



Advanced Analytics im Controlling

Simulation und Maschinelles Lernen

von Karsten Oehler

Advanced Analytics im Controlling – es tut sich einiges. In diesem Teil zwei der dreiteiligen Serie sollen die Chancen, aber auch die Herausforderungen für verschiedene Anwendungsfelder im Controlling, nämlich Planung, Forecasting und Simulation thematisiert werden.

Im ersten Teil wurde ich auf die Möglichkeiten des Einsatzes maschinellen Lernens im Forecasting eingegangen. Im zweiten Teil geht es nun darum, die Wirkungen maschinellen Lernens auf ein für den Controller zunehmend wichtiger werdendes Werkzeug zu skizzieren: die Simulation. Auswirkungen externer Ereignisse (aktuelles Stichwort Trumpsche Strafzölle), eigene Entscheidungen und hieraus resultierende Maßnahmen sollten in ihren möglichen Wirkungen verstanden werden. Dabei kann

man auf die Erkenntnisse aus einem auf maschinellem Lernen (ML) basierten Forecasting aufsetzen. Die Werkzeuge Forecasting und Simulation sind eng verzahnt: Auf der Suche nach einem möglichst akkuraten Forecast sind Wirkungsbeziehungen und damit Einflussfaktoren zu betrachten. Hat man ein entsprechendes Prognosemodell aufgebaut, ist es nur ein kleiner Schritt zur gedanklichen Veränderung der Antezedenz, um die Konsequenz greifbar zu machen – das ist Simulation.

Simulation vs Optimierung

Professor Stahlknecht schrieb allerdings in einem Buch im Jahr 1970 etwas despektierlich: „Wenn man nicht mehr weiter kann, fängt man

zu simulieren an.“⁴¹ Das ist zwar nicht gerade anspruchsvolle Poesie, drückt aber aus, dass die Optimierung der Simulation überlegen sei. Dies ist vom theoretischen Anspruch heraus auch nachvollziehbar. Dennoch verhindern schon geringe Komplexität und Dynamik den Einsatz von Optimierungsrechnungen.

In der Praxis hat sich die Simulation gegenüber der Optimierung durchgesetzt. Managen kann man auch als Balancieren unterschiedlicher Interessen auffassen. Dazu muss aber verstanden worden sein, wie zu balancieren ist. Es ist wie „im Zirkus“: Ohne ein Gefühl für Schwerkraft und den eigenen Körper ist auch das Balancieren auf einem Drahtseil in großer Höhe ein riskantes Unterfangen.

Es stellt sich die Frage, was eine gute Simulation ausmacht. „Schlechte“ Simulationen skizzieren zwar eine mögliche zukünftige Entwicklung, zeichnen sich aber durch geringe Realitätsnähe aus. Fehlentscheidungen werden wahrscheinlicher. Als Beispiel sei eine einfache Simulation auf der Basis einer Gewinn- und Verlustrechnung dargestellt: Man variiert Umsatz und betrachtet die Konsequenzen auf den Jahresüberschuss. Die Veränderung dieses Jahresüberschusses ergibt sich über Verdichtungen und enthält ausschließlich sogenanntes Apriori-Wissen, welches unabhängig von der Wirklichkeit gültig ist. Der Mehrwert einer solchen Simulation ist begrenzt.

„Das Erkennen von belastbaren Wirkungszusammenhängen ist der Grundstoff einer guten Simulation.“

Eine (mögliche) Wirkung der Umsatzveränderung auf Kosten bezieht hingegen empirisch gehaltvolle Beziehungen mit ein. Interessant wird es auch bei den Treibern des Umsatzes, der schließlich nicht vom Himmel fällt. Beispielsweise könnten Marketingaufwendungen, Rabattprogramme usw. den Umsatz (aber auch die Kosten) verändern. Wenn die Wirkungsbeziehungen bekannt sind, lässt sich nun auch der Umsatz steuern.

Mit solchen Erweiterungen kann die Realitätsnähe von Simulationen gesteigert werden. Ein wichtiges Werkzeug hierzu kann maschinelles

Lernen sein. Das Erkennen von belastbaren Wirkungszusammenhängen ist der Grundstoff einer guten Simulation. Das Herausarbeiten von Wirkungsbeziehungen ist das grundlegende Ziel aller maschinellen Ansätze. Allerdings müssen diese Werkzeuge (maschinelles Lernen und Simulation) zusammenpassen, was eine konzeptionelle Herausforderung darstellt.

Diese Kopplungsnotwendigkeit teilt die Simulation mit der Vorschaurechnung. Die Vorschaurechnung kann zudem als Startpunkt einer Simulation dienen. Die Treiber, die bei der Prognose verwendet werden, können auch zur Simulation herangezogen werden.

