

Tech-Einmaleins: Individualisierte Empfehlungen



E-Commerce, Portalentwicklungen, komplexe Datenarchitekturen, individuelle Software- und Technologie-Lösungen für Smart Data: Das sind die Themen der Experten von Valiton, einem Unternehmen von BurdaSolutions. Heute erklärt Manuel Borst, Senior Data Scientist bei Valiton, wie individualisierte Empfehlungen auf digitalen Plattformen funktionieren und welches Potenzial in dieser Technologie steckt.

„Kunden, die diesen Artikel kauften, kauften auch...“ oder „...das könnte Sie auch interessieren“ – Sätze wie diese sind aus heutigen E-Commerce Plattformen nicht mehr wegzudenken. Was machen gute Recommender-Systeme aus?

Gute Recommender-Systeme erhöhen die Kundenzufriedenheit, verringern die sogenannte Churn-Rate, also wie oft sich ein Kunde von einem Unternehmen abkehrt oder sich einem Mitbewerber zuwendet. Vor allem erhöhen Recommender-Systeme aber die Verkaufszahlen. Erreicht wird das durch individuelle Empfehlungen anstelle von Informationsflut mit der Gießkanne.

Womit fängt alles an?

Am Anfang der Implementierung eines Empfehlungs-Algorithmus ist es wichtig, die individuellen geschäftlichen Rahmenbedingungen zu verstehen, für die das System gebaut werden soll.

Aus welchen Daten kann der Algorithmus die individuellen Bedürfnisse und Vorlieben meiner Kunden lernen?

Im einfachsten Fall offenbaren Kunden ihre Präferenzen über explizites Feedback zu einzelnen Produkten selbst, etwa durch 5-Sterne-Bewertungen. Liegt diese Information nicht vor, oder möchte man sich nicht auf sie verlassen, versucht man sie typischerweise durch intelligentes Beobachten des Kundenverhaltens abzuleiten. So können die Verweildauer auf einem Artikel, die Anzahl der wiederholten Käufe in einem Online-Shop, oder die Häufigkeit einer Titelwiedergabe bei Musik- oder Video-Streamingdiensten ebenfalls Aufschluss über die Vorlieben der Nutzer geben – man spricht von implizitem Feedback. Hier ist in jedem Fall Kreativität gefragt, weil die Güte eines Recommender-Systems mit der richtigen Einschätzung der Kundenvorlieben steht und fällt.

Was möchte ich meinen Kunden empfehlen?

Abhängig vom jeweiligen Anwendungsgebiet kann es opportun sein, einem Kunden neue Produkte anzubieten, die ähnliche Eigenschaften besitzen, wie die, die er bereits mag. Man spricht von Content-Based-Filtering.

Beispiel: Einem User, der den Spielfilm „Räuber Hotzenplotz“ mag, würde das System z.B. den ihm noch unbekanntem Film „Wickie und die starken Männer“ empfehlen, weil er ähnliche Eigenschaften besitzt.

Häufig ist die Wahl des Abstraktionsgrads beim Ableiten dieser Eigenschaften nicht einfach, oder die Empfehlung ähnlicher Produkte ist für das Marketingziel nicht ausreichend. Dann kann Collaborative-Filtering der bessere Ansatz sein. Hier werden für einen Zielkunden andere Kunden mit einem ähnlichen Geschmacksprofil gesucht und Produkte empfohlen, die diese Kunden mögen, der Zielkunde aber noch nicht kennt.

Beispiel: Einem User, der gerne nachhaltig produzierten Kaffee kauft, würde das System nachhaltig produzierte T-Shirts empfehlen, die er noch nicht kennt, weil es andere User gibt, die sowohl den Kaffee, als auch die T-Shirts mögen.

In einem hybriden Ansatz wird z.B. eine Kombination aus beiden Systemen verwendet, um das Beste aus beiden Welten zu vereinen. So löst etwa der Content-Based-Ansatz das Problem des Collaborative-Filtering, dass für neue Produkte noch keine Präferenzen anderer Kunden vorliegen, weil es z.B. noch nie gekauft wurde (New-Item-Problem). Über die Ähnlichkeit der Produkteigenschaften zu bereits bestehenden Produkten kann das Content-Based-Filtering problemlos ähnliche Artikel vorschlagen.

Sind die generierten Empfehlungen gut?

Nachdem das System auf das jeweilige Anwendungsgebiet maßgeschneidert wurde, bleibt vor dem praktischen Einsatz natürlich immer die Frage nach der Güte der von ihm generierten Empfehlungen. Anders als bei vielen Machine-Learning-Ansätzen, ist die Reaktion auf eine vergangene Empfehlung häufig unbekannt. Eine Performance-Messung anhand eines Testdatensatzes ist deshalb nicht möglich.

Um dennoch messbare Qualitätskriterien zu erhalten, ist für eine erste Einschätzung die qualitative Bewertung durch Domänenexperten gut geeignet. Wie gut passt der empfohlene Artikel per Augenmaß zu denen, die ein Kunde bereits mochte? Ist es plausibel, dass eine Gruppe von Kunden, die gerne teuren Rotwein trinkt, sich auch für würzigen Käse interessiert?

Im zweiten Schritt wird typischerweise mit klassischen A/B-Tests gearbeitet: Eine Kundengruppe bekommt Empfehlungen nach Gießkannenprinzip, die andere bekommt die aus dem Recommender-System. Ist die Zielgröße, z.B. die Conversion-Rate, in der „Gießkannen“-Gruppe signifikant geringer, darf angenommen werden, dass das Recommender-System gut funktioniert. Die verbesserte Conversion-Rate kann dann als Benchmark für zukünftige Veränderungen am System herangezogen werden.

Individualisierung fängt schon beim Coding an

Vorgefertigte Lösungen auf dem Markt sind meist kostengünstig, schnell implementierbar und geben einen guten Eindruck, was mit Personalisierung grundsätzlich erreichbar ist. Um das volle Potential ausschöpfen zu können, entwickeln wir bei Valiton Algorithmen, die direkt auf den jeweiligen Business-Kontext, die datengenerierenden Prozesse und die Sales-Architektur unserer Kunden zugeschnitten sind. Auch beim Bau von Recommender-Systemen glauben wir an die Macht der Individualisierung.

Die Valiton GmbH ist eine Tochter von BurdaSolutions. Als interner IT-Dienstleister mit Standort Offenburg und München erstellt Valiton innovative Lösungen aus den Bereichen Softwareentwicklung, Data-Science und Data Engineering für Burda Units.

von **Saki Athanassios Danoglidis**
Senior Editor - Corporate Communications
Athanassios.Danoglidis@burda.com



Kategorie **Tech, Karriere**

Schlagwörter **BurdaSolutions, Manuel Borst, Tech, Valiton**

Adresse (URL) **<https://www.burda.com/de/news/tech-einmaleins-individualisierte-empfehlungen/>**