

Paladin Forecast

Bewertung der Vergangenheit mit belastbarer
Einschätzung der Zukunft.

Die Situation

Prognosemodelle werden in den meisten Fällen aus den Daten der Vergangenheit so hergeleitet, dass diese einfach nur übertragen und mit einem Wachstumsfaktor angepasst werden.

Unsere Lösung

Paladin Forecast unterstützt Sie mit Hilfe stochastischer Methoden bei der Risikoanalyse von Vergangenheit und Gegenwart und liefert belastbare Prognosen Ihrer Geschäftsentwicklung. Paladin Forecast kann auf jede Datenbasis angewendet werden, unabhängig, ob die Daten in relationaler oder multidimensionaler Form vorliegen. Die Ausgangsdaten werden aus Ihren Systemen extrahiert und dem Paladin-Modul für Analyse und Forecast zur Verfügung gestellt. Die Ergebnisse können dem Quellsystem wieder zurückgegeben werden.

Die Methode des Bayesian Forecast

Die Bayes-Statistik ist nach Thomas Bayes (1701-1761) benannt. Im Unterschied zur frequentistischen Statistik wird im bayesianischen Ansatz Unsicherheit bzw. Vorwissen über Modellparameter durch eine A-priori-Wahrscheinlichkeitsverteilung quantifiziert. Mit der Information in den Daten, ausgedrückt durch die Datendichte oder Likelihood-Funktion, kann daraus nach dem Bayes-Theorem die A-posteriori-Verteilung bestimmt werden. Die Bayes-Inferenz basiert ausschließlich auf der A-posteriori-Verteilung der Zufallsvariablen.

Der statistische Ansatz nach Bayes kombiniert das A-priori- und das A-posteriori-Wissen, um Zeitreihen zu modellieren. Das Hauptprinzip für Forecasts ist es, ein Modell zu finden, das bestmöglich die Zukunft vorhersagt, nicht bestmöglich die Vergangenheit abbildet.

Es erfolgt eine Berücksichtigung der Vergangenheit derart, dass Ereignisse bzw. Datenpunkte geringer gewichtet werden je weiter sie in der Vergangenheit liegen. Gesetzmäßigkeiten aus der Vergangenheit, die voraussichtlich auch für die Zukunft gelten werden, können dem Modell als Parameter mitgegeben werden. Das kann zum Beispiel die Periodizität der Daten sein (z.B.: Jahresverlauf oder saisonale Wiederholung) oder aber auch eine Aussage, mit welcher Wahrscheinlichkeit der Vorhersagekorridor stimmen soll.

Paladin Forecast

Bewertung der Vergangenheit mit belastbarer
Einschätzung der Zukunft.

Die Arbeit mit Paladin Forecast

Meist unterliegen die Datenreihen z.B. für Produkte bestimmten Gesetzmäßigkeiten. So ist z.B. bei vielen Produkten eine Periodizität über zwölf oder weniger Monate zu verzeichnen, es gibt konstante oder lineare Kurvenverläufe und vieles mehr.

Diese Parameter können manuell und individuell für jedes Produkt festgelegt werden oder aber sie werden automatisch durch das System ermittelt. So kann z.B. festgelegt werden, wie die Daten der näheren und fernen Vergangenheit gewichtet werden sollen.

Viele weitere Parameter können angegeben werden. Falls zu einigen Parametern keine Aussage gemacht werden kann, werden stattdessen standardisierte Werte in die Berechnung einbezogen.

Sie haben die Möglichkeit, zunächst die Vergangenheitsdaten kritisch zu betrachten und zu entscheiden, welche außergewöhnlichen Ereignisse Ihre Daten beeinflusst haben. Sie können diese Ereignisse bewerten und somit eine von allen Sondereinflüssen freie Vergangenheit simulieren. Diese simulierte Vergangenheit wird dann mit Hilfe des Bayesian Forecast in die Zukunft projiziert. Dazu ermittelt der Paladin Forecast automatisch, welche Parameter für den betrachteten Datensatz die besten Ergebnisse erzielen und setzt diesen Parametersatz für die Vorhersage ein.

