

Zeitreihenanalyse für Controller – Mit Zeitreihenprognosen die Zukunft (besser) vorhersagen können (Teil 3)

Florian Bliefert

Nach der **Datenaufbereitung und ersten explorativen Analysen im zweiten Teil der Serie** folgt nun der nächste logische Schritt: die Prognose. Ziel ist es, zukünftige Werte auf Basis historischer Entwicklungen möglichst treffsicher zu schätzen – sei es zur Umsatzplanung, zur Budgetsteuerung oder zur Kapazitätsvorausschau. Dazu gibt es mehrere Prognoseansätze, einen davon haben wir in Teil 1 der Serie bereits angesprochen: exponentielle Glättung.

Dabei werden die jüngeren Beobachtungen stärker gewichtet als die älteren, im Gegensatz zum einfachen gleitenden Durchschnitt, bei dem alle Werte im Zeitfenster gleich behandelt werden. In Excel kann das schnell und einfach dargestellt werden (vgl. Teil 1), aber für eine Pro-



Summary

Zeitreihenprognosen ermöglichen Controllern, zukünftige Entwicklungen fundiert vorherzusagen. Neben einfachen Verfahren wie exponentieller Glättung bieten fortgeschrittene Ansätze wie ARIMA und Prophet präzisere Ergebnisse. Während ARIMA auf statistischen Prinzipien beruht, überzeugt Prophet durch Automatisierung und Flexibilität – ideal für praxisnahe Forecasts im datengetriebenen Controlling-Umfeld.

gnose ist das Modell nur bedingt geeignet. Für die Vorhersage des nächsten Zeitpunkts $t+1$ wird einfach der letzte berechnete Wert des EMA verwendet, genauso wie für $t+2$ und $t+3$. Eine längere Prognose ist mit diesem Verfahren nicht sinnvoll, da bei der Prognose keine weiteren Trend- oder Saisonkomponenten berücksichtigt werden. Und sollte die originale Zeitreihe so träge sein, dass man mehr als drei Tage linear voraussagen kann, wäre der Einsatz von EMA sowieso überflüssig.

Besser ist es daher, mit fortgeschrittenen Algorithmen zu arbeiten wie der Familie der ARIMA-Modelle oder der Prophet-Library. Diese Werkzeuge können jedoch nicht direkt in Excel verwendet werden, sondern nur über Umwege. Dazu müssen entweder Plugins installiert werden (die zum Teil kostenpflichtig sind), oder die Möglichkeit von MS 365 genutzt werden, die Programmiersprache Python aus Excel heraus aufzurufen.

Um Python in Excel zu verwenden, wird mit der Formel `=PY()` eine Python Umgebung in einer Excel-Zelle erstellt (Abb. 1). Der Python-Code wird wie gewohnt in der Formelzeile eingegeben. Die Ergebnisse der Python-Berechnung werden dann als Ergebnis an die Zelle zurückgegeben und können wie gewohnt weiterverarbeitet werden. Die Ausführung des Codes erfolgt jedoch nicht auf dem eigenen Rechner, sondern wird in der Microsoft Cloud ausgeführt.




Abb. 1: Ausführung einer Python-Operation in Excel
(Quelle: Microsoft Homepage)

Unabhängig davon, ob das aus Datensicherheits- und Datenschutzgründen im eigenen Unternehmen möglich und erlaubt ist, wird hier im Weiteren nicht auf diese Möglichkeit eingegangen. Da die Analyse sowieso in Python erfolgt, wird im Folgenden direkt mit Python in einem Jupyter Notebook gearbeitet. Python hat sich in den letzten Jahren als eine der führenden Programmiersprachen für Datenanalyse und Forecasting etabliert – nicht zuletzt wegen seiner breiten Auswahl an Codebibliotheken, der guten Lesbarkeit und der offenen Verfügbarkeit. Für Controller, die sich mit datengetriebenen Analysen und Prognosen beschäftigen, bietet Python einen niedrigschwiligen Einstieg in professionelle Data-Science-Werkzeuge – ohne dabei gleich eine Entwicklerlaufbahn einschlagen zu müssen.