Dies alles klingt plausibel, dennoch ist der Einsatz maschinellen Lernens als Grundlage der Simulation alles andere als einfach. Simulationen im Rahmen des Controllings sind vielschichtig. Um die vollständigen Wirkungen einer Maßnahme oder eines Projekts deutlich zu machen, müssen häufig Unternehmensgesamtmodelle herangezogen werden. Der Fokus von maschinellem Lernen liegt aber hingegen in der Regel auf der Einzelbetrachtung. Daher sind umfassende Transformationen bei der Kopplung vorzunehmen.

Grundlagen der Simulation

Der Controller als „Lotse“ der Unternehmensführung kann vom Einsatz der Simulation in vielerlei Hinsicht profitieren. Entscheidungsunterstützung und Simulation sind eng verbunden. Willensbildung setzt letztendlich voraus, sich der potentiellen Wirkung von Entscheidungen bewusst zu sein. Da man allerdings häufig nicht auf Ergebnisse realer Experimente zurückgreifen kann, bietet sich die Simulation an. Kritische Situationen können so frühzeitig erkannt und Maßnahmen entwickelt werden.

Bei der Simulation soll ein Realitätsausschnitt abgebildet werden, um mögliche zukünftige Entwicklungen durchspielen und hieraus Konsequenzen des eigenen oder fremden Handelns erkennen zu können. Dazu benötigt man:

- Ein Modell, das aus Wirkungsbeziehungen besteht. Wenn beispielsweise der Preis steigt, kann dies einen negativen Effekt auf den Absatz haben. Dies ist zunächst nur eine

Hypothese, wenn auch eine plausible, die hinsichtlich ihrer Stärke permanent infrage gestellt werden kann. Von Bedeutung sind zudem definitorische Beziehungen. Diese dienen der Verdichtung zur besseren Verständlichkeit. So ist die Abhängigkeit des Deckungsbeitrags zum Umsatz definitorischer Natur, denn Deckungsbeitrag ist letztendlich nur eine sprachliche Vereinfachung von Umsatz abzüglich variabler Kosten. Ein Simulationsmodell sollte zumindest einige empirische Beziehungen enthalten. Die Beziehungen sollten in mathematischen Formeln abbildbar sein, was bei Definitionsgleichungen unproblematisch ist. Allerdings sind empirische Wirkungen häufig nicht genau bekannt und damit nicht mathematisch formulierbar. Die Wirkung von Kundenzufriedenheit auf den Umsatz oder aber auch die Preis-Absatz-Funktion sind typische Beispiele. Es ergibt sich im Rahmen von Simulationen folglich häufig eine Sequenz von Automatisierung und manueller Anpassung. Aus der Parameterveränderung ergeben sich Konsequenzen, beispielsweise hinsichtlich einer Finanzierungsnotwendigkeit. Diese Entscheidung ist aber quasi als erneute Parameterveränderung in das Simulationsmodell einzugeben.

„Der Controller als ‚Lotse‘ der Unternehmensführung kann vom Einsatz der Simulation in vielerlei Hinsicht profitieren.“

- Das Ergebnis dieser Berechnungen stellen Zielgrößen dar. Das Ergebnis oder der Zahlungsüberschuss sind häufige Zielgrößen im Controlling.
- Es werden Eingabeparameter benötigt. Dies sind die Drehschrauben, die zur Veränderung der Zielgrößen führen. Parameterbündel können zu Szenarien zusammengeführt werden. Ausgangsgrößen bei den Parametern können durch Erwartungsrechnungen bestimmt werden.

Aus diesem Grundmodell können dann verschiedene „Spielarten“ abgeleitet werden:

- Wenn ein oder mehrere Parameter verändert werden und die Wirkung auf die Zielgrößen betrachtet wird, wird dies als „Was wäre wenn“-Simulation („What-If“) bezeichnet.

Dies ist ein häufiger Einstiegspunkt in die Simulation.

- Man kann auch die Auswertungsrichtung umdrehen und gelangt so zur Zielwertsuche. „Wie hoch muss der Absatz sein, um ein bestimmtes Ergebnis zu erreichen?“ Die Möglichkeit der Umkehrung ist eingeschränkt, da in der Regel nur eine einfache Parameteranpassung erfolgt. Preis und Absatz in der Rückrechnung einer Umsatzsteigerung sind beispielsweise nicht ohne weitere Annahmen gleichzeitig anpassbar.
- Über die Veränderung eines oder mehrerer Eingabeparameter kommt man zur Sensitivitätsanalyse. Damit kann das Bewusstsein über die Stärke von Wirkungsbeziehungen verbessert werden. Insbesondere bei nicht-linearen Beziehungen und bei einer hohen Vernetzung fällt die Wirkungsabschätzung naturgemäß schwer. Wie stark wirken sich beispielsweise Währungsschwankungen auf das Ergebnis aus?
- Und schließlich kann man Eingabeparameter durch Verteilungsfunktionen ersetzen. Dies wird häufig im Risikomanagement vorgenommen, wobei natürlich primär die negativen Ausschläge betrachtet werden. Häufig bezieht man auch Abhängigkeiten zwischen den Modellparametern in die Simulation mit ein. Durch die Simulation kann man die Unsicherheit der Zielgrößen ermitteln. Hier kommt in der Regel eine Monte-Carlo-Simulation zum Einsatz, da so am einfachsten Risiken aggregiert werden können.