Nachdem Paladin Forecast aus den bestehenden Daten Trends ermittelt in die Zukunft projiziert hat und anschließend diese Daten in Ihr Controlling-System übertragen hat, können Sie wiederum eingreifen und diese um Ihr Expertenwissen erweitern. Sie kennen Ihr Geschäft und wissen, welche außergewöhnlichen Ereignisse (z.B. Auslaufen eines Patentes oder Erschließung eines neuen Marktes) in der Zukunft zu erwarten sind. Diese können Sie - einschließlich Kommentierung - in das System eingeben. Es erfolgt dann eine erneute Ermittlung der Zukunftsdaten unter Berücksichtigung Ihres Expertenwissens. Das System fordert Interaktivität - so können wissenschaftliches Forecasting und Expertenwissen zusammengeführt werden.

Ihr Mehrwert

Die Arbeit beginnt mit der Analyse der Vergangenheit und Gegenwart. Hier gewinnen Sie bereits wichtige Risikodaten (alternative Ergebnisse). Die mittels Bayesian Forecast automatisiert ermittelten Daten besitzen erfahrungsgemäß eine um ca. 30 % höhere Treffsicherheit verglichen mit den Ergebnissen einer manuell ermittelten Prognose.

Gerne testen wir das mit Ihren Daten, indem wir die letzten Monate der Vergangenheit als Prognosezeitraum definieren, um dann genau mit diesen bereits vorliegenden Ist-Werten die Qualität des Forecasts zu bewerten.

Beispielsweise können Sie Ihre Materialbeschaffung, Personalkapazitäten und Lagerhaltung optimieren. Weiterhin können Sie mehr verkaufen, weil es zu weniger Engpässen kommt - sie haben eine belastbare Voraussage der Zukunft. Nicht zuletzt haben Produktmanager oder Controller weit weniger Arbeit - den Großteil der Prognosearbeit erledigt Paladin Forecast.

Bayesian Forecasting and Dynamic Models

Second Edition, Mike West, Jeff Harrison, 1999. Springer-Verlag New York:
Chapter 2: Introduction to the DLM, pages 39-44
Übersetzung: Hermann Wandelt

West & Harrison sagen zu Beginn des 2. Kapitels ihres Buches, auf das wir uns hier beziehen und dem auch das Beispiel entnommen ist:

Das folgende Beispiel eines DLM (Dynamic Linear Model) ist ein einfaches, jedoch keineswegs triviales Zeitreihenmodell.

Die Beobachtungsgleichung Y_t wird dargestellt als Zeitreihe,

$$Y_t = F_t \mu_t + v_t, v_t \sim N[0, V_t]$$

mit μ_t als lokalen Mittelwert der Reihe Y_t und dem Beobachtungsfehler v_t . Der lokale Mittelwert μ_t wird ebenfalls als Reihe dargestellt und repräsentiert ein einfaches Random-Walk-Modell:

$$\mu_t = \lambda \mu_{t-1} + \omega_t, \omega_t \sim N[0, W_t]$$

Die beiden Vorfaktoren λ und F_t , als Folge, werden in dem hier betrachteten Beispiel auf konstant Eins gesetzt. Die Unsicherheiten in beiden Gleichungen werden durch den Beobachtungsfehler v_t und den Entwicklungsfehler ω_t repräsentiert und entsprechen einer Normalverteilung um den Erwartungswert 0 mit der Varianz V_t bzw. W_t .

