



Success
Story

Mit Data Science Kundenbedürfnisse identifizieren.

Von der Datenanreicherung bis zur
gezielten Kundenansprache

Branche: Lebensmittelgroßhandel



Wie gut kennen Sie eigentlich die Bedürfnisse Ihrer Kundinnen und Kunden?

Haben Sie genug Informationen über sie und können Sie daraus Wissen gewinnen, um dieses nutzbringend im Unternehmen einzusetzen? Diese Fragen sollten Sie sich regelmäßig stellen, denn sie sind ein entscheidender Erfolgsfaktor. Wenn nicht genügend kundenspezifische Informationen in der eigenen Datenlandschaft vorhanden sind, kann aus Vertriebs- und Marketingsicht nur eine allgemeine Ansprache erfolgen und im schlimmsten Fall werden Produkte angeboten, die an den Bedürfnissen der Kundschaft vorbei gehen. Um die Kundschaft zielgerichtet anzusprechen, Produkte zu optimieren oder sinnvoll zu ergänzen und so den Umsatz zu steigern, müssen Unternehmen wissen, was ihre Kundinnen und Kunden wirklich brauchen. Dafür benötigen sie Informationen.

Wie wir diese und weitere erfolgskritischen Fragen bei unserem Kunden aus dem Bereich Lebensmittelgroßhandel durch den Einsatz von Data Science beantworten konnten, erfahren Sie im Folgenden.

Der Kunde.

Als Lebensmittelgroßhändler verkauft unser Kunde Artikel für die Profiküche wie Großküchen sowie Lebensmittel an Gastronomie und Hotellerie: Restaurants, Hotels, Kantinen und Mensen. Er konnte sein Geschäft in den letzten Jahrzehnten in ganz Europa ausweiten und besitzt in Deutschland mehrere Stützpunkte, von denen aus er seine Endkunden mit einer eigenen Logistik beliefert. Durch mehrere Eigenmarken und zum Konzern gehörende Metzgereien, hebt er sich von der Konkurrenz ab. Zudem bietet er maßgeschneiderte Lösungen an, um seine Kunden im B2B-Bereich zu betreuen. Für unseren Kunden war dies das Startprojekt in die Themengebiete Data Science und Big Data.

Bisherige Situation und Ziel des Projektes.

Die bisherigen Vertriebs- und Marketingaktivitäten unseres Kunden waren eher unspezifisch und allgemein gehalten. Es gab mehrere Sortimentskataloge, die alle zu den persönlichen Gesprächen mitgenommen werden mussten und an sämtliche Kunden verteilt wurden. Die Endkunden wurden weder über den Webshop noch auf postalischem Wege durch Flyer und Broschüren individuell angesprochen. Zudem verfügte der unternehmensinterne Vertrieb über keine adäquaten Instrumente für die Bestandskundenbetreuung und Neukundenakquise, die ihm alle relevanten Informationen auf einen Blick bereitstellten. Dafür war es zwingend notwendig, mehr über die eigenen Endkunden und deren Präferenzen zu erfahren und dieses Wissen allen Fachabteilungen zur Verfügung zu stellen. Eine abschließende Erfolgskontrolle der Maßnahmen sollte die Wirksamkeit der neuen Services sicherstellen.

Herausforderung.

Über die Endkunden waren jedoch nur sehr wenige Informationen im Data Warehouse (DWH) des Unternehmens bekannt. Neben elementaren Stammdaten wie Name und Anschrift waren kaum weiterführende Informationen verfügbar. Weder in den kundenbezogenen Tabellen des DWH noch in anderen operativen Systemen waren Angaben über die Branche der Kunden hinterlegt.

So war auf Basis der Daten nicht auswertbar, ob ein bestimmter Gastronomiekunde ein italienisches, griechisches oder spanisches Restaurant, ein Kiosk oder eine Raststätte ist. Die einzelnen „Küchenvarianten“ haben jedoch unterschiedliche Anforderungen und Bedürfnisse. Hotels greifen eher zum deutschen Rumpsteak, Raststätten dagegen zu Pommes und Bockwurst. Solche Angaben sind für die gezielte Ansprache essenziell und mussten daher zuerst beschafft werden.

Lösungsansatz und Vorgehen.

Der erste Schritt im Projekt war deshalb eine Datenanreicherung der Kundeninformationen mithilfe von externen Diensten (siehe Abbildung 1).



