



TREASURYLOG

Informationen für Treasurer und Finanzverantwortliche, seit 1992 herausgegeben von Schwabe, Ley & Greiner

2018

Liquiditätsplanung und Risiko-Management

s. 9 **Optimierte Sicherungsstrategie**

Alternative Anwendung der Portfoliotheorie nach Markowitz

s. 10 **Die Verlockungen des niedrigen Zinsniveaus**

Zur faktenbasierten Beurteilung langfristiger festverzinslicher Finanzierung

s. 16 **Expertenmeinungen zur Zinsentwicklung**

Wie sich die Schwerpunkte geändert haben

s. 19 **Predictive Analytics**

Liquiditätsplanung mittels Algorithmus

Kann der Computer besser planen als der Mensch?

Eine sorgfältige Liquiditätsplanung kostet Zeit und Nerven. Der Gedanke, diesen Prozess zu automatisieren und per Knopfdruck in wenigen Minuten zu erledigen, klingt verlockend. Welche Chancen stecken in dem neuen Verfahren und was muss bedacht werden, bevor die Plandaten aus dem Computer kommen?

Predictive Analytics ist derzeit eines der vielversprechendsten Digitalisierungs-Themen im Treasury, würde eine Liquiditätsplanung auf Knopfdruck für Konzerne doch eine immense Zeitersparnis bedeuten. So könnten Tochtergesellschaften in der Planung entlastet werden, die Zentrale müsste fehlenden Plandaten nicht mehr hinterherlaufen und Schulungs- und Betreuungsaufwände könnten weitgehend entfallen.

Ganz so einfach ist es aber leider nicht. Wer hinter Predictive Analytics eine Lösung vermutet, die auf magische Weise Plandaten liefert, wird schnell merken, dass es ohne menschliches Zutun nicht geht. Man kann seinen Rechner zwar mit nahezu unendlich vielen Daten füttern, die Zukunft wird er damit aber nicht vorhersagen können. Diese Sichtweise greift zu kurz und erzeugt hohe Erwartungen, die auch der schlaueste Computer nicht erfüllen kann.

Was kann Predictive Analytics tatsächlich leisten?

Keine Frage, Predictive Analytics birgt ein großes Potenzial. Ein Algorithmus kann unter Umständen deutlich bessere Planzahlen liefern, weil er in der La-

ge ist, große Datenmengen zu verarbeiten und hochkomplexe Analysen durchzuführen, die für einen Menschen nicht zu bewältigen wären. Statistische Ausreißer lassen sich damit aber nicht abdecken und brauchen immer den Treasurer, der mit wachen Augen auf interne und externe Einflüsse achtet. Außerdem verlangt die Komplexität von Predictive Analytics ein hohes Maß an Spezialkenntnissen und damit auch Verständnis für die Grenzen des Möglichen. Nur wer dieses Wissen hat, kann zuverlässig einschätzen, wie sich Zeitaufwand und Erfolgswahrscheinlichkeit eines Projekts darstellen.

Welches Prinzip steckt hinter Predictive Analytics?

Predictive Analytics nutzt historische Daten, um Entwicklungen vorhersagen zu können. Das ist keine neue Idee – schon heute analysieren viele Unternehmen mithilfe von Excel ihre Cashflows der vergangenen Jahre, um Verläufe und Muster zu erkennen. Wenn wir über Predictive Analytics sprechen, geht es um genau das gleiche Prinzip, allerdings auf einem wesentlich höheren und technisch ausgereifteren Niveau mit einem stärkeren Automatisierungsgrad. Dennoch gilt: Wer die Zukunft vorhersagen

Die Autoren:



Nils Rohe,
Project Manager,
TIPCO Treasury &
Technology GmbH



Jochen Bamminger,
Lead Software
Architect, TIPCO
Treasury & Techno-
logy GmbH



Abb. 1: **Auswahl des passenden Rechenmodells im Testlauf mit historischen Ist-Daten**

Die ersten drei Ist-Jahre werden zur Validierung des passenden Rechenmodells verwendet. Das Modell, das den Ist-Daten aus dem vierten Jahr am nächsten kommt (grüner Graph), wird schließlich für die Plandaten-Berechnung ausgewählt.