Das Beispiel

Ein pharmazeutisches Unternehmen vertreibt KURIT, ein ethisches Medikament, welches zurzeit im Mittel mit 100 Einheiten pro Monat umgesetzt wird. Empfehlungen aus der Medizin führten zu einer neuen Beschreibung des Produkts mit erweiterten Einsatzmöglichkeiten. Deshalb wird für dieses Produkt mit einer größeren Nachfrage im Markt gerechnet. Es besteht Übereinstimmung, dass ab Januar ($t = 1$), dieses Produkt in einer neuen Verpackung das gegenwärtige Produkt ersetzen soll. Preis und der Name KURIT bleiben jedoch gleich. Für die Planung der Produktion, die Lagerhaltung und die Rohstoffbeschaffung ist eine kurzfristige Prognose der zu erwartenden Nachfrage gefordert. Das Medikament wird von den Patienten regelmäßig angewendet, so dass die Nachfrage über die Zeit als konstant angesehen werden kann. Daher wird für die monatlichen Umsätze ein DLM 1. Ordnung angenommen. Es wird erwartet, dass die Umsatzschwankungen und zu beobachtende Variationen der Nachfrage von Monat zu Monat wesentlich die Variation des Grundniveaus der Nachfrage übersteigt, so dass W (Systemvarianz) klein ist im Vergleich mit V (Beobachtungsvarianz). Darum wird das DLM $\{F_t=1, \lambda=1, V_t=100, W_t=5\}$, welches erfolgreich für das bisherige Produkt Verwendung fand, beibehalten.

Month	Forecast Distribution		Adaptive Coeff.	Datum	Error	Posterior Information	
	Q_t	f_t				A_t	Y_t
0						130.0	400
1	505	130.0	0.80	150	20.0	146.0	80
2	185	146.0	0.46	136	-10.0	141.4	46
3	151	141.4	0.34	143	1.6	141.9	34
4	139	141.9	0.28	154	12.1	145.3	28
5	133	145.3	0.25	135	-10.3	142.6	25
6	130	142.6	0.23	148	5.3	143.9	23
7	128	143.9	0.22	128	-15.9	140.4	22
8	127	140.4	0.21	149	8.6	142.2	21
9	126	142.2	0.21	146	3.8	143.0	20
10	125	143.0	0.20				

Tabelle 2.1 KURIT Beispiel

Im Dezember, ($t = 0$), halten Marktexperten eine Steigerung der Nachfrage um 30 % auf 130 Einheiten pro Monat, für sehr wahrscheinlich. Eine Abweichung um mehr als 10 Einheiten nach unten oder 70 Einheiten nach oben hält man jedoch für unwahrscheinlich. Die sich daraus ergebende Spanne von 80 Einheiten repräsentiert vier Standardabweichungen für μ_0 .

Daher kann die Annahme des Unternehmens vor dem Start wie folgt beschrieben werden:

$$m_0 = 130 \text{ und } C_0 = (80/4)^2 = 400, \text{ so dass } (\mu_0 | D_0) \sim N[m_0, C_0] = N[130, 400].$$

Folglich, das Modell für den Umsatz Y_t im Monat t ist:

$$\begin{aligned} Y_t &= \mu_t + v_t, v_t \sim N[0, 100], \\ \mu_t &= \mu_{t-1} + \omega_t, \omega_t \sim N[0, 5], \\ (\mu_0 | D_0) &\sim N[130, 400] \end{aligned}$$

Dass, das Signal-to-noise Verhältnis $r = W/V = 0.05$ wie hier, niedrig ist, ist typisch für diese Art Anwendungen.

Anmerkung des Übersetzers:

Da dieses Verhältnis von System- zu Beobachtungsvarianz, sein Grenzverhalten und Konvergenz zum tieferen Verständnis von Bedeutung ist, sei auf den Abschnitt 2.3.3 des Buches verwiesen, in dem das Theorem und der Beweis zu finden sind.

Beobachtungen über die nächsten paar Monate und die verschiedenen Komponenten der Ein-Schritt-Prognose und die sich wiederholenden Schritte der Aktualisierung sind in der Tabelle 2.1 gegeben.

