, dass er existiert. Findet man keinen, kann man nicht sicher sein, dass er nicht existiert. Insofern ist es eher nicht angeraten, bei wenigen Daten komplexe statistische Verfahren anzuwenden, um eine „automatisierte“ Prognose zu erstellen.

Zu (2): Die typische „Big Data“-Situation ist es, sehr viele Daten zur Verfügung zu haben, oft auch aus verschiedenen Quellen. Mit genügend Daten lassen sich auch kleinste Effekte finden. Wenn bspw. mehr als 100.000 Datensätze vorhanden sind, werden auch Korrelationskoeffizienten von 0,01 in den Daten gefunden, die aber praktisch keine Bedeutung haben und reine Zufallserscheinungen sein können (vgl. Apgar, 2015). **Abb. 3** zeigt, dass es einen abnehmenden Grenznutzen von zusätzlichen Daten gibt. Eine Umsatzprognose auf Basis aller Kundendaten und historischen Geschäftsvorfälle eines Großunternehmens wäre technisch kein Problem (vgl. bspw. Satzger et al., 2015, S. 231 ff.), nur dürfte der Nutzen mit zunehmendem Datenvolumen immer geringer werden. Die zusätzliche Prognosegenauigkeit einer Prognose auf Basis von Millionen Daten gegenüber einer solchen mit wenigen Hundert oder Tausend Daten ist vermutlich minimal. Nicht zuletzt, da sich viele Er-

### Implikationen für die Praxis

- Für die Unternehmensplanung ist es wichtig, sich zunächst über die Planungszwecke Gedanken zu machen, erst dann über Methoden und Datenbedarf.
- Prognose- und Planungsmodelle sollten die sachlogischen Wirkungszusammenhänge abbilden, die aus einer ökonomischen Sicht hergeleitet sind (operationale Modelle).
- Mit der Datenmenge nimmt der Grenznutzen eher ab. Daher sollte sich der Fokus stärker auf die Datenqualität als auf die schiere Anzahl richten.
- Die Unsicherheit und Unbestimmtheit der Zukunft kann ein stochastisches Modell nicht eliminieren. Es ist sinnvoll, in der Prognose und Planung Szenarien und Bandbreiten zu verwenden, um besser vorbereitet zu sein und die Zukunft zu gestalten.

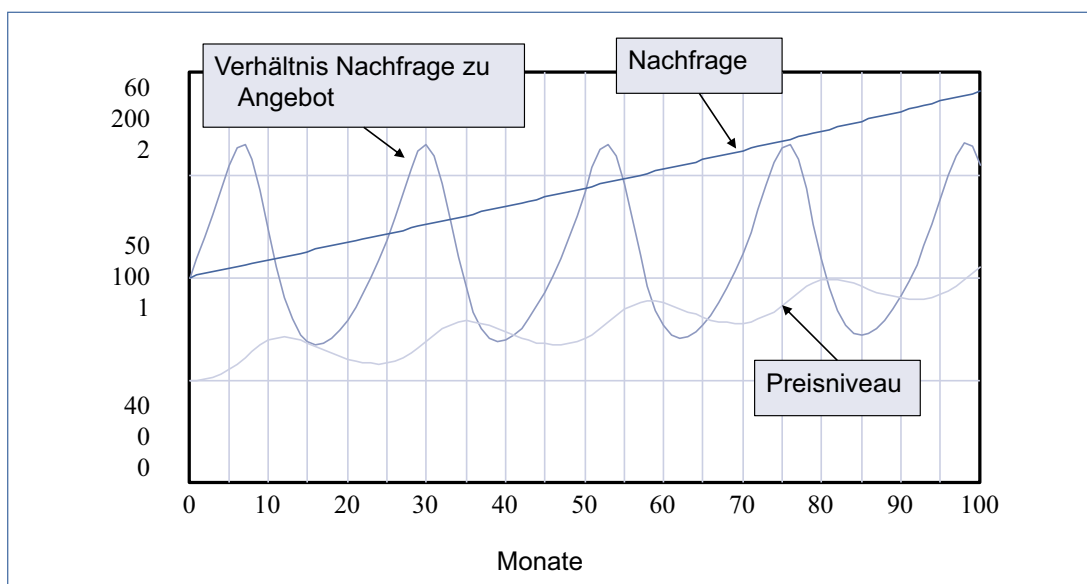
eignisse der Vergangenheit, die sich in diesen großen Datenmengen widerspiegeln, so nicht wiederholen werden.