Abbildung 1: Projektschritte (© MT GmbH)

Anschließend teilten wir unter Einsatz von Clustering-Algorithmen aus dem Machine-Learning-Bereich die Gastronomiekunden anhand ihrer Stammdaten, weiterer Kundenmerkmale und ihres Kaufverhaltens in unterschiedliche Gruppen ein. Ein vereinfachendes Beispiel einer Gruppe sah wie folgt aus: spanische Restaurants mit einem hohen Umsatz bei Meeresprodukten und Gemüse, die mittelpreisige Gerichte anbieten und online häufig und sehr gut bewertet waren. In der abschließenden Cluster-Bildung benutzten wir weitere Merkmale (siehe Kapitel „Kundensegmentierung“). Darauf aufbauend führten wir für jede Gruppen eine Warenkorbanalyse durch, bei der häufig gemeinsam gekaufte Produkte identifiziert wurden. Damit konnten wir zum Beispiel den spanischen Restaurants mediterrane Warenkörbe anbieten, bestehend aus Produktvorschlägen und -kombinationen, die für sie von Interesse waren. Aus diesen Erkenntnissen und zusätzlichen Data-Science-Analysen, die wir im weiteren Verlauf vorstellen, entwickelten wir verbesserte und neue Produkte.

Möglichkeiten der Datenanreicherung.

Es gibt unterschiedliche Ansätze, um an zusätzliche Daten zu kommen:

- › Informationen über Analyse der Stammdaten ableiten:
 - Zum Beispiel wird der Kunde „Pizzeria Italia“ voraussichtlich ein italienisches Restaurant sein
- › Daten bei einem Adresshändler unter Berücksichtigung der DSGVO dazukaufen
(Es ist von Fall zu Fall zu bewerten, welcher Anbieter infrage kommt - unserem Fall spielten dafür Daten im Bereich Gastronomie und Hotellerie eine Rolle)
- › Einsatz von Web-Crawling für weitere Kundenmerkmale
- › Nutzung externer Dienste mittels Web-APIs

Um eine optimierte Datengrundlage für eine Kundensegmentierung zu schaffen, entschieden wir uns nach der Prüfung der möglichen Varianten gemeinsam mit unserem Kunden für die Nutzung von Web-APIs. Dabei waren die Aspekte des Aufwandes und der Datenverfügbarkeit sowie juristische Gründe entscheidend. Durch die Nutzung von Web-APIs konnten wir gezielt weitere Kundenmerkmale abfragen.

Auswahl der externen Dienste.

Die wichtigste Frage bei der Auswahl der externen Dienste ist sicherlich, welche Informationen für den jeweiligen Anwendungsfall benötigt werden. Für Kunden aus dem Gastronomiebereich identifizierten wir die Branche, den Küchenstil, die durchschnittliche Bewertungshöhe und die Anzahl der Online-Bewertungen sowie die Preiskategorie als wichtige Merkmale. Bei der Auswahl evaluierten wir zehn Anbieter hinsichtlich der dazu verfügbaren Datenbasis, der Kosten und der rechtlichen Nutzung. Gemeinsam entschieden wir uns für zwei kostenlose Anbieter - den Kartendienst Nokia Here [1], das Facebook Graph API [2] sowie das kostenpflichtige Google Places API [3].

Auf den Webseiten von Google, Facebook und Nokia Here finden sich diverse Informationen zu sogenannten Point-of-Interests (siehe Abbildung 2). Über das fiktive Restaurant „Lecker“ lässt sich beispielsweise ermitteln: Es ist ein mittelpreisiges, italienisches Restaurant, das über 102 Bewertungen verfügt, die im Schnitt bei einem Wert von 4,4 von 5 Sternen liegen. Über eigens entwickelte Prozesse in Python und eine anschließende Anbindung in das ETL-Tool (Extract, Transform, Load) des Kunden konnten diese Daten unter Berücksichtigung der DSGVO und der Nutzungsbedingungen der externen Dienste angezogen und abgespeichert werden.



Abbildung 2: Schaubild der Datenanreicherung (© MT GmbH, Logos von Facebook und Google, Fotografie: Pixabay.com)

Ablauf des API-Calls.

Die grundsätzliche Ansprache von Web-APIs ist nicht sehr komplex, da dies ein standardisiertes Vorgehen (zum Beispiel REST API) ist. Das API wird mit bestimmten Suchparametern angesprochen und man erhält eine Antwort zurück. Um Daten zu einem Unternehmen zu erhalten, wird eine Suchanfrage mit einer Kombination des Kundennamens, der -adresse sowie der Accountdaten des jeweiligen Dienstes ausgeführt (siehe Abbildung 3). Im Idealfall werden die Daten als Ergebnis der API-Anfrage zurückgeliefert (siehe Abbildung 4).

```
if (longitude != ',' and latitude != ','):
    searchtext = urllib.parse.quote(data[''+column][i])
    url = 'https://places.cit.api.here.com/places/v1/discover/search?in=' \
+latitude+';'+longitude+';r=500&q='+searchtext+ \
,app_id='+here_app_id+'&app_code='+here_app_code
    response = requests.get(url, verify=False)
```

Abbildung 3: API-Call des Kartendienstes Nokia Here (© MT GmbH)

Name	Status	Kategorie	Küchenstil	Preiskategorie
Restaurant Lecker GmbH	Gefunden	Restaurant	Italienisch	Mittel

Abbildung 4: Ergebnis des API-Calls im Idealfall (© MT GmbH)

Plan vs. Wirklichkeit.