Eine besonders benutzerfreundliche Umgebung für interaktive Datenanalysen ist das sogenannte Jupyter Notebook. Es handelt sich um eine browserbasierte

Arbeitsumgebung, in der Code, Kommentare, Tabellen und Grafiken direkt nebeneinander dargestellt werden können. Jupyter Notebooks sind damit ideal für explorative Analysen, Testläufe von Prognosemodellen oder die visuelle Aufbereitung von Zeitreihen.

In der Unternehmenspraxis stellt sich allerdings schnell die Frage nach der technischen Umsetzbarkeit: Auf vielen Unternehmenslaptops sind aus Sicherheitsgründen keine Administratorrechte vorhanden – und damit keine freie Installation neuer Software möglich. In solchen Fällen kann es hilfreich sein, auf virtuelle Umgebungen auszuweichen, die zentral bereitgestellt werden (z. B. über Citrix oder cloudbasierte Analyseplattformen). Alternativ bieten viele Unternehmen heute dedizierte Data-Science-Umgebungen auf internen Servern oder über sichere Browserzugänge an. Dass umgekehrt die Analyse von Unternehmensdaten auf einem privaten Gerät mit den notwendigen Werkzeugen offensichtlich keine kluge Idee ist, muss hier nicht extra erläutert werden.

ARIMA – das Schweizer Taschenmesser der Zeitreihenanalyse

Eines der am weitesten verbreiteten Verfahren zur Prognose von Zeitreihen ist das ARIMA-Modell, das für Auto Regressive Integrated Moving Average steht. Es wurde in den 1970er Jahren maßgeblich durch George Box und Gwilym Jenkins systematisiert und ist seitdem unter dem Namen Box-Jenkins-Modell bekannt. Ihr Ziel war es, ein flexibles, mathematisch fundiertes Modell zu entwickeln, mit dem sich unterschiedlichste Zeitreihenphänomene modellieren und vorhersagen lassen – insbesondere dann, wenn keine klaren erklärenden Einflussgrößen vorhanden sind. Im Gegensatz zu Regressionsmodellen, die externe Variablen benötigen, nutzt ARIMA ausschließlich die Struktur der Zeitreihe selbst.

Die Grundidee von ARIMA ist einfach, aber wirkungsvoll: Viele wirtschaftliche Prozesse folgen bestimmten Mustern – etwa, dass der heutige Umsatz eng mit dem von gestern zusammenhängt, dass es längerfristige Trends gibt oder dass Fehler der Vergangenheit sich in zukünftigen Beobachtungen fortsetzen. Diese Muster werden in drei mathematischen Komponenten erfasst:

Autoregression (AR) – die Vergangenheit als Prognosebasis

Die autoregressive Komponente bildet die Annahme ab, dass der aktuelle Wert einer Zeitreihe durch eine lineare Kombination seiner eigenen vergangenen Werte beschrieben werden kann. Ein AR(1)-Modell geht etwa davon aus, dass der heutige Wert stark vom gestrigen Wert abhängt. Wie stark die Werte von vorangegangenen Werten abhängt, wird durch die Autokorrelation ausgedrückt (vgl. Teil 1).



**Florian
Bliefert**

MBA und B.Sc.

ist als Manager bei der CA Akademie AG sowohl als Trainer als auch Berater tätig. Seine Schwerpunkte liegen in den Bereichen Kosten- und Leistungsrechnung, Planung und Reporting. Er betreut seine Kunden bei Projekten in den Bereichen KI, Predictive Analytics, Data Mining und Robot Process Automation (RPA).
f.bliefert@ca-akademie.de




Abb. 2: Differenz erster Ordnung der Mail-Service-Tagesumsätze

Lag zum Beispiel der Umsatz an einem Tag bei 10.000 €, ist es sehr wahrscheinlich, dass der nächste Tagesumsatz in einer ähnlichen Größenordnung liegt – insbesondere bei regelmäßigen Abomodellen oder stabilen Geschäftsprozessen.

Integration (I) – aus nicht-stationär mach stationär

Viele reale Zeitreihen, insbesondere im Controlling, zeigen Trends oder saisonale Muster. Diese führen dazu, dass klassische Modelle, die konstante statistische Eigenschaften voraussetzen, nicht funktionieren. Die ARIMA-Methode begegnet dem mit dem sogenannten „Integrated“-Teil: Die Zeitreihe wird durch Differenzbildung in eine stationäre Form überführt. Dabei werden anstelle der absoluten Werte ihre Veränderungen betrachtet.