## 4. Modellaufbau

Ein Prognose- und Planungsmodell ermittelt aus Eingangsgrößen eine Vorhersage. Welche Eingangsgrößen sollen in ein solches Modell aufgenommen werden? Hier bietet sich natürlich an, vorhandene Ist-Daten zu nehmen und diese fortzuschreiben, also bspw. eine Extrapolation von Zeitreihen (vgl. Seiter, 2017, S. 147 ff.). Dieses Vorgehen berücksichtigt jedoch meist nicht die Gründe für die Datenentstehung und die Wechselwirkungen zwischen Variablen. Ein einfaches Beispiel dient hier zur Veranschaulichung. Die Zeitreihe von Nachfrage und Preisen in **Abb. 4** zeigt einen typischen, wenn auch idealisierten Verlauf.

Im ersten Moment mag man hier an eine Fortschreibung der Daten denken. Das würde aber nicht erklären, wie die Daten entstehen, und es würde angenommen, dass hier ein deterministisches Modell vorläge. Wird die Entstehung der Daten genauer betrachtet, ist das typische Verhalten des sog. „Schweinezyklus“ zu erkennen (vgl. Glö-

**Daten allein zeigen nicht, wie ein Planungsmodell aussehen sollte.**



**Abb. 4: Beispiel Zeitreihe Preise, Nachfragemengen und relatives Verhältnis**



beschreibt eine systematische Abweichung der Vorhersagen von den Ist-Daten, „variance“ die Streuung der Vorhersagen um den Mittelwert (vgl. einfürend *Katsikopoulos/Syntetos*, 2016). Der Grund liegt in der Überbetonung einzelner Ereignisse, die sich so nicht in der Zukunft wiederholen werden. Mithin darf die Prognosegenauigkeit nicht anhand derselben Daten getestet werden, mit denen das Modell kalibriert wurde (in-sample test), sondern anhand neuer Daten (out-of-sample test).

Hier kommt hinzu, dass maschinelle Prognosen aufgrund ihres deterministischen Ansatzes nicht Ereignisse und Entscheidungen der Zukunft berücksichtigen. Beides sind aber Merkmale der Planung, die mehr umfasst als nur die Prognose.

## 6. Planung ist mehr als nur Prognose

Die Zukunft eines Unternehmens ist nicht die Fortschreibung der Vergangenheit, also nicht deterministisch, wie es die Verfahren der Predictive Analytics annehmen. Entscheidungen werden getroffen und bisher nicht bekannte Ereignisse treten auf, die alle die Zukunft verändern.

Hinzukommt, dass neben der Prognose weitere, wichtige Planungszwecke existieren: die Koordination im Unternehmen ebenso wie die Motivation und das Setzen von Anreizen. Das hat aber weniger mit einer punktgenauen Prognose zu tun, als mit der Vorgabe einer bestimmten Zielrichtung sowie mit Verantwortung und Aufgaben. Gerade anspruchsvolle Ziele (stretch goals) sind eben nicht identisch mit einer Hochrechnung aus der Vergangenheit in die Zukunft. Planung ist daher „Zukunftsgestaltung“ (vgl. *Horváth et al.*, 2015, S. 68).

Vor allem ein operationales Planungsmodell (analog zur [Abb. 5](#)) erlaubt es, Szenarien zu integrieren, die Wechselwirkungen der Sachlogik der Planung beachten und nicht nur statistische Zusammenhänge. In obigem Fall wäre es bspw. möglich, die Fluktuationen zu verringern, indem weniger sensitiv auf Nachfrage-Angebotsveränderungen reagiert und bei Neuinvestitionen die Kapazität im Aufbau beachtet wird.