Soweit die Theorie. Wie im echten Leben wich die Realität auch in diesem Projekt davon ab.

Wir wurden mit unterschiedlichen Hürden konfrontiert, die die Datenanreicherung komplizierter gestalteten, als es zunächst den Anschein hatte (siehe Abbildung 5).

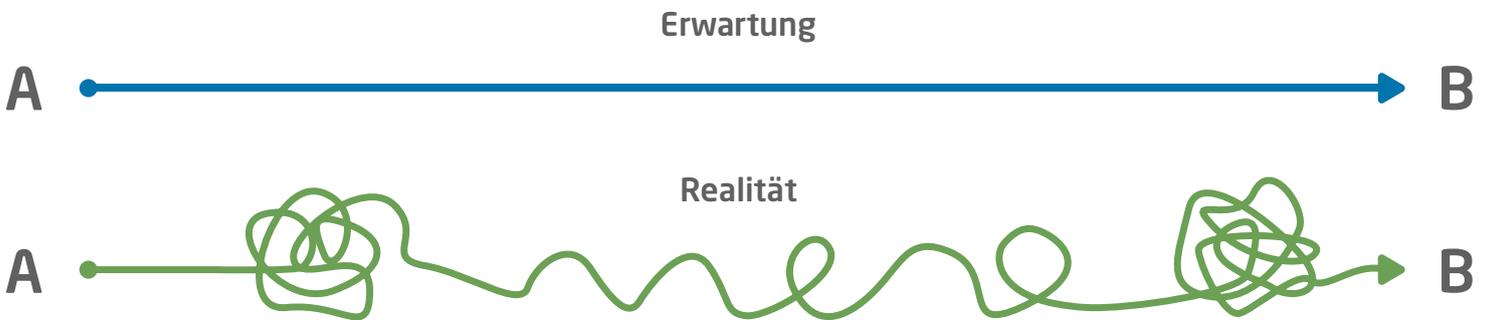


Abbildung 5: Plan vs. Wirklichkeit (© MT GmbH)

Der erste Aufwandstreiber war die mangelnde Qualität der Stammdaten aus dem DWH, weshalb wir diese vor dem Aufruf des API-Calls aufbereiten mussten (siehe Abbildung 6). Zum einen wurden im DWH Abkürzungen im Namen und in der Adresse der Kunden verwendet. Zum anderen kamen auch unzulässige Werte in den Daten vor. Hierbei handelte es sich häufig um Zusatzangaben für die Lieferung, zum Beispiel „3. Tor links“.

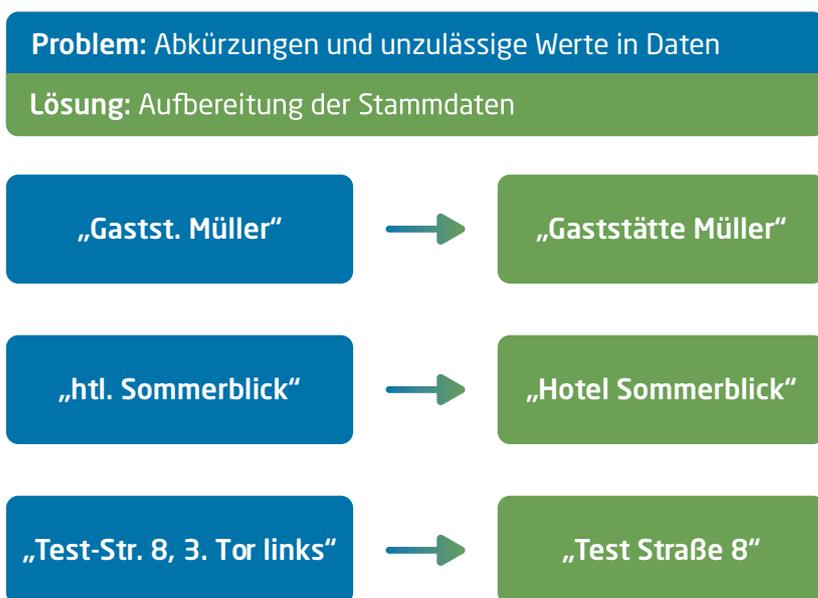


Abbildung 6: Aufbereitung der Stammdaten für die API-Calls (© MT GmbH)

Des Weiteren kam es vor, dass mehrere Namensbezeichnungen und Adressen für denselben Kunden im DWH gespeichert waren. Das war darauf zurückzuführen, dass das System historisch gewachsen war und es bisher kein standardisiertes Verfahren beim Anlegen von Kunden gegeben hatte. Wie in der folgenden Tabelle dargestellt, waren die Angaben zum Namen der Lokalität, zum Inhaber und gegebenenfalls zur Kette in unterschiedlichen Datenfeldern verteilt. Mithilfe einer Abfrage-Logik konnten diese Daten in eine wahrscheinliche Reihenfolge gebracht und systematisch für den API-Call benutzt werden.

