



Paladin Predictive Forecast

Predictive Forecast

Ein Predictive Forecast nutzt stochastische Modelle, um zukünftige Entwicklungen effizienter zu prognostizieren, als es traditionelle Verfahren ermöglichen. Die Prognosen basieren auf historischen Daten, können im Spezialfall aber auch Echtzeitsysteme als Quelle besitzen. Die Vorhersagen können durch menschliche Interventionen und Maßnahmen adäquat an spezielle, im Modell nicht vorhergesehene Gegebenheiten, angepasst werden. Mit den Methoden des Predictive Forecast werden Prognosen exakter, Maßnahmenplanung realistischer und die Unternehmenssteuerung effizienter.

Herkömmliche FC-Strategien

Der Forecast ist der besonders dynamische Bereich zwischen dem fertigen PLAN und dem nachrückenden IST. Die einfachste Methode ersetzt die Planwerte sukzessiv durch eintreffende Ist-Werte und präzisiert so die Entwicklung des Jahresergebnisses.

Eine Verbesserung wird erreicht, indem eintreffende Erkenntnisse über die Zukunft fortlaufend den ursprünglichen Plan präzisieren. Eine weitere Ausbaustufe könnte eine kurzfristige Maßnahme-Planung im FC-Bereich sein. Diese unterschiedlichen Methoden sind vielfach erprobte Bestandteile unserer TM1-nativen Paladin-Lösungen.

Unser Bayesian-Forecast-System

Ein entscheidender Vorteil liegt darin, dass keine Einzelwerte, sondern ganze Wahrscheinlichkeits-Verteilungen prognostiziert werden. Dadurch, dass viele der in der Praxis verwendeten Forecast-Methoden als dynamisch lineares Modell formulierbar sind, sind diese als Spezialfälle (z.B. ARIMA und MLR) in unserer Lösung enthalten. Unser System kann durch entsprechende Parametrisierung auf eine große Bandbreite von Anwendungen angepasst werden.

Unser Bayesian-Forecast-System bietet eine automatische Anpassung auf die Dynamik einer Zeitreihe durch Cross-Validierung gegen Vergangenheitsdaten. Daraus folgend kann sich unser System sowohl an langfristige Trends als auch an kurzfristige Saisonalitäten anpassen, wie sie beispielsweise bei Monatswerten im Rechnungswesen auftreten.

Die flexible Wissens-Repräsentation in Form von Wahrscheinlichkeitsverteilungen erlaubt es dem System, von Experten zu lernen, die ihre Zukunftsvorhersagen meist statistisch ausdrücken (z.B. "mit 60 Prozent Sicherheit liegt unser Auftragswert für Produkt X im nächsten Monat zwischen 100.000 Euro und 150.000 Euro").

Die wissenschaftliche Basis

Das Bayesian Dynamic Forecasting System (Bayesian-Forecast-System), gemeinsam von Hermann und Prof. Benjamin Wandelt (benwandelt.org) auf der Grundlage der Publikationen von Mike West und Jeff Harrison entwickelt, ist ein mächtiges System, in dem vollständig beliebige dynamische lineare Modelle unter Verwendung des Bayes-Theorems implementiert werden können.

Das Wandelt-Modell

Das Wandelt-Modell hat die eingebaute Fähigkeit, mit realistischen Zeitreihen umzugehen. Realistische Zeitreihen sind im Allgemeinen nicht stationär, das heißt sie verändern ihre statistischen Eigenschaften über die Zeit. Außerdem spielt in der Wirtschaft nichtlineare Dynamik immer auch eine Rolle. Die Modellgleichungen des Bayesian-Forecast-System beinhalten Rauschterme, die die Nicht-Stationarität und Nichtlinearität in realistischen Systemen abbilden.

Die flexible Wissens-Repräsentation in Form von Wahrscheinlichkeitsverteilungen erlaubt es dem System nicht nur aus Vergangenheitswerten, sondern auch von Experten zu lernen, die ihre Zukunftsvorhersagen meist statistisch ausdrücken (z.B. "mit 60 Prozent Sicherheit liegt unser Auftragswert für Produkt X im nächsten Monat zwischen 100.000 Euro und 150.000 Euro").

Professor Benjamin Wandelts Forschung in theoretischer, numerischer und statistischer Astrophysik verbindet Fundamentalphysik und Kosmologie mit astronomischen Daten, die von Sternen bis hin zu den größten Skalen reichen, die für Beobachtungen zugänglich sind. Er leitet eine Forschungsgruppe in der etwa 15 Doktoranden promoviert haben und in der eine ähnliche Anzahl promovierter Jungwissenschaftler gearbeitet haben, die ihrerseits jetzt sowohl in der Wissenschaft als auch in der Wirtschaft in führenden Positionen tätig sind.