Die Graphik (Figure) 2.3 (Die Nummerierung erfolgt im Sinne des Buches von West und Harrison) zeigt Y_t und f_t in Abhängigkeit von t .

Beide Graphiken beziehen sich auf die Daten der Tabelle 2.1 bis September ($t = 9$).

Die Annahme des Unternehmens zum Zeitpunkt t_0 , die Nachfrage betreffend, war lebenswichtig für die folgenden Entscheidungen bezüglich der Produktion und der Bevorratung des Produkts. Der Einfluss dieser teils subjektiven Annahme wird rapide weniger, sobald Beobachtungsdaten (Y_t) verwendet werden.

Zum Beispiel (s. Tabelle 2.1):

Der Anpassungskoeffizient A_1 hat den Wert 0.8, so dass

$$m_1 = m_0 + 0.8e_1 = (4Y_1 + m_0) / 5$$

Folglich hat die Januarbeobachtung 4-mal das Gewicht des prior Mittelwertes m_0 in der Berechnung des posterior Mittelwertes m_1 . Bei $t = 2$ und $A_2 = 0.46$ setzt sich m_2 wie folgt zusammen:

$$m_2 = m_1 + 0.46e_2 = 0.46Y_2 + 0.43Y_1 + 0.11m_0,$$

So ist Y_2 relativ hoch gewichtet, während m_0 nur noch zu 11% an den in m_2 beinhalteten Informationen beiträgt.

Wenn t größer wird, zerfällt A_t zusehends auf einen Grenzwert nahe 0.2.

In der Tat, der Abschnitt mit dem oben erwähnten Beweis, 2.3.3 Limiting Behaviour and Convergence, zeigt, dass A_t in diesem Beispiel gegen exakt $A = 0.2$ konvergiert.

Der Koeffizient von m_0 in m_t ist:

$$(1 - A_t)(1 - A_{t-1}) \dots (1 - A_1),$$

so dass m_0 nur 1% der Information zur Errechnung von m_{10} beiträgt und mit ansteigendem t die Relevanz des subjektiven Prior (der Annahme) gegen 0 strebt.

Intervention, um externe Information zu integrieren.

Ein geschlossenes Modell ist unklug. Es verbietet die Verwendung von zusätzlichen externen Informationen, die für den Umgang mit außergewöhnlichen Umständen wichtig sind und ist für angewandte dynamische Systeme nicht akzeptabel.

Einer der großen Vorteile des bayesianischen Ansatzes liegt in der Einfachheit, mit der subjektive Information und die Information des Modells bzw. der Daten kombiniert werden können.

In dem Beispiel, bei $t = 9$, sind die (Posterior Level)- und die (one-step ahead)- Prognose-Verteilung

$$\begin{aligned} (\mu_9 | D_9) &\sim N[143, 20], \\ (Y_{10} | D_9) &\sim N[143, 125]. \end{aligned}$$

Wir nehmen an, dass uns Informationen erreicht haben über ein wichtiges Mitbewerber-Medikament, BURNIT, das aufgrund des Verdachts auf schwerwiegende Nebenwirkungen vom Markt genommen werden wird.

Es soll zum Zeitpunkt $t = 10$ geschehen, dass Patienten, denen BURNIT verschrieben wurde, zu einem Mitbewerber-Produkt wechseln. Diese Information wurde zum Zeitpunkt $t = 9$ erhalten und wird bezeichnet als S_9 . Es ist bekannt, das BURNIT gegenwärtig 50% Marktanteil besitzt. Dies veranlasst das Unternehmen zu der Annahme, dass die Nachfrage nach KURIT um 100% steigen wird,

$$E[\mu_{10} | D_9, S_9] = 286.$$

Allerdings ist die Unsicherheit in diesem Fall hoch. Die geschätzten Nachfragezunahmen reichen in der Marketing-Abteilung von pessimistischen 80 bis optimistischen 200 Einheiten.