Diese Klassifikation ist nicht disjunkt. So lässt sich eine Monte-Carlo-Simulation auch als „was wäre wenn“-Simulation ausführen. Die [Abbildung 1](#) zeigt diese Zusammenhänge noch mal auf.

Maschinelles Lernen und Simulation

Auf die Grundlagen des maschinellen Lernens (CML) ist im ersten Teil schon kurz eingegangen worden. Die Modellierungstechnik steht im Beitrag nicht im Vordergrund, sondern die Anwendung. In Kürze: Statt „Wenn-dann“-Regeln zu programmieren, kann ein ML-Algorithmus Zusammenhänge selbst erkennen und dann das Regelwerk dynamisch über neue Daten erweitern.

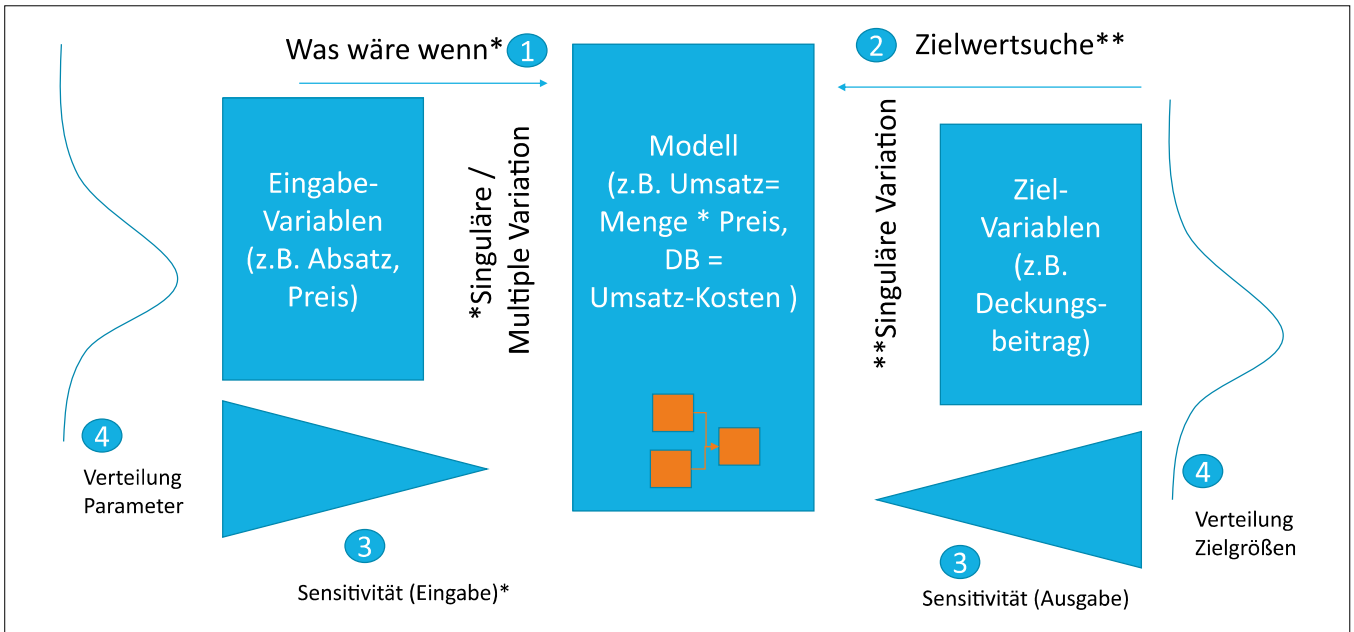


Abb. 1: „Spielarten“ der Simulation

An welchen Stellen kann nun konkret maschinelles Lernen in der Simulation eingesetzt werden?

- Simulation benötigt, wie dargelegt, empirisch fundierte Wenn-Dann-Regeln. Diese werden benötigt, um Zielgrößen ableiten zu können. Der wichtigste Einsatz maschinellen Lernens dürfte daher die Ableitung möglichst realistischer Wirkungsketten sein. Als Grundlage der Simulation eignet sich das überwachte Lernen. Aus den Erkenntnissen populärer Modelle wie beispielsweise Abwanderungsanalysen, Sales Pipeline Analysen oder Predictive Maintenance können Wirkungsbeziehungen abgeleitet und in Simulationsmodelle integriert werden. Aus den Zusammenhängen zwischen Kundenattributen und Kaufentscheidung werden beispielsweise bei der Pipeline-Analyse Thesen bezüglich Ursache und Wirkung abgeleitet. So könnten bestimmte Altersgruppen vergleichsweise besonders entscheidungsfreudig sein. Die Wirkungen von Maßnahmen zur Bewerbung dieser Altersgruppe könnte somit besser eingeschätzt werden.
- Mittels maschinellem Lernen ergibt sich die Möglichkeit der Modellerweiterung. Im Rahmen von Treiberbaumsimulationen stellt sich häufig die Frage, wie komplexere Abhängigkeiten jenseits der finanziellen Größen modelliert werden können. Die relativ einfache hierarchische Strukturierung „klassischer“ Treiberbäume bietet zwar den Vorteil einer guten Übersichtlichkeit. Dies hat aber die