Professor Wandelts Motivation, in diesem Projekt mitzuarbeiten ist das Interesse daran, seine erfolgreichen Methoden der statistischen und numerischen Analyse, sowie der künstlichen Intelligenz und des Maschinenlernens aus der Astrophysik und Kosmologie in die Wirtschaft zu übertragen.

Die zentrale Problematik

Im Bereich der Entscheidungsunterstützung durch Methoden des modernen Maschinenlernens in den Datenwissenschaften (Data Sciences) existieren zwei fundamentale Problematiken:

Entscheidungen unter Unsicherheit

Oft liefern Methoden des Maschinenlernens Ergebnisse aus denen nicht zu erkennen ist, wie risikobehaftet oder verlässlich sie wirklich sind. Zu dieser Problematik gibt es derzeit an der Forschungsspitze viele Teilantworten, meist in naturwissenschaftlichen und ingenieurwissenschaftlichen Anwendungen. Unsere Ambition ist die standardisierte quantitative Berücksichtigung der Unsicherheit in den zur Verfügung stehenden Informationen und der Modellauswahl.

Interpretierbarkeit

Künstliche Intelligenzen erzielen oft beeindruckende Ergebnisse. Dennoch ist die Interpretation der automatisch erstellten Modelle schwierig bis unmöglich. Die fehlende Möglichkeit, diese Black Box zu öffnen bleibt ein fundamentales Problem.

Gerade wenn Forecasting-Methoden zur Entscheidungsfindung genutzt werden sollen, fehlt dem Anwender die Möglichkeit, die Ergebnisse zu verifizieren. Hier entsteht beim Planer eine schwer zu überwindende Barriere beim Einsatz von künstlicher Intelligenz.

Es stellt sich die Frage der Akzeptanz eines Analyse- bzw. Forecast-Ergebnisses, beispielsweise wenn berechtigterweise nach den Gründen für einen Investitionsvorschlag gefragt wird, bei dem signifikantes Kapital riskiert werden soll.

Unser Lösungsansatz

Mit unserer Lösung treten wir dieser fehlenden Interpretierbarkeit konsequent entgegen, indem wir ein datengetriebenes Modell aus klar definierten Grundbausteinen errichten, deren jeweilige Funktion klar definiert und verständlich dargestellt wird.

Modellbasierte Vorhersage auf Grund von Vergangenheitsdaten

Unser bayesianisches Prognosesystem implementiert auf mathematisch fundierte Weise die modellbasierte Vorhersage auf Grund von Vergangenheitsdaten. Die Parameter des dynamischen Modells werden mit in jedem Schritt angepasst. Zu jedem Zeitpunkt können Prognosen aufgrund der gerade bestehenden Parameterschätzungen vorwärtsgerechnet werden (Forward Modeling). Dabei werden in der Vorhersage die Unsicherheiten der Parameter, als auch der Messwerte berücksichtigt. Dieser Ansatz erlaubt die Punktvorhersage einer möglichen Zukunftsentwicklung und darüber hinaus die Entwicklung der gesamten Wahrscheinlichkeitsverteilung der Zielgrößen. Das erlaubt signifikante empirische Entscheidungsunterstützung in der Planung.

Unsere dynamischen Modellbausteine beschreiben die konstante, lineare oder quadratische Entwicklung über die Zeit, sowie Trendmodelle und Saisonalitäten mit beliebigen Intervallen (z.B. 7 Tage, mehrere Wochen, Monate oder Jahre). Darüber hinaus sind die einzelnen Modellbausteine so konzipiert, dass sie beliebig zu komplexeren Modellen (z.B. mit multiplen Trends und Saisonalitäten) kombiniert werden können.

Robuster Forecast durch Diagnostik von Ausreißern und punktaktigen Marktveränderungen

Innerhalb jedem dieser Modellbausteine können Bruchstellen in den Daten, an denen sich Modellparameter sprunghaft ändern, oder punktuelle Ausreißer automatisch erkannt werden. Das führt einerseits zur schnellen Anpassung an neue Gegebenheiten, andererseits zu robusten Vorhersagen, die nicht durch einzelne Ausreißer (Fehlein-gaben oder Ausnahmesituationen) gestört werden.

Die daraus hervorgehende Forecast-Genauigkeit dient der Diagnostik, z.B. der Erkennung von Veränderungen oder von Ausreißern in den Daten. So können beispielsweise fehlerhaft erfasste Daten aufgespürt werden.