Nach Diskussion einigt man sich für $t = 10$ auf folgende Änderungen:

$$(\omega_{10} | D_9, S_9) \sim N[143, 900],$$

führt zu den überarbeiteten (one-step ahead)-Prognose-Verteilungen

$$(\mu_{10} | D_9, S_9) \sim N[286, 900]$$

und

$$(Y_{10} | D_9, S_9) \sim N[286, 1020].$$

Die Beobachtung (Der Umsatz) $Y_{10} = 326$ impliziert $e_{10} = 40$ und

$$(\mu_{10} | D_{10}) \sim N[322, 90].$$

Man beachte, dass die konditionierte Information

$$D_{10} = \{Y_{10}, D_9, S_9\}.$$

Die Graphiken (Figures) 2.3 und 2.4 zeigen die abgesetzten Einheiten bzw. adaptiven Koeffizienten über der Zeit über die folgenden sechs Monate, von $t = 10$ bis $t = 15$.

Wenn unerwartete aber relevante externe Informationen dieser Art verfügbar werden, dann ist Intervention von herausragender Bedeutung, gute Entscheidungen zu treffen.

Wenn unerwartet, relevante externe Information dieser Art verfügbar wird, dann ist Intervention von herausragender Bedeutung, gute Entscheidungen zu treffen.

Das Beispiel zeigt, dass die Beschränkung auf die Veränderung der erwarteten mittleren Nachfrage bei einer Intervention unbefriedigend sein muss, obwohl dies unglücklicherweise ein von einigen Prognostikern akzeptierter Ansatz ist.

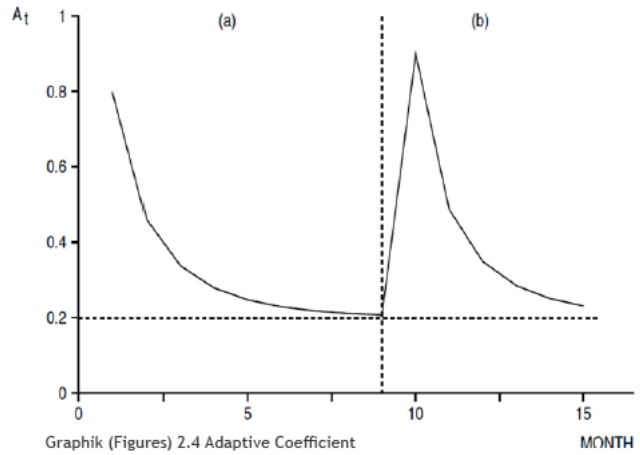
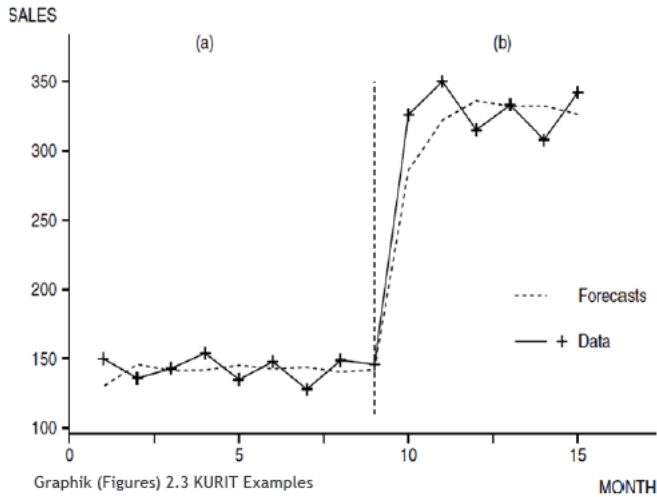
Die mit einer Intervention verbundene große Varianz reflektiert den Anstieg an Unsicherheit, führt zu geringerer Gewichtung der Daten vor der Änderung, wirkt sich schneller auf die unmittelbar bevorstehenden Prognosefehler aus und führt zu zuverlässigeren Prognoseergebnissen.