Einschränkung, durch zu starke Vereinfachung nur bedingt realitätsnah zu sein. Viele Treiber entwickeln einen Wirkungsfächer, der durch eine Baumstruktur nur unzureichend repräsentiert werden kann. Währungseffekte sind beispielsweise äußerst vielfältig, da sie auf allen Märkten des Unternehmens Auswirkungen haben können. Dies widerspricht einer streng hierarchischen Struktur.

- Gleichermaßen benötigt die Simulation plausible Ausgangsdatengrößen der Parameter. Auch diese können über maschinelles Lernen erzeugt werden, wie bereits in den Ausführungen zum Forecasting skizziert wurde. Wenn etwa die DSOs (Days of Sales Outstanding, Forderungsreichweite) als Grundlage einer Erfolgs- und Finanzsimulation verwendet werden, kann maschinelles Lernen hier helfen, diesen Eingabeparameter realistisch zu schätzen. Dies kann klassisch mittels einfacher Statistik erfolgen, „nach welcher Zeit haben Kundengruppen in der Vergangenheit gezahlt?“ Interessanter wird es jedoch, wenn kundenspezifisches Zahlungsverhalten, auch unter Einbezug der individuellen wirtschaftlichen Situation, antizipiert werden kann. Dies schließt auch die potentielle Zahlungsunfähigkeit mit ein.
- Bei einer Modellverdichtung kann unüberwachtes Lernen zum Einsatz kommen. Die Bildung von homogenen Gruppen wie beispielsweise Kunden mit einer gewissen Kaufstärke, die gleiches Kaufverhalten zei-

gen, ist ein typisches Beispiel für eine dynamische Strukturanpassung. Auch Wirkungsbeziehungen können verdichtet werden. Einschränkung ist allerdings, dass das Ergebnis gegebenenfalls eine abstrakte Gruppe² darstellt, die zwar homogen ist, aber zu abstrakt für eine Interpretation von Wirkungszusammenhängen ist.

- Im Zusammenhang mit spieltheoretischen Überlegungen könnte man auch das verstärkende Lernen (Reinforcement Learning) berücksichtigen. Vergleichbar einem Schachspiel könnte das Verhalten der Marktteilnehmer antizipiert werden und somit Reaktion und Gegenreaktion durchgespielt werden. Nur ist das Verhalten der Marktteilnehmer im realen Leben deutlich heterogener als bei einem Schachspiel. Auch die Zielfunktion ist komplexer. Insofern besteht hier noch wenig Realitätsnähe.

Simulation auch ohne Wirkungsmodellierung?

Die Erstellung komplexer Simulationsmodelle ist in der Regel aufwendig und wird durch den Einbezug maschinellen Lernens auch nicht einfacher. Es stellt sich daher die Frage, ob sich maschinelles Lernen nicht auch direkt unter Umgehung der dargestellten Wirkungsmodellierung für eine Simulation eignet. Ein einfaches Modell, welches lernt und dann auf neue Daten angewendet wird, stellt grundsätzlich auch die

Möglichkeit bereit, zu simulieren, indem neue Daten im Sinne von Eingabeparametern generiert werden. Man betrachtet nur noch die Inputvariablen und das ML-Modellergebnis. Bei einfachen Simulationsmodellen dürfte das praktikabel sein.

Ein Beispiel: Bei der Betrachtung einer Vertriebspipeline könnten als wesentliche Treiber Besuchsfrequenz und Rabatte identifiziert worden sein. Wenn dann eine Simulation über die aktuelle Pipeline durchgeführt werden soll, können die entsprechenden Maßnahmen im Rahmen einer Simulation direkt mittels ML-Modell durchgespielt werden. Fragestellungen, wie sich beispielsweise eine zweiprozentige Rabatt-erhöhung auf den Vertriebs-erfolg auswirkt oder welche Auswirkungen die Erhöhung der Besuchsfrequenz auf die Kaufentscheidung haben könnten, ließen sich damit beantworten.

Aber das Beispiel skizziert nur eine vereinfachte Simulation. Wenn die Erfolgs- und Liquiditätskonsequenzen von Maßnahmen deutlich werden sollen, sind umfassendere Betrachtungen notwendig. Welche weiteren Konsequenzen ergeben sich aus einer Auftragsannahme? Sind vielleicht sprungfixe Kosten oder Engpässe zu betrachten? Welche Zahlungswirkungen sind zu betrachten? Dies betrifft Erfolg und Liquidität. Ergo ist das Einbinden in eine umfassende Rechnung notwendig. Auch dies könnte rein theoretisch über ein ML-Modell mit dem EBIT als Zielvariabler erstellt werden. Allerdings wird dann ein solches Modell zu einer Blackbox, da Wirkungsbeziehungen stark verdichtet werden. Zudem schwächt sich durch die vielfältigen Einflüsse die Identifizierbarkeit einzelner Beziehungen ab. Auch ist auf dieser Ebene schwer entscheidbar, ob es sich nicht unter Umständen um Modellanomalien wie beispielsweise Scheinkorrelationen handelt.