Als dritte Hürde stellte sich die fachliche Validierung der API-Antworten heraus. Neben Mehrfachangaben für Kunden im System bekam man für viele Suchanfragen mehrere Einträge als Antwort zurück. Dies war vor allem bei Lokalitäten in der Nähe von Sehenswürdigkeiten und Ausflugszielen zu beachten. Aber wie konnten wir sicherstellen, dass wir wirklich unseren gesuchten Kunden über den API-Call gefunden hatten? Eine solche Prüfung der wahrscheinlichsten Antwort erfolgte mithilfe der sogenannten Levenshtein-Metrik (siehe Abbildung 8). Hohe Werte bedeuten dabei eine große Ähnlichkeit von zwei Zeichenketten - in unserem Fall dem Suchbegriff und der Antwort aus dem API-Call.

Name 1	Name 2	Name 3
Name des Inhabers	Name des Restaurants	–
Name des Restaurants	Name des Inhabers	–
Name der Kette	–	Name des Restaurants
–	Name des Inhabers	Name der Kette

Abbildung 7: Keine eindeutigen Kundennamen im System (© MT GmbH)

Suchbegriff	API-Antwort	Levenshtein-Metrik
Restaurant zur Seeschänke	Restaurant Seeschänke	84 %
	See Auerbach	19 %

Abbildung 8: Validierung API-Antworten (© MT GmbH)

Ergebnis der Datenanreicherung.

Lohnte sich der Aufwand für die Aufbereitungsschritte? Ganz eindeutig ja! Denn die Trefferquote für die API-Calls konnte durch die Optimierung signifikant verbessert werden (siehe Abbildung 9). Wurden zu Beginn mit der einfachen Variante der API-Calls lediglich knapp 58 Prozent der Gastronomiekunden gefunden, so konnte in den weiteren Iterationen durch die Optimierungsschritte und die Konsolidierung mehrerer externer Dienste die Trefferquote auf über 92 Prozent gesteigert werden. Bei den restlichen 8 Prozent handelte es sich um fehlerhafte Stammdaten, die durch einen manuellen Prozess abgeglichen werden mussten.

Das hieß: Nach der Datenanreicherung wussten wir bei 92 Prozent der Gastronomiekunden, welcher Branche und welchem Küchenstil sie angehören. Wir konnten die Kunden zum Beispiel in „positiv bewertete italienische Restaurants“ und „internationale Hotels“ unterteilen. Wir wussten auch, wie viele Bewertungen der Kunde bekommen hatte, und dementsprechend, wie bekannt er war. Zudem konnten wir nun das Preisniveau des Kunden bestimmen. All diese Informationen waren nach der Datenanreicherung in der eigenen Datenlandschaft vorhanden und standen den jeweiligen Fachabteilungen zur Verfügung. Zuvor waren diese Informationen unbekannt! Die Kundendaten waren nun mit ausreichend Merkmalen angereichert, um eine Kundensegmentierung und weitere Analysen durchführen zu können.