## 7. Zukunft der operativen Planung im Zeitalter von Predictive Analytics

Statistische Verfahren helfen im Allgemeinen Prognosen zu verbessern. Wenn die Diskussion um Predictive Analytics die Aufmerksamkeit stärker auf diese Methoden lenkt, ist das hilfreich für die Praxis. Dafür werden jedoch nicht zwingend sehr große Datenmengen benötigt, da deren Grenznutzen mit der Datenmenge abnimmt. Auch erfordert der Einsatz statistischer Methoden einiges an Vorüberlegungen und Erfahrungen wie Beispiele in dieser Zeitschrift zeigen (vgl. *Satzger et al.*, 2015; *Möller et al.*, 2016) Statistische Prognosen funk-

nieren weniger gut, wenn hohe Volatilität und Unsicherheit herrscht. Hier bieten sich dann andere Methoden an, so etwa Umfragen und Prognosemärkte (vgl. *Becker et al.*, 2013).

Ein Geschäftsmodell und damit auch die Planung werden jedoch nicht allein dadurch verstanden, dass immer mehr Daten gesammelt und statistisch ausgewertet werden, sondern indem die ökonomischen Prinzipien hinter dem Geschäftsmodell und den Wettbewerbsvorteilen verstanden und genutzt (vgl. bspw. *Besanko et al.*, 2015) werden. Darüber hinaus sollte verstanden werden, dass Pläne auch andere Zwecke als die Prognose erfüllen und daher nicht „genau“ sein müssen.

## Literatur

- *Apgar, D.*, The False Promise of Big Data: Can Data Mining Replace Hypothesis-Driven Learning in the Identification of Predictive Performance Metrics?, in: *Systems Research and Behavioral Science*, 32. Jg. (2015), H. 1, S. 28–49.
- *Becker, B./Rieg, R./Schoder, R.*, Verbesserung von Unternehmensprognosen mit Prognosemärkten am Beispiel Lufthansa Cargo AG, in: *Controlling*, 25. Jg. (2013), H. 2, S. 115–120.
- *Behringer, S./Gleißner, W.*, Die Unternehmensplanung als Grundlage für die Unternehmensbewertung: Eine empirische Studie, in: *Die Wirtschaftsprüfung* (2018), H. 5, S. 312–319.
- *Besanko, D./Dranove, D./Shanley, M./Schaefer, S.*, *Economics of strategy*, 7. Auflage, Hoboken, NJ 2015.
- *Eid, M./Gollwitzer, M./Schmitt, M.*, *Statistik und Forschungsmethoden*, 2. Auflage, Weinheim, Basel 2011.
- *Ellis, P.*, *The Essential Guide to Effect Sizes: Statistical Power, Meta-Analysis, and the Interpretation of Research Results*, Cambridge et al. 2010.
- *Glöser-Chahoud, S./Hartwig, J./Wheat, I.D./Faulstich, M.*, The cobweb theorem and delays in adjusting supply in metals' markets, in: *System Dynamics Review*, 32. Jg. (2016), H. 3–4, S. 279–308.
- *Hogarth, R. M./Makridakis, S.*, Forecasting and Planning: An evaluation, in: *Management Science*, 27. Jg. (1981), H. 2, S. 115–138.
- *Horváth, P./Gleich, R./Seiter, M.*, *Controlling*, 13. Auflage, München 2015.
- *Katsikopoulos, K. V./Syntetos, A.*, Bias-Variance Trade-offs in Demand Forecasting, in: *Foresight*, o. Jg. (2016), H. 40, S. 12–19.
- *Kieninger, M./Mehanna, W./Vocelka, A.*, Wie Big Data das Controlling verändert, in: *Controlling* 28. Jg. (2016), H. 4–5, S. 241–247.
- *Krejcie, R. V./Morgan D. W.*, Determining sample size for research activities, in: *Educational and Psychological Measurement* 30. Jg. (1970), S. 607–610.

