



**Sieben drängende Einzelhandelsfragen,
auf die maschinelles Lernen Antworten
geben kann**



Zebra
Prescriptive Analytics™
Powered by Zebra Savanna™



In diesem eBook werden folgende Themen behandelt:

- Sieben Fragen, die Einzelhändler beantworten müssen, um erfolgreich zu sein
- So kann maschinelles Lernen helfen, Antworten zu finden
- So steigern die Antworten Gewinne und Margen und bieten andere Vorteile

Einführung

Der Konkurrenzdruck im Einzelhandel ist heute so hoch wie nie zuvor: Margen und Gewinne werden durch Preisschlachten immer weiter erodiert, und sparsame Kunden erwarten, dass jeder Wunsch sofort erfüllt wird.

Die gute Nachricht für Einzelhändler: Ihnen stehen zahlreiche Tools zur Verfügung, um den Umsatz zu steigern, Verluste zu reduzieren und Risiken zu vermeiden. Besonders hervorzuheben ist hierbei das maschinelle Lernen, ein Bereich der künstlichen Intelligenz (KI), bei dem es darum geht, dass Maschinen „lernen“, Muster und Zusammenhänge zu erkennen sowie Daten ohne spezifische Programmierung auf bestimmte Art und Weise zu verarbeiten. Vor allem in Kombination mit Prescriptive Analytics kann maschinelles Lernen ein pragmatischer KI-Ansatz sein, der im Einzelhandel hilft, Verbesserungspotenzial aufzudecken.

In diesem Dokument werden sieben zentrale Fragen behandelt, auf die maschinelles Lernen Antworten geben kann.



Sieben Fragen, auf die maschinelles Lernen Antworten geben kann


1

Welche Trends können zur Umsatzsteigerung genutzt werden?



2

Wie hoch sind die tatsächlichen Kosten von Bestandsmangel?



3

Wie lassen sich anhand von Online-Rezensionen Filialen oder Produkte mit hohem PR-Risiko identifizieren?




4

Welche ungewöhnlichen Verhaltensweisen in meinem Unternehmen sind potenziell schädlich?



5

Sind Schwund und Risiken vorhersehbar und vermeidbar?



6

Bei welchen Kassenmitarbeitern kommt es zu Betrug oder Compliance-Verstößen?



7

Wie lässt sich das Risiko beim Verkauf von Rauschmitteln mindern?



Frage 1



Welche Trends können zur Umsatzsteigerung genutzt werden?

Im Kampf um immer höhere Verkaufszahlen geben Trends Einzelhändlern wichtige Hinweise. Einige Beispiele: Was wird in bestimmten Regionen am meisten gekauft? Welche Werbeaktionen oder Coupons motivieren Kunden, mehr Geld auszugeben? Wie wirken sich Demografien auf das Einkaufsverhalten von Kunden aus? Bisher konnten diese Fragen durch einen Blick auf historische Trends beantwortet werden. Leider sind solche Daten vor allem heutzutage nicht mehr sehr zuverlässig, da sich Situationen niemals genau wiederholen (Mitbewerber passen ihre Strategien an, die Vorlieben von Verbrauchern ändern sich usw.). Deshalb ist es nicht empfehlenswert, Vorhersagen aufgrund von historischen Daten zu treffen.


Zum Glück lässt sich dieses Problem umgehen. Die fortschrittlichsten Modelle zum maschinellen Lernen nutzen das sogenannte „Clustering“, um positive Trends wie die oben genannten zu verstehen und zur Umsatzmaximierung zu nutzen.

Beim Clustering werden zunächst Einheiten (z. B. Kassenmitarbeiter, Filialen, Bezirke, Anbieter usw.) in Cluster gruppiert. Dabei wird anstelle von historischen Daten ein ähnliches Verhalten zugrunde gelegt. Anhand dessen wird für jeden Cluster der Durchschnittsumsatz berechnet. Beim Überschreiten dieses Durchschnittswerts ermittelt das maschinelle Lernen blitzschnell die Ursache (z. B. Wein verkauft sich besser, wenn er in der Nähe von Windeln platziert ist) und benachrichtigt die entsprechenden Mitarbeiter, damit die ursächlichen Bedingungen unternehmensweit übernommen werden, um den Umsatz deutlich zu steigern.





Frage 2



Wie hoch sind die tatsächlichen Kosten von Bestandsmangel?

Als Einzelhändler sind Sie vermutlich bestens vertraut mit der Tatsache, dass Bestandsmangel mit Umsatzverlust einhergeht. Aber wie hoch ist der Verlust ganz konkret?