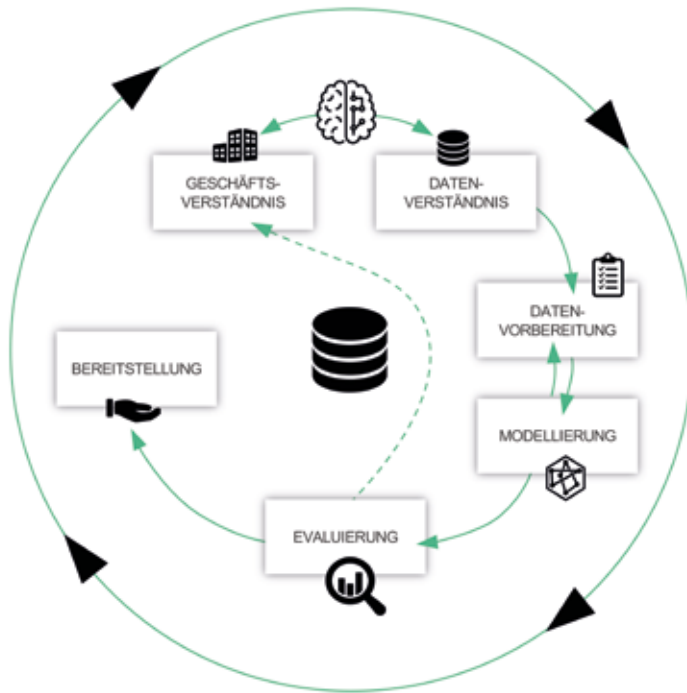


Abb. 2: **Cross-industry standard process for data mining**
 Kurz „CRISP-DM“ ist eine von europäischen Technologiekonzernen entwickelte Methode, die den Prozess des Data-Minings in die beschriebenen Phasen aufteilt.

möchte, muss in der Vergangenheit nach Trends, Mustern und Zusammenhängen suchen. Das mag trivial klingen, zeigt aber gleichzeitig, wie zentral die Rolle der bereits vorhandenen Daten ist. Denn: Wo nichts ist, kann auch nichts gefunden werden. Predictive Analytics ist keine Magie, sondern basiert auf statistischen Verfahren, die Ergebnisse auf Basis der Daten liefern, mit denen sie gefüttert werden. Damit das zuverlässig funktioniert, müssen die Daten nicht nur vorhanden sein, sondern bestimmte qualitative und quantitative Anforderungen erfüllen.

Das Data-Mining-Projekt – der Weg zu automatisch generierten Plandaten

Ganz am Anfang steht das genaue Verständnis vom eigenen Geschäftsmodell, um die richtigen Informationen für die Berechnungen identifizieren zu können. Sobald klar ist, was benötigt wird, muss sichergestellt werden, dass diese Daten mindestens für die vergangenen vier Jahre vorliegen, um belastbare Testläufe durchführen zu können. Sind diese zusammengetragen, erfolgt eine inhaltliche Überprüfung und Aufbereitung für die maschinelle Interpretation. Auf dieser Basis wird das passende Rechenmodell ausgewählt. Was genau „passend“ heißt, hängt von der Struktur der vorliegenden Daten ab und zeigt sich in der Qualität der Ergebnisse. Um diese zu prüfen, wird ein erster Testlauf mit den historischen Daten gefahren (Abb. 1). Ergibt die Berechnung auf Basis der ersten drei Jahre eine Prognose, die den

Ist-Daten aus dem vierten Jahr nahekommt, liegt das Verfahren richtig. Bei deutlichen Abweichungen muss nachjustiert werden.