In **Abb. 2** wurden die einzelnen Tagesumsätze des Mail-Services vom jeweiligen Vortagesumsatz subtrahiert und eine neue Zeitreihe gebildet. Es ist deutlich zu sehen, dass durch die einfache Differenzierung die Zeitreihe stationär geworden ist und keinen Trend mehr aufweist. Die Daten schwanken um den Mittelwert mit relativ konstantem Abstand. Sollte eine Zeitreihe nach der ersten Differenzbildung noch eine Trendkomponente aufweisen, kann die

Differenzierung wiederholt werden und eine Differenzierung zweiter Ordnung berechnet werden.

Moving Average (MA) – Lernen aus Fehlern

Die dritte Komponente des Modells berücksichtigt nicht vergangene Werte, sondern vergangene Prognosefehler. Der heutige Umsatz kann beispielsweise dadurch beeinflusst sein, dass der gestrige deutlich höher oder niedriger ausfiel als erwartet. Dieses Muster wird über die MA-Komponente abgebildet – nicht zu verwechseln mit dem einfachen gleitenden Durchschnitt.

So kann ein positiver Ausreißer gestern (z. B. durch eine Großkampagne) dazu führen, dass der heutige Wert eher niedriger liegt – ein klassisches Beispiel für ein verzögertes Korrekturverhalten.

Warum funktioniert ARIMA?

ARIMA funktioniert, weil es systematisch alle relevanten Aspekte einer Zeitreihe berücksichtigt, ohne externe Variablen zu benötigen: die Autoregression nutzt die Vergangenheit, die Differenzierung beseitigt Trends und die Moving-Average-Komponente glättet Unregelmäßigkeiten.

Damit eignet sich ARIMA besonders gut für betriebswirtschaftliche Zeitreihen, in denen interne Dynamik wichtiger ist als externe Einflüsse. Vor allem in Szenarien ohne große saisonale Schwankungen oder bei kurzen Prognosehorizonten ist ARIMA oft erstaunlich präzise – etwa bei der Vorhersage von Tagesumsätzen, Lagerbeständen oder wiederkehrenden Kosten. Ein konkretes Modell $ARIMA(p, d, q)$ wird durch drei Parameter beschrieben:

- p = Ordnung der Autoregression (wie viele Vergangenheitswerte)
- d = Anzahl der Differenzierungen (wie oft zur Stationarität differenziert wurde)
- q = Ordnung des gleitenden Durchschnitts (wie viele Fehlerterme berücksichtigt werden)

Ein einfaches Beispiel ist $ARIMA(1,1,1)$ – eine einmal differenzierte Zeitreihe, bei der der aktuelle Wert auf einem autoregressiven Anteil ersten Grades und einem Fehlerterm aus der Vorperiode basiert. In der praktischen Anwendung auf unsere Beispielzeitreihe liefert $ARIMA(1,1,1)$ jedoch ein unbefriedigendes Ergebnis. Die Prognosekurve wirkt geglättet, fast schon träge, und bildet die typischen Ausschläge und Muster der historischen Zeitreihe kaum ab. Auch die erkennbaren wiederkehrenden Effekte im Wochenverlauf – etwa der Anstieg Richtung




Abb. 3: Prognose der nächsten zwei Wochen mit ARIMA

Wochenende – werden vom Modell nicht eingefangen. Das liegt daran, dass ARIMA(1,1,1) keine Informationen über längere zeitliche Abhängigkeiten berücksichtigt. Insbesondere die wöchentliche Saisonalität bleibt damit unberücksichtigt.

An dieser Stelle wäre der Einsatz eines saisonalen Modells – konkret eines SARIMA-Modells – eigentlich geboten. SARIMA erweitert das ARIMA-Modell um explizite saisonale Komponenten, beispielsweise mit einem saisonalen AR-Term, der den Zusammenhang mit dem Wert vor sieben Tagen modelliert. In unserem Fall würde das bedeuten, dass das Modell nicht nur den Vortag, sondern gezielt auch den gleichen Wochentag der Vorwoche berücksichtigt – ein naheliegender Ansatz bei regelmäßig wiederkehrenden Mustern im Wochenverlauf.