Zur Beantwortung dieser Frage dient die „versteckte Nachfrage“, die sich jedoch nicht einfach berechnen lässt. Ein Algorithmus für maschinelles Lernen erledigt das für Sie. Dieser ermittelt zunächst anhand der Daten die echte Nachfrage bei Verfügbarkeit eines bestimmten Artikels ab Lager. Daraufhin wird diese Berechnung als Richtwert herangezogen, um die Nachfrage bei Bestandsmangel vorherzusagen, selbst wenn das Lieferkettensystem fälschlicherweise annimmt, dass Bestand vorhanden ist (Scheinbestand). Zuletzt übersetzt der Algorithmus die Nachfrage bei Bestandsmangel in einen konkreten Geldbetrag, der den Umsatzverlust insgesamt darstellt. Diese Informationen können Ihnen helfen, die Bestandsgenauigkeit zu verbessern, die Verlustraten zu senken und Verkaufszahlen durch einfache Priorisierung, spezifische Aufgabenzuweisung und beschleunigte Produkteingabe zu maximieren, um eine versteckte Nachfrage und Verbrauchererwartungen zu erfüllen.

Frage 3



Wie lassen sich anhand von Online-Rezensionen Filialen mit hohem PR-Risiko identifizieren?

Täglich werden Tausende Online-Rezensionen veröffentlicht, von denen viele Ihr Unternehmen betreffen. Die darin enthaltenen Informationen können Ihnen Bereiche mit Verbesserungspotenzial aufzeigen. Doch wie können Sie diese Rezensionen auswerten und nutzen?

Ein Algorithmus für maschinelles Lernen kann eine sogenannte „Sentiment-Analyse“ durchführen. Dabei handelt es sich um eine Data-Mining-Methode, bei der Online-Inhalte, wie etwa Rezensionen, Kommentare und Bewertungen („unstrukturierte Daten“), darauf untersucht werden, wie Kunden Ihr Unternehmen wahrnehmen. Berechnungsgrundlage ist die echte Intention (positiv oder negativ) der Verfasser. Anhand der Ergebnisse werden Ihnen Filialen gemeldet, die ein besonders hohes Risiko für das Unternehmensimage

darstellen, und Schulungsempfehlungen zur Behebung von Problemen gegeben. Die Sentiment-Analyse überwacht die betroffenen Standorte auch nach dem Ergreifen von Korrekturmaßnahmen, um deren Wirksamkeit zu bestätigen. Dank dieser Diagnose der Empfindungen von Kunden in Bezug auf Ihr Unternehmen haben Sie alles, was Sie brauchen, um PR-Krisen zu vermeiden bzw. zu meistern.



Frage 4




Welche ungewöhnlichen Verhaltensweisen in meinem Unternehmen sind potenziell schädlich?

Wer Bereiche mit Verbesserungspotenzial identifizieren will, sucht am besten nach Anomalien. Diese treten auf, wenn Echtzeit-Verhaltensweisen nicht mit dem „typischen“ Verhalten übereinstimmen. Maschinelles Lernen kann Daten fortlaufend überwachen, um zu überprüfen, ob aktuelle Trends den typischen Verhaltensweisen entsprechen. Jede Abweichung von der Norm wird als potenzielle Chance für Verbesserung hervorgehoben. Maschinelles Lernen kann sowohl interne (eigene Mitarbeiter, Lieferaktivitäten usw.) als auch externe (Anbieter von Direktlieferungen an Filialen, Drop-Shipping usw.) Anomalien erkennen.

Einzelhändler setzen die auf maschinellern Lernen basierende Erkennung von Unregelmäßigkeiten ein, um Möglichkeiten zum Steigern von Umsätzen und Margen zu identifizieren. Je besser eine Lösung ist, desto mehr richtig positive Ergebnisse werden gemeldet. Durch die Optimierung der Personalauslastung und eine höhere Problembehebungsrate sind Untersuchungen effizienter und effektiver.



Frage 5



Sind Schwund und Risiken vorhersehbar und vermeidbar?

Im Einzelhandel werden Verlustraten und Risiken nicht anhand einer festen zeitlichen Abfolge ermittelt, sondern aufgrund von unkalkulierbaren Faktoren. Dies ist durchaus schlüssig, denn viele Ursachen sind abhängig von externen Aspekten, wie etwa organisierte Kriminalität im Einzelhandel, Fehllieferungen, operative Verluste und andere unwägbare Ereignisse. Deshalb erscheint es zunächst unmöglich, Warenschwund und Risiken zuverlässig vorherzusagen.

Algorithmen für maschinelles Lernen analysieren Verlustraten zum Zeitpunkt der letzten periodischen Inventur, wenden bekannte Verlustindikatoren darauf an – Diebstahl, Personalabbau, Anstellungsverhältnis von Mitarbeitern, Retouren, Belege, Kundenverkehr, Einführung neuer Produkte usw. – und generieren entsprechende Prognosen. Mit der Zeit

„merken sich“ die Algorithmen die Faktoren, die sich am stärksten auf die Verlustraten auswirken, um die Ergebnisse kontinuierlich zu verbessern. Verlustprognosen, die auf maschinellem Lernen basieren, können Ihnen strategische Transparenz in Bezug auf physische Bestände und gezielte Inventuren bieten und zugleich Filialen oder Produktkategorien identifizieren, auf die sich Korrekturmaßnahmen konzentrieren müssen.