Diese Schritte sind ein wichtiger Teil des „Data-Mining-Projekts“ (s. Abb. 2) und sind ausschlaggebend für die Qualität Ihrer Prognosen. Was einfach klingt, ist vor allem eine Frage der theoretisch benötigten und der praktisch vorhandenen Daten. Diese Informationen zu beschaffen, kann durchaus zur Herausforderung werden. Häufig liegen Ist-Daten nicht nach den relevanten Planungskategorien aufgeschlüsselt vor oder die Zeitreihen sind zu kurz. Sehr vereinfacht ausgedrückt liegen dem beschriebenen Ablauf folgende Fragen zugrunde:

1. Welche internen und externen Faktoren beeinflussen mein Geschäft und wie lassen sie sich in Daten (im statistischen Fachjargon „Features“) ausdrücken?
2. Liegen die benötigten Zahlen in der richtigen Granularität und für einen ausreichend großen Zeitraum vor?
3. Gibt es statistische Ausreißer im Datenmaterial, die nicht dem „normalen“ Verlauf entsprechen und Prognosen verfälschen könnten?
4. Sind Anpassungen notwendig in Hinblick auf die Form und die maschinelle Interpretierbarkeit der Daten?

Manchmal ist weniger mehr – wie viele Faktoren verträgt ein Modell?

Wer über einen qualitativ hochwertigen Datenschatz über viele Jahre verfügt, könnte versuchen, ein für alle Eventualitäten vorbereitetes Rechenmodell mit besonders vielen Faktoren (Features) zusammenzustellen. Die Praxis zeigt allerdings, dass es wenig zielführend ist, wenn zu vieles Features einbezogen werden. Das liegt an einem Phänomen, das die Datenexperten „Over-Fitting“ nennen. Eine zu hohe Anzahl von Features kann dazu führen, dass ein Modell zwar sehr gut mit den Daten funktioniert, mit denen es erstellt wurde, aber weniger gut mit neuen Daten. Nicht jeder wirtschaftliche Geschäftsfaktor sollte es also in das Rechenmodell schaffen.

Daten aufbereiten – eine Wissenschaft für sich

Zwischen der Datenbeschaffung und dem ersten Testlauf liegt der wichtige Schritt der Datenaufbereitung. Je nachdem, welches Modell ausgesucht wird, müssen die Experten unterschiedliche Anpassungen vornehmen, bevor sie die Daten an das Modell übergeben können. So kann es beispielsweise nötig sein, „kategorische Variablen“ zu codieren. Was hochkomplex klingt, bedeutet, dass Daten in Zahlen und nicht in Worten vorliegen müssen. Im Treasury ist

Day	Inflow on bank account	Day	Inflow on bank account
Saturday	0	6	0
Sunday	0	7	0
Monday	321	1	321
Tuesday	294	2	294
Wednesday	912	3	912
Thursday	678	4	678
Friday	869	5	869
Saturday	0	6	0
Sunday	0	7	0
Monday	274	1	274
Tuesday	321	2	321
Wednesday	767	3	767
Thursday	454	4	454
Friday	912	5	912
Saturday	0	6	0
Sunday	0	7	0
Monday	211	1	211
Tuesday	412	2	412
Wednesday	541	3	541
Thursday	654	4	654
Friday	874	5	874

Abb. 3: **Kategorische Variablen codieren in der Datenmodellierung**

Klingt kompliziert, ist aber einer der einfacheren Arbeitsschritte: Daten müssen so aufbereitet werden, dass sie von den statistischen Modellen auch verarbeitet werden können. In diesem Fall müssen die Wochentage in Werte umgeformt werden.

ein möglicher Anwendungsfall dafür das Umformen von Wochentagen in Zahlen (s. Abb. 3).

Ein anderes Beispiel ist die Verteilung von Daten. Bestimmte Modelle setzen voraus, dass die Basisdaten normalverteilt sind. Ist dies nicht der Fall, muss auch hier entsprechend umgeformt werden.