**Prognosen sind nicht der einzige und nicht immer der wichtigste Planungszweck.**

- *Lazer, D./Kennedy, R./King, G./Vespigniani, A.*, Big data. The parable of Google Flu: traps in big data analysis, in: *Science*, 343. Jg. (2014), H. 6176, S. 1203–1205.
- *McCarthy, T./Davis, D./Golicic, S./Mentzer, J.*: The evolution of sales forecasting management: a 20-year longitudinal study of forecasting practices, in: *Journal of Forecasting*, 25. Jg. (2006), H. 5, S. 303–324.
- *McKinney Jr., E./Yoos, C./Snead, K.*, The need for ‘skeptical’ accountants in the era of Big Data, in: *Journal of Accounting Education*, 38. Jg. (2017), H. 1, S. 63–80.
- *Möller, K./Federmann, F./Pieper, S./Knezevic, M.*, Predictive Analytics zur kurzfristigen Umsatzprognose, in: *Controlling*, 28. Jg. (2016), H. 8–9, S. 509–518.
- *Olaya, C.*, Cows, agency, and the significance of operational thinking, in: *System Dynamics Review*, 31. Jg. (2015), H. 4, S. 183–219.
- *Olhede, S./Rodrigues, R.*, Why data is not a commodity, in: *Significance* 14. Jg. (2017), H. 5, S. 10–11.
- *Otto, B./Legner, C.*, Datenqualitätsmanagement für den Industriebetrieb: Best Practices und Implikationen für die Digitalisierung, in: *Controlling*, 28. Jg. (2016), H. 10, S. 550–557.
- *Pellens, B./Lehmann, K.*: Managementprognosen und Analystenschätzungen – Eine deskriptive Analyse auf Basis der HDAX-Unternehmen, in: *Zeitschrift für betriebswirtschaftliche Forschung*, 64. Jg. (2012), H. 8, S. 873–892.
- *Rieg, R.*: Do forecasts improve over time? A case study of the accuracy of sales forecasting at a German car manufacturer, in: *International Journal of Accounting and Information Management*, 18. Jg. (2010), H. 3, S. 220–236.
- *Satzger, G./Holtmann, C./Peter, S.*, Advanced Analytics im Controlling – Potenzial und Anwendung für Umsatz- und Kostenprognosen, in: *Controlling*, 27. Jg. (2015), H. 5, S. 229–235.
- *Schäffer, U./Weber, J.*, Digitalisierung ante portas : Die Veränderung des Controllings im Spiegel der dritten WHU-Zukunftsstudie, in: *Controlling*, 30. Jg. (2018), H. 1, S. 42–48.
- *Seiter, M.*, *Business Analytics*, München 2017.
- *Steinmüller, W.*, *Informationstechnologie und Gesellschaft : Einführung in die Angewandte Informatik*, Darmstadt 1993.

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

- Klaus Möller, Frank Federmann, Svenja Pieper und Michael Knezevic, Predictive Analytics zur kurzfristigen Umsatzprognose – Entwicklung eines Prognosemodells auf Basis von Auftrags-eingängen bei der Infineon Technologies AG, Ausgabe 08–09/2016, S. 509–518.
- Henning Baars, Predictive Analytics in der IT-basierten Entscheidungsunterstützung – methodische, architektonische und organisatorische Konsequenzen, Ausgabe 03/2016, S. 174–180.
- Maximilian Stichter, Predictive Analytics, Ausgabe 10/2013, S. 573–574.

#### Stichwörter

# datengenerierender Prozess # Operative Planung # Planungszwecke # predictive analytics # stochastisches Modell

#### Keywords

# Data Generating Process # Operational Planning # Planning Purposes # Predictive Analytics # Stochastic Models

#### Summary

Predictive analytics promises to automate forecasting and planning. This article shows that it is not the volume of data that is most relevant, but an operational model of the data generating process. Furthermore, firms should be aware that forecasting is not the only purpose of planning.