Anmerkung des Übersetzers:

Die Übersetzung dient dem Zweck, die Denk- und Arbeitsweise des bayesianischen Prognostizierens, ohne das Hindernis einer englischen Fachsprache, leichter nachvollziehen zu können. Das zu diesem Zweck ausgewählte Beispiel ist einfach aber nicht trivial! Dieses Modell entspricht durchaus einer häufig vorkommenden Praxis und ist in seiner Schlichtheit einer Reihe bestehender Prognosesysteme nicht nur ebenbürtig, sondern auch systemisch überlegen.

Vergleichen Sie: Kapitel 2.3.5 Limiting Predictors and Alternative Methods.

Die Rechenbeispiele können mit dem Programm Mathematica von Wolfram Research sowohl nachprogrammiert wie auch graphisch nachgezeichnet werden, wie die folgenden Graphiken zeigen. Dabei ist es möglich, auf jeden einzelnen Punkt in der Grafik mit dem Schieber zu gehen und sich so jede einzelne Situation anzeigen zu lassen.



```

In[1]:= Tabelle :=
(*Mit manueller Dateneingabe*)
Module[{y = {150, 136, 143, 154, 135, 148, 128, 149, 146, 326, 349, 312, 327, 309, 342},
mp = {0, 0, 0, 0, 0, 0, 0, 0, 143, 0, 0, 0, 0, 0, 0},
cp = {0, 0, 0, 0, 0, 0, 0, 0, 900, 0, 0, 0, 0, 0, 0}, m = {0, 0, 0, 0, 0, 0, 130, 400},
v = 100, w = 5, lab1 = {"KURIT, DLM[1,1,100,5]"}},
p10 = Power[10, {0, 0, 1, 2, 0, 1, 1, 0}];
m = {Round[p10 * m] / p10 // N};
n = Length[y];
i = 1; While[i <= n, It = 1;
ft = m[[i, 7]];
qt = v + w * m[[i, 8]];
at = (qt - v) / qt // N;
yt = y[[i]];
et = yt - ft;
mt = at * et + ft * mp[[i]];
ct = at + v + cp[[i]];
m = Append[m, Round[p10 * {It, qt, ft, at, yt, et, mt, ct}] / p10 // N]; i = i + 1];
m = Prepend[m, {"t", "Qt", "ft", "At", "Yt", "et", "mt", "ct"}]
]

In[2]:= ml = Tabelle;
Manipulate[MatrixForm[
{{MatrixForm[ml[[1 ;; nend]]]},
{ListLinePlot[ml[[3 ;; nend, 5]], ml[[3 ;; nend, 3]],
Axes -> True, AxesLabel -> {1, n, 1}, ImageSize -> 250, PlotStyle ->
{{PointSize[0.02], Blue}, {PointSize[0.01], Pink, Thick}}, Joined -> {False, True}},
GridLines -> Automatic, Frame -> True, FrameTicks -> Automatic, PlotLabel ->
Style[Framed["DLM[1,1,V,W]", 18, Blue, Bold, Background -> Lighter[Yellow]]]},
{ListLinePlot[ml[[3 ;; nend, 4]], ImageSize -> 250,
PlotStyle -> {{PointSize[0.02]}, {PointSize[0.02]}, Magenta, Dashed, Thick}},
GridLines -> Automatic, Frame -> True, FrameTicks -> Automatic, PlotLabel -> Style[
Framed["Adapt.Koeffizienten(At)", 18, Blue, Bold, Background -> Lighter[Yellow]]]}],
{nend, -Length[ml] + 2, -1, 1}]

```

```

In[2]:= NotebookPrint[]
In[3]:= Export["mynotebook.pdf", EvaluationNotebook[]]
mynotebook.pdf

```

Die Tabelle 2.1 KURIT Beispiel und die Graphiken 2.3 KURIT Examples, 2.4 Adaptive Coefficient (erstellt mit Mathematica Software)