*Wir präsentieren gern remote oder bei Ihnen vor Ort!
Sprechen Sie uns an!*

+49 211 9708 140

Bayes FC auf TM1-Daten

IBM stellt in den aktuellen PAW-Versionen seinen ersten Prototypen von Predictive Forecast zur Verfügung. Dieser Prototyp arbeitet jedoch nur im PAW-Front-End. Eine einzelne Zeitreihe kann analysiert und in die Zukunft projiziert werden. Das verwendete Programm, die Zwischenergebnisse pro Zeitpunkt und die Wahrscheinlichkeitsverteilungen bleiben verborgen und kommen auch nicht in das TM1-Modell zurück. Der OLAPLINE-Ansatz geht hier viel weiter.

TM1-Planungssysteme mit voll integriertem Bayesian Forecast

Die komplette Analyse jeder Zeitreihe bleibt erhalten und wird im TM1-Modell vorgehalten. Ebenso bleiben alle Teilergebnisse einschließlich Wahrscheinlichkeitsverteilung der Prognose im TM1-Modell erhalten.

Die Prognosen können im Zusammenhang mit Datenimporten im Stapel aktualisiert werden. Weil alle Zwischenergebnisse im TM1-Modell erhalten bleiben, kann die Prognose ab dem Zeitpunkt x für den folgenden Zeitpunkt $x+1$ weitergerechnet werden. Somit eignet sich unsere Methode im Zusammenhang mit TM1 sowohl für automatisches Forecasting von Massendaten als auch für detaillierte Planungsaktivitäten auf einzelnen Zeitreihen im Zusammenhang mit Interventionen.

Weil wir diese Methoden selbst umgesetzt haben, können wir weitere hinzufügen und so jede Aufgabenstellung bis hin zu intensiver Zusammenarbeit mit der Spitzenforschung erfüllen.

FC berechnen

TM1-Datenmodelle sind sauber strukturiert. Sie unterscheiden zwischen Meta-Daten und Daten. Importe aus VORSYSTEMEN sind gleichzeitig Aufbereitung und Prüfung von Daten. Zu diesem Standard für OLAP-Systeme kommen nunmehr die Auswertung der importierten Zeitreihen auf jedem Punkt der Zeitreihen, so dass in zugehörigen Auswertungen weitere Informationen wie z.B. die Evidenz etc. zur Verfügung stehen. Die IST-Zeitreihen können per Forecast in die Zukunft projiziert werden. Auch hier stehen ganze Wahrscheinlichkeitsverteilungen parallel zur Verfügung.

Diese Zusatzinformationen auf jedem Datenpunkt der Zeitreihe werden in einer zusätzlichen Dimension abgebildet.

Die Berechnung der Zeitreihen kann im Stapel oder in einzelnen Durchläufen pro Zeitreihe erfolgen. Sie müssen beliebig oft erfolgen können und bei Wiederholung zu gleichem Ergebnis führen.

Intervention

Die Intervention wird wie ein zusätzlicher Plan gehandhabt. In der Dimension Wertart (Plan, IST) wird jeweils ein zusätzliches Element Intervention sowohl zum IST als auch zu den Plänen angelegt. Die dort abgelegten Interventionen werden in die jeweiligen Forecast-Berechnungen einbezogen.

So können im IST die Ausreißer kompensiert und in der Planung das Expertenwissen des Planers einbezogen werden.

Jede Eingabe einer Intervention kann mit einem FC-Lauf auf dieser Zeitreihe abgeschlossen werden.

Optimierung der FC-Programme

Für jede Zeitreihe wird ein Forecast-Modell in Form eines Parametersatzes vorgehalten. Jeder einzelne Parameter steuert eine Komponente des Bayesian Forecast Modells. Am Anfang wird das Modell einer Vergleichszeitreihe verwendet. Durch die Suche nach dem optimalen Modell wird das Programm im Laufe der Zeit verbessert. Somit benötigen wir für jede Zeitreihe einen Parametersatz. Vermutlich sollte der Parametersatz für das laufende Jahr eingefroren werden, so dass auch noch eine Jahresdimension angebracht erscheint.

Die Optimierung der Programme erfolgt in zusätzlichen Verarbeitungsschritten. Die Optimierung kann pro Zeitreihe oder als Batch angestoßen werden.

Integration in Paladin-Framework

Das Bayesian Forecast Modul besteht aus drei Komponenten:

- TM1-Strukturen und Prozesse,
- Transfertechnologien,
- Bayes-Modul im Umfeld.

Die zusätzlichen TM1-Strukturen beschränken sich auf einige FC-Dimensionen und FC-Cubes, wobei einige Dimensionen des Zielsystems mitverwendet werden.

Die Transfertechnologien sind dazu geeignet, große Datenmengen in kürzester Zeit zwischen den Systemen auszutauschen.

Das Bayes-Modul ist ein Dienst, der die Forecast-Berechnungen und auch die Optimierung der Programme nach Anforderung einzeln oder im Batch erledigt.



*Wir präsentieren gern remote oder bei Ihnen vor Ort!
Sprechen Sie uns an!*

+49 211 9708 140