Neben der Form der Daten ist bei der Modellierung auch der Inhalt entscheidend. Denn statistische Ausreißer sind nicht nur für die Zukunft zu erwarten (und von einem Computer nicht vorhersagbar), sondern kommen auch in der Vergangenheit vor. Um die Vorhersagen nicht zu verfälschen, müssen diese entweder im Vorfeld entfernt oder durch das gewählte Modell behandelt werden, um ihren Einfluss zu minimieren.

Um möglichst genaue Prognosen berechnen zu können, müssen alle relevanten Einflussfaktoren genau betrachtet werden. Dafür analysieren Treasurer und Datenexperten gemeinsam die historischen Daten, um etwaige Ausreißer oder Veränderungen in den

Mustern (s. Abb. 4) erklären zu können. Im nächsten Schritt entscheidet das Team, wie mit den Ergebnissen weiter zu verfahren ist, oder ob die Datensätze aus der Analyse ausgeschlossen werden müssen.

Ob sich der Aufwand der Datensuche und der Aufbereitung gelohnt hat, zeigt sich erst nach der Erstellung des Prognosemodells. In der Regel gelingt es nicht auf Anhieb, ein passendes Modell zu entwickeln. Es bedarf meistens mehrerer Durchläufe der beschriebenen Schritte, in denen unterschiedliche Verfahren und Daten getestet werden.

Entlastung für den Faktor Mensch

Wer ein Vorhersagemodell entwickelt, muss sich bewusst sein, dass ein gewisses Maß an Abweichungen unvermeidbar ist. Dennoch können mit moderner Rechenleistung Daten in Größenordnungen verarbeitet werden wie nie zuvor. Auch wenn Prognosemodelle auf absehbare Zeit keine standardisierten Systemfunktionalitäten sein werden, sind sie in der Lage, Konzerne bei ihrer Liquiditätsplanung entscheidend zu entlasten und Ergebnisse zu liefern, zu denen der Mensch alleine nicht in der Lage wäre. Für Treasury-Abteilungen lohnt es sich also durchaus, die Möglichkeiten von Predictive Analytics zu evaluieren und Projekte für klar definierte Anwendungsgebiete aufzusetzen.

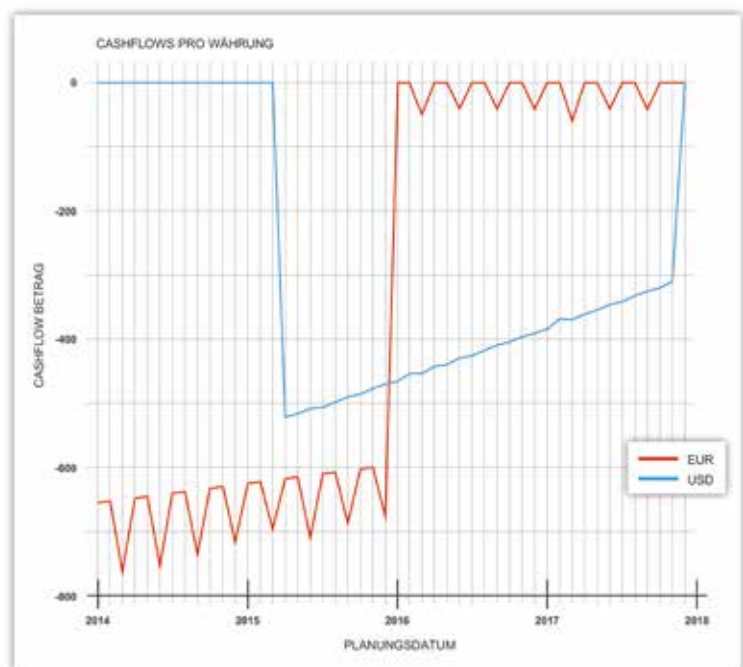


Abb. 4: **Verlaufsveränderungen am Beispiel eines Währungswechsels**

Der USD wird 2015 als neue Währung in die Planung aufgenommen und ersetzt 2016 beinahe vollständig die Währung EUR. Ohne entsprechende Erklärung würde der Computer den Währungswechsel als Ausreißer betrachten und nicht als dauerhafte Änderung interpretieren.