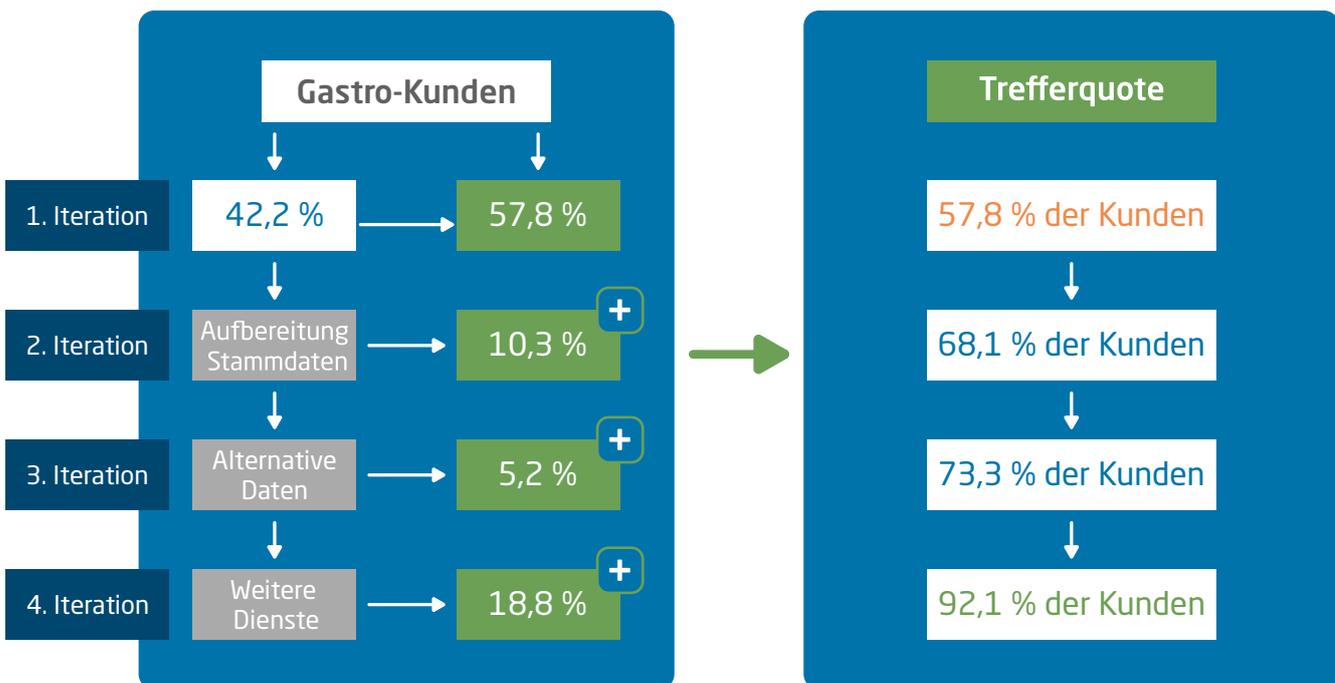


Abbildung 9: Verbesserung der Trefferquote (© MT GmbH)

Kundensegmentierung.

Ziel einer Kundensegmentierung ist es, relevante Gruppen – für den entsprechenden Fachbereich und Verwendungszweck – innerhalb seiner Kunden zu identifizieren, um anschließend Rückschlüsse auf geschäftliche Maßnahmen ziehen zu können. Dafür werden die Kunden anhand bestimmter Eigenschaften und Merkmale aufgeteilt. Kunden einer Gruppe sind sich in diesen Eigenschaften besonders ähnlich.

Der Prozess der Kundensegmentierung besteht aus drei Teilschritten:



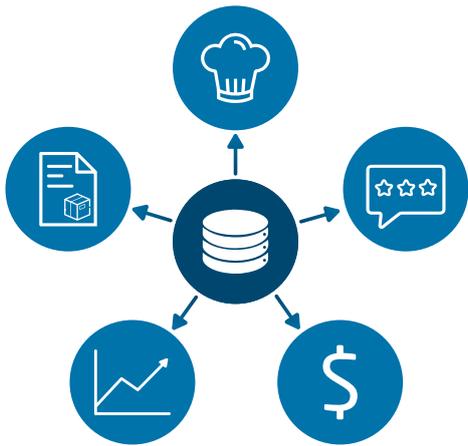
Abbildung 10: Prozess der Kundensegmentierung (© MT GmbH)

Auswahl der relevanten Informationen.

Zuerst wählten wir Merkmale über die Kunden aus, die bei der Segmentierung berücksichtigt werden sollten. Der Fokus lag auf dem Verwendungszweck der Kundengruppen. Für das Ziel, die Vertriebs- und Marketingaktionen des Lebensmittelgroßhändlers zu optimieren, waren verschiedene Informationen notwendig. Zum einen sammelten wir Umsatzkennzahlen und Bestellinformationen aus dem internen Datenbestand. Zum anderen verwendeten wir die zuvor angereicherten Informationen über Küchenstil, Online-Bewertungen und Preiskategorie. Aus den 300 abgeleiteten Merkmalen identifizierten wir 30 Merkmale zur Modellerstellung (siehe Abbildung 11). Denn eine größere Anzahl von Kriterien verbessert nicht unbedingt das Ergebnis der Kundensegmentierung. Qualitativ hochwertige und aussagekräftige Merkmale sind wichtiger als die Quantität der Informationen! Kriterien, die fachlich nicht zum Ziel der Kundensegmentierung beitragen, „verwirren“ den Algorithmus eher und verfälschen das Ergebnis [4].

300 Merkmale aus verschiedenen Kategorien

30 Merkmale zur Modellerstellung



- > Branche/Küchenstil
- > Bewertungen
- > Preiskategorie
- > Umsatzkennzahlen
- > Bestellinformationen

```
'NIEDERLASSUNG',
'AUFTRAEGE',
'ANZAHL_RUECKGABEN',
'ANZAHL_ANFAHRTEN',
'UMSATZ_FOOD',
'UMSATZ_NONFOOD',
'PREISKATEGORIE',
'ANZAHL_BEWERTUNGEN',
'BEKANNTHEIT',
'BRANCHE_KATEGORIE', (One-Hot-Codierung)
'BRANCHE_KUECHENSTIL', (One-Hot-Codierung)
'ANTEIL_AUSSTEHENDER_RECHNUNGEN',
'DURCHSCHN_TAGE_BESTELLVORLAUF',
'UMSATZ_ARBEITSBEKLEIDUNG',
'UMSATZ_MEERESFRUECHTE',
'UMSATZ_FLEISCHWAREN',
'UMSATZ_GASTROARTIKEL',
'UMSATZ_GETRAENKE',
'UMSATZ_GROSSKUECHENBEDARF',
'UMSATZ_KOSMETIKARTIKEL',
'UMSATZ_BACKWAREN',
'UMSATZ_MILCHPRODUKTE',
'UMSATZ ObstGEMUESE',
'UMSATZ_REINIGUNGSARTIKEL',
'UMSATZ_SPEISEKAMMER',
'UMSATZ_TIEFKUEHLWAREN'
```

Abbildung 11: Auswahl der relevanten Merkmale (© MT GmbH)

Erstellen von Segmenten mit Machine-Learning-Algorithmen.