Aus methodischer Sicht wäre SARIMA hier die sauberste Lösung. Doch in vielen Controlling-Umfeldern steht diese Modellvariante nicht ohne Weiteres zur Verfügung – sei es aus Gründen der Toolunterstützung, fehlender Rechenressourcen oder begrenzter Modellierungskompetenz. Als pragmatische Alternative bietet sich daher ein besser parametrisiertes Standard-ARIMA-Modell an.

Mit dem Wechsel auf ein ARIMA(7,1,2) verbessert sich die Prognosequalität deutlich. Das Modell berücksichtigt nun sieben autoregressive Lags – also eine ganze Woche zurückliegender Werte – sowie zwei MA-Lags zur Glättung kurzfristiger Fehler. Damit gelingt es, die typische Struktur der Zeitreihe

mit ihren Wochenmustern deutlich besser zu erfassen. Die Prognosekurve folgt den Schwankungen realistischer, spiegelt das bekannte Wochenprofil wider und liefert insgesamt eine deutlich plausiblere Vorhersage der kommenden Tage (**Abb. 3**).

Diese Erfahrung zeigt: Schon durch eine geschickte Wahl der Parameter lässt sich auch mit einem einfachen ARIMA-Modell viel erreichen – insbesondere dann, wenn man weiß, welche saisonalen Strukturen in den Daten verborgen sind. Für Controller bedeutet das: Die Kombination aus fachlichem Verständnis der Geschäftsdaten und einem gezielten Modellansatz kann deutlich bessere Ergebnisse liefern als der bloße Einsatz von Standardparametern.

Die Prophet-Library – ARIMA auf Steroiden

Während klassische ARIMA-Modelle eine solide statistische Grundlage bieten und bei gut vorbereiteten, stationären Zeitreihen sehr gute Ergebnisse liefern können, stoßen sie in der Praxis oft an Grenzen – besonders dann, wenn Zeitreihen nicht sauber, nicht stationär oder von komplexen saisonalen Mustern geprägt sind. Genau an dieser Stelle setzt Prophet an – ein Open-Source-Tool, das von Facebook (heute: Meta) speziell für die Anforderungen in der Unternehmenspraxis entwickelt wurde.

Prophet richtet sich ausdrücklich an Anwenderinnen und Anwender aus Business, Controlling und Data Analytics, die Forecasts erstellen möchten, ohne sich tief mit statisti-

scher Modellierung auseinandersetzen zu müssen. Im Gegensatz zu ARIMA verlangt Prophet keine Stationarität, geht flexibel mit Feiertagen, saisonalen Mustern und Strukturbrüchen um und liefert automatisch interpretierbare Komponenten wie Trend, Saisonalität und besondere Effekte. Das ist besonders hilfreich, wenn die Prognose nicht nur als Zahl im Reporting stehen, sondern auch visuell und inhaltlich nachvollziehbar erklärt werden soll.

Prophet basiert auf einem additiven Modell, das sich aus Trend, Saisonalität und Feiertagseffekten zusammensetzt. Die Zeitreihe wird also als Summe dieser Komponenten modelliert – ein Ansatz, der nicht nur intuitiv, sondern auch transparent ist. Hinzu kommt: Prophet ist als Open-Source-Projekt kostenlos verfügbar und profitiert von einer aktiven Entwicklergemeinschaft. Der Quellcode liegt offen auf der Plattform GitHub, sodass Fehler schneller behoben, Funktionen erweitert und die Nutzung frei an individuelle Anforderungen angepasst werden kann – ein Vorteil, der gerade in der zunehmend digitalisierten und datengetriebenen Controlling-Welt an Bedeutung gewinnt.

Bei der Vorhersage in **Abb. 4** sind auch die Konfidenzintervalle mit eingezeichnet, die eine mögliche Schwankungsbreite der vorhergesagten Tagesumsätze verdeutlichen. Die Ausschläge sind etwas breiter als im ARIMA-Modell und für die Erstellung war keine separate Untersuchung auf Stationarität oder Saisonalität notwendig – Prophet hat dies automatisch erledigt.