Mehr Transparenz durch „handgefertigte“ Simulationsmodelle

In Bezug auf die Transparenz haben „handgefertigte“ Simulationsmodelle mit der Ergänzung von ML-Komponenten einen Vorteil. Insofern ist für eine Kopplung zwischen maschinellem Lernen und Simulation zu plädieren. Klassische

Simulationsmethoden haben sich bewährt und sind entsprechend um maschinellen Methoden zu erweitern.

Allerdings ist eine Transformation notwendig. Dies ist zum einen technischer Natur (siehe Abschnitt zur Umsetzung). Es sind auch konzeptionelle Hürden zu überwinden. Wie auch schon beim Forecasting dargestellt, haben die ML-Modelle in der Regel andere, operative Aufgaben und werden nicht originär für die Simulation entwickelt. Es muss zudem eine Transformation von Korrelationen in vermutete Kausalitäten vorgenommen werden. Hierbei ist Vorsicht geboten. Da häufig mit niedriger Signifikanz potentieller Wirkungsbeziehungen gearbeitet wird, sind Einflussstärken hinsichtlich der Plausibilität zu hinterfragen.

Ein konzeptionelles Problem ist die mögliche Abstraktionsdifferenz zwischen dem ML-Modell und der Simulation. Das Controlling arbeitet bei der Simulation wie auch im Forecasting meistens auf periodisierten Daten. Die ML-Modelle benötigen, wenn sie wirkungsvoll sein sollen, Detaildaten, also möglichst einzelne Transaktionen. Eine Ausnahme stellen ML-unterstützte Zeitreihenanalysen dar. Hier ist eine Kopplung einfacher.

Die Ergebnisse eines ML-Modells stellen häufig Auswertungen in der Form „Kunde xy kauft mit x% Wahrscheinlichkeit“, dar. Die Simulation enthält hingegen nur Aggregationen wie beispielsweise Kundengruppen. Somit müssen die einzelnen Ergebnis-Datensätze auf eine Kundengruppe transformiert werden. Kundengruppen sind unter Umständen selbst Einflussgrößen für die Entscheidung.

Wenn beispielsweise durch eine Marketinginitiative die Anzahl Kundengruppe um erwartete 10% gesteigert werden soll, muss sich diese

Änderung in den ML- Eingabedaten widerspiegeln. Bei den Eingabedaten kann es sich um grundsätzliche neue Daten oder um additive Daten einer aktuellen Pipeline handeln.

Im Beispiel der Abbildung 2 folgt eine Rabattanpassung für eine Kundengruppe. Dies wird auf verschiedene Industriekunden angewendet, indem die Einzelrabatte angepasst werden. Hieraus können die relevanten Kundendatensätze adjustiert werden. Eine Interferenz gibt das veränderte Kaufverhalten zurück. Falls der Entscheidungshorizont höher als die Pipelinefrequenz ist, müssen neue Einträge, die einen plausiblen Forecast darstellen, generiert werden.

Allerdings gelten einige Einschränkungen:

- Für die Berechnung der Simulation ergibt sich die Besonderheit, dass aus der Simulation heraus die ML-Interferenz gestartet werden muss. Solche Kalkulationen sind lauffeiertkritisch, insbesondere bei einer Monte-Carlo-Simulation. Insofern wäre es sinnvoll, die Kalkulation nicht „überbrücken“ zu müssen. Eine Regeltransformation zur Übernahme in die Simulationskalkulation wäre angemessen. Bei modernen ML-Methoden ist dies allerdings unrealistisch, da sich die ermittelten Abhängigkeiten kaum in Formeln beschreiben lassen, die von Simulationswerkzeugen verarbeitet werden.
- Die Verfahren des maschinellen Lernens werden immer selbstständiger, allerdings leider dadurch auch intransparent. Während ein klassisches Entscheidungsbaumverfahren einfach zu integrierende Regeln liefert, ist das bei neuronalen Netzen, Sampling- oder Boosting-Verfahren nicht mehr der Fall. Zwar können die Ergebnisse des ML-Modells integriert werden. Die konkreten Wirkungsbeziehungen lassen sich jedoch kaum noch isoliert betrachten.

Autor



■ Prof. Dr. Karsten Oehler

ist Professor für Controlling an der Provdavis Hochschule Frankfurt und Solution Architect und Domain Expert für Advanced Analytics bei CCH Tagetik in Unterschleißheim. Er beschäftigt sich seit vielen Jahren mit der Ausgestaltung von Informationssystemen im Controlling.