Im zweiten Schritt führten wir mithilfe von maschinellem Lernen die eigentliche Segmentierung der Kunden durch. Dafür verwendeten wir sogenannte Clustering-Algorithmen. Diese können die Kunden anhand der zuvor ausgewählten Merkmale trennen und in Cluster beziehungsweise Gruppen aufteilen (siehe Abbildung 12). Sie berechnen Ähnlichkeiten mithilfe des Abstands der einzelnen Datenpunkte. Sowohl in diesem als auch in anderen Projekten haben wir sehr gute Erfahrungen mit den Algorithmen K-Means [5] und DBSCAN [6] gemacht.

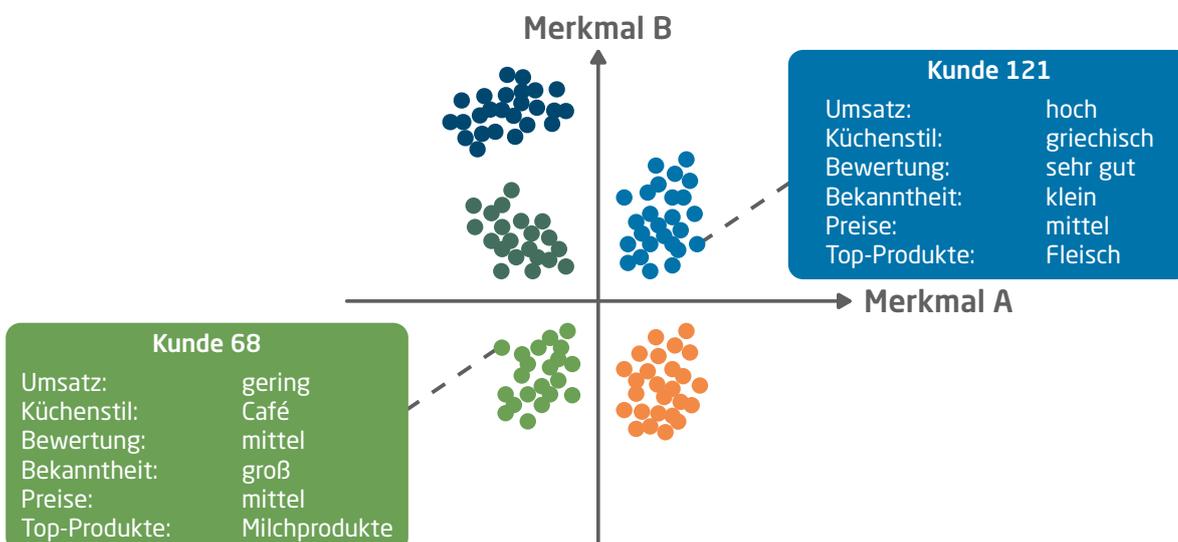


Abbildung 12: Bildung von Kundensegmenten durch Clustering-Algorithmen (© MT GmbH)

Der Weg zu optimalen Kundensegmenten erforderte mehrere Iterationen und Optimierungsschritte in der Modellerstellung. Beispielsweise musste die optimale Anzahl von Clustern gefunden werden. Dafür wurden Verfahren wie die Elbow-Methode [7] eingesetzt. Des Weiteren sollte auch die technische Güte der Modelle anhand von Metriken ermittelt werden. Eine dieser Metriken war der sogenannte Silhouetten-Koeffizient [8]. Er eignete sich zur Bewertung, wie klar die einzelnen Cluster voneinander getrennt wurden.

Fachliche Interpretation der Kundensegmente.

Nach der technischen Erstellung der einzelnen Cluster mussten diese auch fachlich interpretiert werden. Wie konnten sich die Cluster fachlich benennen und beschreiben lassen? Und welche Eigenschaften hatten die Kunden innerhalb der Cluster? Um diese Fragen zu beantworten, wurden bestimmte Machine-Learning-Verfahren eingesetzt. Mithilfe von Entscheidungsbäumen und der Feature Importance [9] konnten die wichtigsten Merkmale bestimmt werden, die für die Einteilung in Cluster entscheidend waren (siehe Abbildung 13).

