

Aufgabenstellung

Die Basis zur Prüfung der Prognosegenauigkeit unseres Produktes deepRetail sind Daten von 17 Unternehmen aus dem deutschen Textilhandel.

Warenwirtschaftssysteme bilden lediglich den Iststand der Vergangenheit bis zur Gegenwart ab, bieten jedoch keine wirksamen Instrumente zur Steuerung des Warenflusses durch Prognosen. Es stellt sich daher die Frage, wie genau durch Künstliche Intelligenz erstellte Prognosen den Warenabsatz vorhersagen können.

Aufgrund der vielfältigen Warensortimente pro Unternehmen wurden neben übergreifenden Gesamt-Prognosen auch Prognosen per Warengruppe und Marke erstellt. 400 Modelle für die verschiedensten Szenarien wurden berechnet, mit Szenarien wie *Unternehmen A | Marke B | Damenblusen, Unternehmen X | Marke Y | Herrenjacken* etc.

3 getestete Prognosezeiträume

- Ein kürzerer Vorhersagezeitraum von 1 Monat erlaubt die Vermeidung potenzieller Out-of-stock Situationen.
- Ein mittlerer Vorhersagezeitraum von 3 Monaten erlaubt die Reduktion von Überhang, z.B. mittels Preissteuerung oder Marketingmaßnahmen.
- Ein längerer Vorhersagezeitraum von 9 Monaten unterstützt den Saisoneinkauf und das Erstellen fundierter Einkaufs-Budgets.

Bereitgestellte Daten

Es standen uns zur Verfügung:


30 GB an Verkaufsdaten aus rund 10 Mio. Transaktionen über 3 Jahre von 17 Retailern mit 62 Stores und einem Gesamtumsatz von 250 Mio €, 500.000 verschiedene Artikel und 744 Marken, 730.000 Kundenkarten.

Die Datenbasis ist daher äußerst repräsentativ.

Ergebnis

Die Prognosegenauigkeit aller Szenarien wurde durch Vergleich mit den tatsächlichen Ist-Werten gemessen. Je niedriger der mittlere relative Fehler zwischen Prognose und tatsächlichem Umsatz, desto besser ist ein Modell.

Weiters wurde für die 9-Monats Prognose der Fehler gemessen, der durch die häufig zu beobachtende Heranziehung des Vorjahresergebnisses als Basis für eine Saisonschätzung entsteht.



Die Modelle sind nach Performance sortiert, links befinden sich die besten Modelle mit dem niedrigsten Fehler. Für jedes Szenario von *Unternehmen | Marke | Warengruppe* wurden 3 verschiedene Prognosezeiträume erstellt (1 Monat, 3 Monate und 9 Monate).

Je länger der Prognosezeitraum, desto größer ist der Prognosefehler. Die Prüfung der Prognosen mit den schlechtesten Ergebnissen ergab **zwei wesentliche Fehlerquellen: schlechte Datenqualität und geringe Datendichte** aufgrund niedriger Verkaufszahlen bei Randprodukten.

Im Vergleich mit der manuellen Alternativmethode, die Vorjahresergebnisse als Basis für eine Saisonschätzung heranzuziehen, wird der Fehler durch den Einsatz von deepRetail halbiert.


Drei Viertel der 1-Monats Prognosen liegen unter 10% mittlerer relativer Abweichung von den tatsächlichen Verkaufszahlen.

Die Hälfte liegt unter 5%.

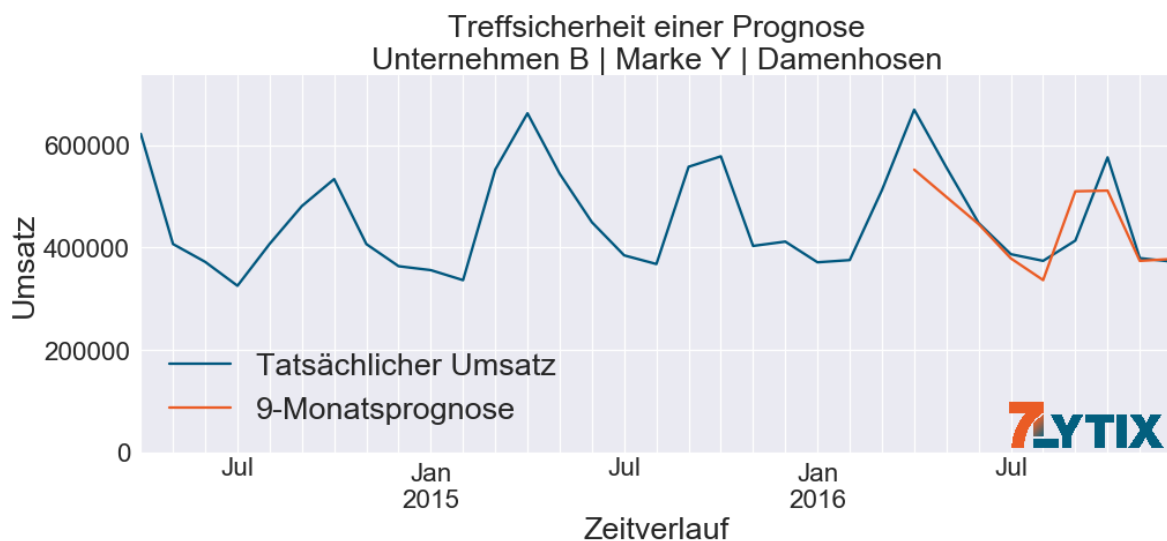
Die kurzfristige Prognosegenauigkeit lässt sich durch Einbeziehung von Wetterdaten, die langfristig durch Berücksichtigung äußerer Einflussfaktoren (Kalendarische Informationen, Großereignisse, Wirtschaftsdaten u.a.) noch weiter steigern.

Beispielszenarien

Damenblusen, Prognosezeitraum 9 Monate: mittlerer Prognosefehler 5 %



Damenhosen, Prognosezeitraum 9 Monate: mittlerer Prognosefehler 8,5 %



Wirtschaftlichkeit von Prognosen mit deepRetail

Die **Kosten von deepRetail** betragen **erfahrungsgemäß 5-20 % der Ertragssteigerung** durch verringerte Abschriften und Vermeidung von Nullbeständen.

Technologie

Die Modell-Berechnungen erfolgen über die Microsoft Azure-Cloud. Es wird ausschließlich Open Source Software (Python, Neuronale Netze, Deep Learning, div. Machine Learning-Libraries) verwendet. Der Datenzugang erfolgt durch Schnittstellen zum ERP, Warenwirtschaftssystem oder Data Warehouse des Kunden.