E-Mail: karsten_oebler@yahoo.de

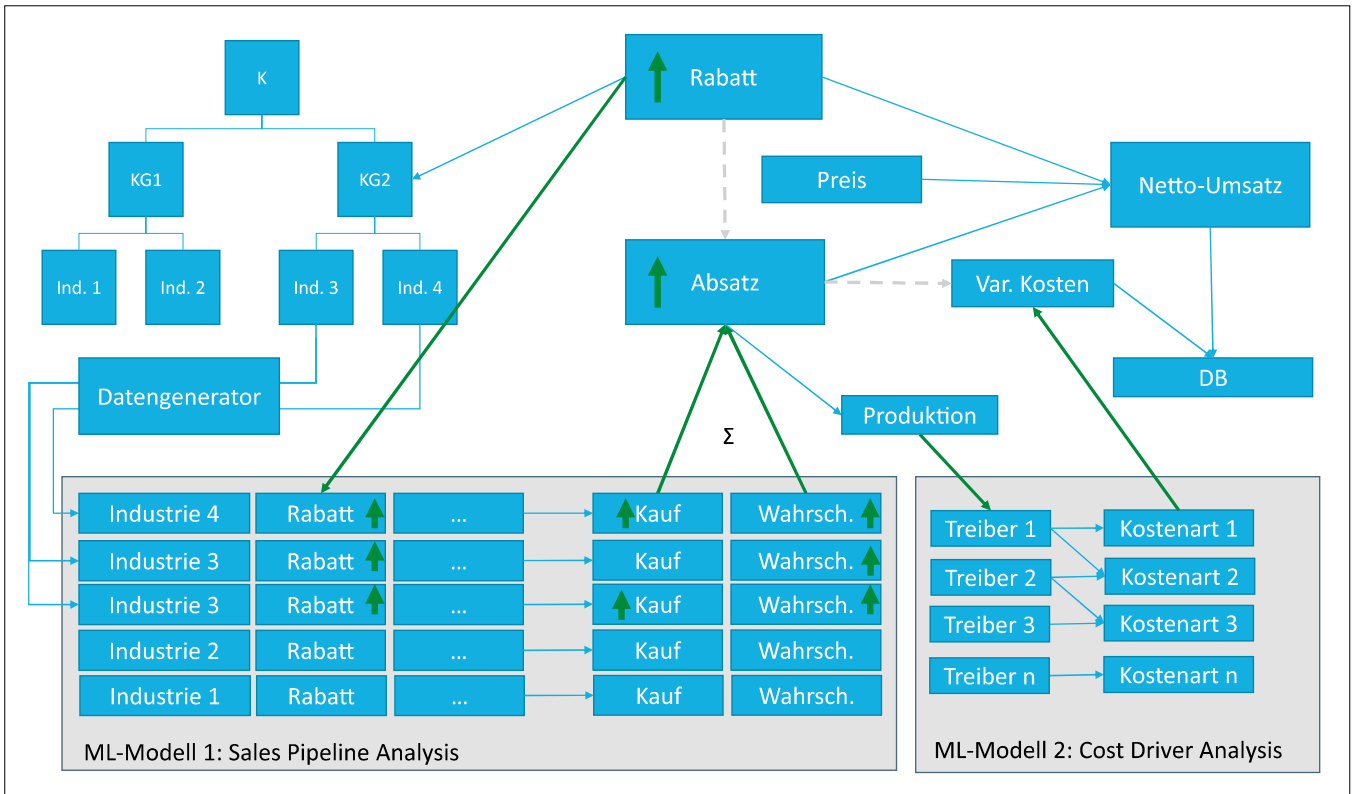


Abb. 2: Kopplung von ML und Simulation

Zur Qualität von Simulationen

Anders als beim Forecast geht es bei der Simulation nicht um eine möglichst hohe (spätere) Treffsicherheit zukünftiger Ergebnisse, sondern um die „Stimmigkeit“ der Ergebnisse. Die Simulation sollte die Wirkungen der Realität möglichst gut widerspiegeln. Dies lässt sich aber ex post nur überprüfen, wenn die Parameterkonstellation auch umgesetzt wird, was nicht zwangsläufig der Fall sein dürfte.

Es ist selbstverständlich, nach guten Modellen zu streben, natürlich unter Berücksichtigung der Wirtschaftlichkeit. Aber was macht die Qualität von Simulationen aus? Simulationen zeichnen sich gelegentlich durch sehr „wagemutige“ Annahmen aus. Übertriebene Wachstumsannahmen oder unrealistische Wirkungstreiber erzeugen dementsprechend unrealistische Ergebnisse, die die Sinnhaftigkeit der Simulation infrage stellen. Einige Anomalien:

- Das Modell ist zu stark vereinfacht. Dies hat häufig Aufwandsgründe. Die Frage ist, welche Ungenauigkeit noch zu akzeptieren ist. Ein Modell ist dann gut, wenn es auf der einen Seite möglichst einfach (im Sinne von Occams Skalpell) ist, auf der anderen Seite aber auch realitätsnahe Ergebnisse erzeugt.