Die Auswertung bestätigte uns dabei, dass eine pragmatische, logische Trennung der Kunden nach Branche und Küchenstil zu sinnvollen Kundensegmenten führte und gleichzeitig die fachliche Interpretierbarkeit gewährleistete. Das Ergebnis waren 32 Kundensegmente, wie zum Beispiel „mittelpreisige griechische Restaurants mit sehr guten Online-Bewertungen und einem hohen Umsatz bei Fleischprodukten“.

Problem: Anhand welcher Merkmale konnte der Algorithmus die Cluster bilden?

Lösung: Auswertung der Feature Importance von Entscheidungsbäumen

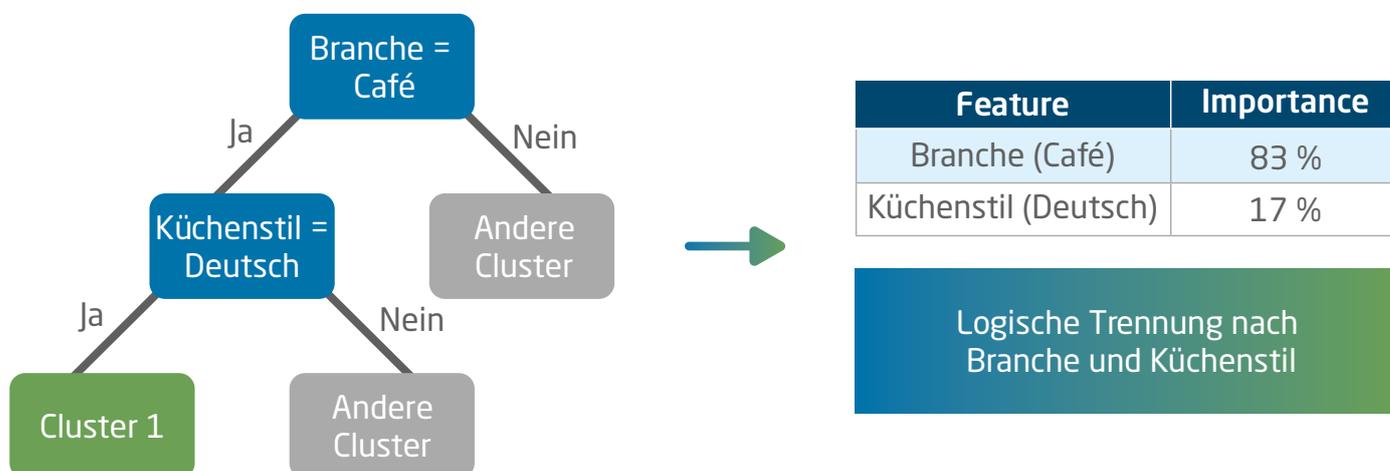


Abbildung 13: Fachliche Auswertung der Kundensegmente mit Entscheidungsbäumen (© MT GmbH)

Warenkorbanalyse und Auswertungen der Kundensegmente.

Wie konnten wir nun aus den Kundensegmenten nützliches Wissen ziehen? Die neu erzeugten Kundensegmente bildeten eine optimale Basis für weiterführende Analysen, wie etwa eine Warenkorbanalyse. Dabei wurden mithilfe von Algorithmen wie beispielsweise Apriori oder dem FP-Growth [10] sogenannte Assoziationsregeln erstellt, um das Kaufverhalten der Kunden besser zu verstehen. Dieses Wissen ermöglichte es uns, den Warenbestand und die Produktpräsentation zu optimieren. Die Assoziationsregeln lieferten interessante Erkenntnisse, wie zum Beispiel: „Wenn ein Kunde Pommes Frites kauft, kauft er zu 80 Prozent Tomatensuppe dazu.“ Solche Regeln können dann auf Webseiten und in Online-Shops genutzt werden. Ruft nun ein Kunde einen Pommes-Frites-Artikel auf, so kann als Produktvorschlag „Tomatensuppe“ angezeigt werden (sog. Next-Best-Offer). Auch automatisierte Preisanpassungen oder die Erstellung von Produktbündeln sind aufbauend auf solchen Regeln möglich.

Zudem konnten die einzelnen Kundensegmente durch weitere Analysen ausgewertet werden. Dabei konnten wir einige Auffälligkeiten entdecken, die offensichtlich oder auch überraschend waren: Zum einen konnten wir durch den Vergleich der Kundensegmente die griechischen Restaurants als besonders umsatzstarke Kundengruppe identifizieren. Zum anderen analysierten wir die gekauften Produktgruppen innerhalb eines Kundensegments.

Eine der vielen spannenden Erkenntnisse war unter anderem, dass griechische Restaurants mit guten Online-Bewertungen besonders viel Ouzo kaufen. Des Weiteren waren manche Kunden erkennbar, die sich im Vergleich zum Rest eines Kundensegments auffällig verhielten. So gab es viele Bars und Pubs, die gar keine Getränke bestellten. Das ist eventuell darauf zurückzuführen, dass sie einen separaten Getränkehändler hatten oder noch nicht vom Getränkeangebot des Großhändlers wussten.