Frage 6



Bei welchen Kassensmitarbeitern kommt es zu Betrug oder Compliance-Verstößen?

Vor allem zwei Betrugsmethoden durch Kassenspersonal beunruhigen Einzelhändler. Beim „Sliding“ schiebt ein Kassensmitarbeiter einen Artikel über den Scanner und verdeckt dabei vorsätzlich den Barcode. Der Kunde, bei dem es sich häufig um einen Bekannten des Mitarbeiters handelt, kann das Geschäft mit dem Artikel verlassen, ohne dafür zu bezahlen. Die „bevorzugte Behandlung“ ist ein ähnliches Vorgehen, bei dem ein Kassensmitarbeiter anstelle eines hochwertigen Artikels einen anderen, preisgünstigen Artikel scannt, zum Beispiel Kaugummi oder einen Schokoriegel. Selbst mit Videoüberwachung oder durch persönliche Beobachtung kann es schwierig sein, vorsätzlichen Betrug (statt eines Versehens) nachzuweisen.

Algorithmen für maschinelles Lernen können dabei helfen. Bei den besten Modellen werden die Scanrate pro Minute oder Stunde und andere Verhaltensweisen analysiert, um

Durchschnittswerte zu ermitteln, wobei Transaktionsart, Datum und Uhrzeit berücksichtigt werden. Jeder Kassenmitarbeiter, dessen Scanrate drei Standardabweichungen aufweist, wird als verdächtig markiert. Dahinter steht die Annahme, dass ein überdurchschnittlich langes Intervall zwischen Scanvorgängen auf nicht gescannte Artikel hinweist. Ein derartiger Befund gilt vor allem während bestimmter Hochrisiko-Zeiten als verdächtig, wie etwa Mittagspausen, Vorweihnachtsgeschäft, Pausen oder Urlaub von Vorgesetzten usw.



Frage 7



Wie lässt sich das Risiko beim Verkauf von Rauschmitteln mindern?

Es gibt wenige Probleme, die ein derart hohes Risiko für Einzelhändler darstellen wie Compliance-Verstöße beim Verkauf von Rauschmitteln. Wenn ein Kassenmitarbeiter Tabak oder Alkohol an Minderjährige verkauft, kann dies erhebliche Strafzahlungen, Gerichtsverfahren, aber auch eine negative Berichterstattung in den Medien nach sich ziehen und dadurch zu einem Einbruch der Verkaufszahlen führen. Angesichts solch schwerwiegender Folgen muss das Risiko von Compliance-Verstößen gemindert werden.

Algorithmen für maschinelles Lernen können Verhaltensweisen identifizieren, die auf Compliance-Verstöße beim Verkauf von Tabak und Alkohol hinweisen. Eine mögliche Maßnahme ist es, die Eingabe des Geburtsdatums von Kunden anhand von Ausweispapieren erforderlich zu machen. Gibt ein Kassenmitarbeiter während seiner Schicht mehrmals dasselbe Geburtsdatum ein, wird dies als potenzieller Verstoß gemeldet.

Dahinter steht die Annahme, dass dieser Mitarbeiter die Prüfung der Ausweispapiere unterlässt und stattdessen immer dasselbe Datum eingibt, um Zeit zu sparen. Andere verdächtige Aktivitäten beim Verkauf von Rauschmitteln, die maschinelles Lernen erkennen kann, sind etwa die mehrfache Eingabe des eigenen Geburtsdatums des Mitarbeiters, unwahrscheinliche Datumsangaben (z. B. 01.01.01) oder ungewöhnlich niedrige Verkaufszahlen für Tabak oder Alkohol in Kombination mit einer Zunahme bei den manuell eingegebenen Preisen. Maschinelles Lernen kann diese Auffälligkeiten zur Nachverfolgung durch das Sicherheitsteam identifizieren.





Antworten finden

Der Konkurrenzdruck im Einzelhandel ist heute so hoch wie nie zuvor, und immer häufiger sind die Antworten in einer Flut von über Jahre hinweg gesammelten Daten versteckt. Zum Glück gibt es auf maschinellem Lernen basierende Analyselösungen, wie etwa Zebra Prescriptive Analytics, das mit der Analyse kurzen Prozess macht. Maschinelles Lernen macht es möglich, Antworten auf Ihre schwierigsten Fragen zu finden, und ist daher für den modernen Einzelhandel unverzichtbar.



Zebra Prescriptive Analytics[™]

Powered by Zebra Savanna[™]

ZEBRA und der stilisierte Zebra-Kopf sind Marken von Zebra Technologies Corp., die in vielen Ländern weltweit eingetragen sind. Alle anderen Marken sind im Besitz der jeweiligen Eigentümer. © 2020 Zebra Technologies Corp. oder Vertragspartner. Alle Rechte vorbehalten.