Häufig werden beispielsweise Preis-Absatz-Wirkungen aufgrund von Messproblemen vernachlässigt: Eine Preiswirkung wird lediglich durch die Multiplikation mit dem Absatz zum Umsatz und infolge zum Deckungsbeitrag oder EBIT linear durchgerechnet. Mögliche Wirkungen auf den Absatz werden aufgrund der Schwierigkeiten bei der Quantifizierung vernachlässigt.

- Die Eingabewerte sind nicht realistisch. Planungsdefekte wie etwa der Hockeyschlägereffekt treten auf. So läuft es in der aktuellen Entwicklung in vielen Unternehmen häufig nicht so rund, der Glaube an eine rosige Zukunft ist dennoch ungebrochen.
- Falsche Annahmen bezüglich Wirkung und Wirkungsstärke (zum Beispiel Scheinkausalitäten).³
- Nicht ausreichende Berücksichtigung von Unsicherheit. Die rechnerisch genaue Ermittlung von Zielgrößen täuscht Sicherheit vor. Ein Problem ist, dass Modellparameter unterschiedlich mit Unsicherheit behaftet sind. Man tut sich schon schwer mit der isolierten Einschätzung einzelner Risiken. Die Verdichtung von Unsicherheiten verschärft dieses Problem.
- Ein weiterer kritischer Punkt ist eine häufig aus Komplexitätsgründen vorgenommene Li-

nearitätsannahme. Ob eine Rabattvariation auf den Absatz linear wirkt, ist zumindest zu hinterfragen. Häufig hat man keine empirische Grundlage bei größeren Parameteränderungen. Die Anwendung einer linearen Abhängigkeit führt zwar dann zu einem Simulationsergebnis, welches aber nicht empirisch gestützt ist.

- Falsche Interpretation. Die Darstellung der Ergebnisse ist für das Verständnis der Wirkungsbeziehungen wichtig. So ist es beispielsweise hilfreich, bei mehrfacher Parameteränderung die Einflüsse der einzelnen Parameter auf die Zielgröße erkennen zu können.

Diese Auflistung macht deutlich, wie anspruchsvoll die Modellbildung ist und wie schwierig es ist, die Eignung von Modellen zu erkennen.

ML-Modelle können allerdings der Qualitätsverbesserung dienen: Bei der Entwicklung von ML-Modellen unterteilt man die verfügbaren Daten, die Eingabe- und Zielvariablen enthalten, nach Training und Test. Über die Trainingsdaten wird das Modell trainiert und anschließend mit den Testdaten überprüft. Entsprechen die durch die Regeln abgeleiteten Ergebnisse den beobachteten Ergebnissen bei minimaler Abweichung,

ist das Modell geeignet. Eingabeparameter können ebenfalls mittels statistischer / ML-Modellen hinsichtlich der Validität geprüft werden.

Diese Vorgehensweise ist allerdings bei der Simulation in Gänze kaum anwendbar. Man will ja Konstellationen durchspielen, die in der Realität gerade noch nicht aufgetreten sind. So möchte man häufig durch Simulation die Auswirkung von disruptiven Ereignissen feststellen. Hier ist es eher wahrscheinlich, dass eine entsprechende Konstellation noch gar nicht aufgetreten ist. Eine Gesamtmodellvalidierung ist somit nur in Ausnahmefällen möglich. Insofern muss man sich bei der Qualitätsbeurteilung mit Teilausschnitten begnügen.

Umsetzung

Eine wichtige Anforderung an eine effektive Umsetzung der Simulation ist die enge Anbindung an bestehende Planungssysteme. Zum einen benötigt man Modellstrukturen wie Organisations-, Produkt- oder Kundenstruktur. Hierbei sind aber in der Regel nur Ausschnitte oder Verdichtungen für die jeweilige Simulation relevant. Auch die klassischen Finanzmodelle (GuV, Deckungsbeitragsrechnung usw.) eignen sich zum Modelllaufbau. Zum anderen liefert das Forecasting die Ausgangsdaten für eine Simulation.

Ein weiterer Punkt ist die Anbindung von Systemen des maschinellen Lernens. Diese sollen, wie schon dargestellt, grundlegende Wirkungsbeziehungen bereitstellen, damit simuliert werden kann.

Zur Umsetzung bieten sich verschiedene Möglichkeiten an⁴:

- Die bewährte Tabellenkalkulation ist natürlich ein potentieller Kandidat zur Umsetzung der skizzierten Architektur. Eine Simulation ist damit schnell aufgesetzt. Es gibt einige Werkzeuge, die eine Simulation in Excel unterstützen und zusätzlich auch ML-Funktionen bereitstellen. Allerdings gerät man hier recht schnell in die Komplexitätsfalle. Insbesondere dimensionale hierarchische Strukturen überfordern Excel regelmäßig. Beschränkte Wartbarkeit und mangelnde Skalierbarkeit führen diesen Ansatz schnell an seine Grenzen.