Abb. 4: Prognose der nächsten zwei Wochen mit Prophet, inklusive Konfidenzintervall

Mit ARIMA und Prophet stehen Controllern zwei leistungsfähige Werkzeuge zur Verfügung, um Zeitreihen nicht nur zu analysieren, sondern auch fundierte Prognosen zu erstellen. Während ARIMA auf einem klassischen, statistisch sauberen Fundament basiert und bei gut vorbereiteten

Zeitreihen hervorragende Ergebnisse liefert, überzeugt Prophet durch seine Praxisnähe, Flexibilität und Automatisierung – ideal für den Einsatz in realen Unternehmensdaten, die nicht immer „lehrbuchkonform“ sind. Beide Ansätze zeigen: Zeitreihenprognosen müssen nicht kompliziert

sein – vorausgesetzt, man versteht die Struktur der Daten und wählt das passende Modell. ■

Fußnote

1 <https://github.com/facebook/prophet>

Impressum

ISSN 1616-0495_ 51. Jahrgang

Herausgeber

RA Conrad Günther,

Vorstandsmitglied des Verlags für ControllingWissen AG, Wörthsee

Redaktion

RA Conrad Günther,

conrad.guenther@vcw.de

Susanne Eiselmayer,

susanne.eiselmayer@vcw.de

Günther Lehmann,

guenther.lehmann@haufe-lexware.com

Verlagssitz

VCW Verlag für ControllingWissen AG

Munzinger Str. 9, 79111 Freiburg i. Br.

Internet: <https://vcw.de> | E-mail: info@vcw.de

Tel.: 08153 / 8041 oder 0761 / 898-0

Abonnenten-Service

Silvia Fröhlich,

0800 - 72 34 269, silvia.froehlich@vcw.de

Magazingestaltung

Susanne Eiselmayer,

susanne.eiselmayer@vcw.de

Die Zeitschrift ist Organ folgender Organisationen:

Internationaler Controller Verein eV,

München, www.icv-controlling.com

RMA Risk Management & Rating Association e.V.,

München, www.rma-ev.org

Die Mitglieder erhalten das Controller Magazin im Rahmen ihres Mitgliedsbeitrags.



Wir versenden klimafreundlich mit der Deutschen Post



Literaturforum

Dipl.-Betriebswirt Alfred Biel,

Fachjournalist (DFJS),

Beethovenstraße 275, 42655 Solingen,

alfred.biel@gmx.de

Anzeigenverkaufsleitung

Thomas Horejsi,

Tel 0931 27 91-451

thomas.horejsi@haufe-lexware.com

Haufe-Lexware GmbH & Co. KG,

John-Skilton-Straße 12, 97074 Würzburg

Anzeigenverkauf

Annette Förster,

Tel 0931 27 91-544

annette.foerster@haufe-lexware.com

Anzeigen Stellenmarkt

Eva Hofmann,

Tel 0931 27 91-558

stellenmarkt@haufe.de

Anzeigendisposition

Jonas Miller,

Tel 0931 27 91-457

jonas.miller@haufe-lexware.com

Konzept und Design, Herstellung Magazin

Gestaltung Titel und Sonderteil RMA sowie ICV

deyhle & löwe Werbeagentur GmbH,

www.deyhleundloewe.de

Druck

Grafisches Centrum Cuno GmbH & Co. KG,

39240 Calbe (Saale), Tel 039291/428-0

Erscheinungsweise

6 Ausgaben pro Jahr: Januar, März, Mai, Juli, September, November

Online-Archiv

Als Abonnent des Controller Magazins können Sie exklusiv auf das gesamte digitale Archiv der Zeitschrift seit 1975 zugreifen.

Die Online-Ausgabe finden Sie unter www.controllermagazin.de

Online-Shop

<http://shop.haufe.de/controller>

Bezugsgebühr pro Jahr im Abonnement € 248,-

zuzüglich € 9,90 Portopauschale

Jahresabonnement Digital € 238,-. Die Preise enthalten die USt.

Sollte das CM ohne Verschulden des Verlags nicht ausgeliefert werden, besteht kein Ersatzanspruch gegen den Verlag.

Durch die Annahme eines Manuskriptes oder Fotos erwirbt der Verlag das ausschließliche Recht zur Veröffentlichung.

Nachdruck (auch auszugsweise) nur mit Zustimmung der Redaktion.

Bildnachweis

iStock