- Es besteht auch die Möglichkeit, direkt mit Planungswerkzeugen (Tagetik, SAP BPC etc.) zu simulieren. Planungswerkzeuge sind in der Regel gut skalierbar. Viele Anbieter von Planungslösungen integrieren ML-Werkzeuge. Allerdings werden unterschiedliche Zwecke mit diesen Planungssystemen verfolgt, so dass eine Simulation hinsichtlich der Flexibilität eingeschränkt sein dürfte. Auch kommt durch die Unterstützung von Planungsprozessen, verbunden mit einer hohen Governance, zusätzliche Komplexität dazu. Bestandteil einer Simulation kann auch die Veränderung von Strukturen betreffen. Die Konsistenz bestehender Planungsansätze darf aber dadurch nicht gefährdet werden.
- Dedizierte Simulationslösungen, die teilweise auf etablierten Methoden wie System Dynamics (zum Beispiel Vensim, Anylogic, Dynaplan) basieren, sind hinsichtlich der Simulationsflexibilität vorbildlich. Dies ist schließlich deren Hauptaufgabe. Nachteilig ist ein höherer Konfigurationsaufwand bei der Modellerstellung, da Strukturen übernommen oder neu aufgebaut werden müssen. Die Anbindung von maschinellem Lernen ist noch nicht sehr weit ausgeprägt. Zwar beschäftigen sich die Anbieter auch mit maschinellem Lernen. Allerdings gehen diese Bestrebungen wenig auf die spezielle Problematik der skizzierten Controller-Anforderungen ein.
- Es lässt sich auch mit den klassischen OLAP-Lösungen (zum Beispiel Jedox, TM1, Alea) relativ gut simulieren. Vorteilhaft ist, dass man auch auf großen Datenmengen simulieren kann. Zum Teil besteht auch die Möglichkeit, die Ergebnisse maschinellen Lernens direkt einzubinden. Aufgrund der üblicherweise recht komplexen Modellierungssprache werden allerdings Simulationsmodelle schnell unübersichtlich.

Fazit

Die Fundierung von Annahmen ist eine erhebliche Schwachstelle bei der Simulation. Die Simulationsqualität lässt sich allerdings durch maschinelles Lernen verbessern. Der Einsatz maschinellen Lernens erlaubt, sich stärker auf die Qualität der Wirkungsbeziehungen konzentrieren zu können. Dies setzt jedoch eine intensive Beschäftigung voraus. Wünschenswert ist

es, nicht individuelle und damit stark aufwands-erhöhende Modellerweiterungen zu konzipieren, sondern vorwiegend möglichst vorhandene ML-Modelle nutzen zu können. Hierzu ist eine Kopplung zu spezifizieren.

Auch müssen leistungsfähige Werkzeuge bereitstehen. Viele Anbieter beschäftigen sich mit der Problematik, dennoch ist der Stand der Umsetzung nicht allzu fortgeschritten. Allerdings hat sich in letzter Zeit einiges getan, so dass eine effiziente Umsetzung mit etwas Eigenleistung notwendig ist.⁵

Ebenso wie der maschinelle Forecast sollte sich der Einsatz von Simulation natürlich lohnen. Zur Wirtschaftlichkeit des Einsatzes gilt ähnliches, wie bereits im Beitrag zum Forecasting erläutert wurde: Der Aufwand ist noch einschätzbar, der Wert der Qualitätsverbesserung hingegen kaum. Allerdings verschärft sich das Bewertungsproblem gegenüber der Bewertung des ML-basierten Forecasting noch zusätzlich, da eine Gesamtvalidierung – wie dargestellt – kaum möglich ist.

Fußnoten

¹ Stahlknecht, 1970.; ² in der Produktionsplanung nennt man das Ergebnis einer solchen Gruppenbildung über Produkte auch „Phantomprodukte“.; ³ Scheinkausalitäten müssen nicht unbedingt kritisch für die Modellierungsqualität sein. Wenn eine Variable geschätzt wird, kann dies auch auf die zweite korrelierende Variable übertragen werden, ohne dass der Ursprungstreiber bekannt ist.; ⁴ Vgl. auch Isbruch u. a. A., 2016.; ⁵ Vgl. z. B. Oehler, 2019.

Literatur

Oehler, K.: Advanced Analytics für Controller, Freiburg 2019.
 Romeike, F., Spitzner, J.: Von Szenarioanalyse bis Wargaming, Weinheim 2013.
 Stahlknecht, P.: Operations Research, 2. Auflage, Braunschweig 1970.
 Isbruch, R., Renner, N., Möller, K., Berendes, K., Wunderlich, P.: Treiberbasierte Planungs- und Simulationsmodelle im Controlling, in: Zeitschrift für Controlling, 12/2016, S. 755-764. ■