Diese zusätzlichen Informationen konnten Vertrieblerinnen und Vertriebler bei ihrer täglichen Arbeit und Vorbereitung auf Kundengespräche unterstützen.

Aus Erkenntnissen neue Produkte und Services ableiten.

Wie ließen sich diese zusätzlichen Informationen nutzen, um unternehmerischen Mehrwert zu erzielen? Dazu wurden mehrere Services beziehungsweise Produkte optimiert oder neu entwickelt. Als ein gänzlich neues Produkt entstand eine mobile Applikation zur Unterstützung der Vertriebsmitarbeiter (siehe Abbildung 14). In ihr werden die verschiedensten Informationen zu einem Kunden beziehungsweise einem Kundensegment gebündelt. Auf einer Kartendarstellung wird visualisiert, wo die jeweiligen Kundensegmente vertreten sind. Zusammen mit den meistgekauften Produkten und umsatzstarken Produktsortimenten für das jeweilige Kundensegment, kann das Kaufverhalten des jeweiligen Kunden analysiert und entsprechende Produktvorschläge angeboten werden. Wenn ein griechisches Restaurant bisher nur Bedarfsartikel für eine Großküche, aber kaum Fleischprodukte gekauft hat, können ihm die Top-Produktvorschläge aus dem griechischen Kundensegment angeboten werden.



Abbildung 14: Mobile Applikation für den Vertrieb (© MT GmbH, Kartendaten ©2022: Google, GeoBasis-DE/BKG, MockUp Smartphone: Freepik.com)

Die Erkenntnisse und Empfehlungen zu dem Kunden werden dem Vertrieb in Form von übersichtlichen Grafiken und Auswertungen in der App zur Verfügung gestellt, damit er sich nicht mehr mit mühseliger Beschaffung von Informationen herumschlagen muss. Ein weiterer Vorteil besteht darin, dass Vertrieblerinnen und Vertriebler diese Informationen jederzeit auf mobilen Geräten abrufen und so in Kunden- und Verkaufsgesprächen nutzen können. Umständliches Zusammensuchen von Informationen und hektisches Wälzen von Produktkatalogen in den Gesprächen sind nicht mehr notwendig.

Eine weitere Business Action war die Optimierung des Webshops. Anhand der neuen Informationen aus den Analysen wird das Design des Webshops je nach Segmentzugehörigkeit des Kunden dynamisch angepasst. Das heißt, Kundinnen und Kunden mit einem italienischen Restaurant erhalten ein Design mit italienischem Flair und zudem Produktangebote, die speziell auf die Bedürfnisse der italienischen Küche ausgerichtet sind.

Dazu wurden die allgemeinen Produktkataloge überarbeitet. Anhand der Analysen entstanden neue, auf die einzelnen Kundensegmente ausgerichtete Werbekataloge. Sie enthalten ausgewählte Produktkombinationen und Angebote, die die Bedürfnisse der verschiedenen Küchenrichtungen und die Präferenzen der Kunden gezielt ansprechen. Dadurch müssen die Vertriebsmitarbeiterinnen und -mitarbeiter nicht länger mehr als zwei Dutzend unterschiedliche Kataloge zum Kundengespräch mitnehmen und können sich mithilfe der spezialisierten neuen Kataloge und der App auf eine bessere Beratung fokussieren.

Fazit.

Mithilfe der Analysen und der daraus entstandenen Produkte und Services, wurde in diesem Projekt erheblicher betrieblicher Nutzen für unseren Kunden erzielt. Zum einen lieferten die angereicherten Kundeninformationen in Kombination mit den darauf aufbauenden Auswertungen neues und zentrales Wissen für die verschiedenen Fachabteilungen. Zum anderen ermöglichten die Vertriebs-App, der Webshop und die angepassten Produktkataloge eine verbesserte Kundenansprache bei Vertriebs- und Marketingaktivitäten. Diese neuen und verbesserten Services kamen sowohl beim Vertrieb als auch bei den Kundinnen und Kunden positiv an. Zudem ist es ab jetzt möglich, all diese Informationen zu nutzen, sich bei der Neukundensuche auf lukrative Kundensegmente zu fokussieren und diese gezielt mit passgenauen Produkten anzusprechen.

Mehrwerte für den Kunden

- > Verbesserte Kundenanalyse
- > Möglichkeit personalisierter Newsletter und Kataloge
- > Erfolgskontrolle der Maßnahmen
- > Höherer Umsatz durch Steigerung der Verkäufe

Ihr Ansprechpartner für Data Analytics.



Ralf Böhme

Bereichsleiter Analytics

Telefon: +49 2102 30 961-162

Mobil: +49 162 2364603

Mail: Ralf.Boehme@mt-itsolutions.com

www.mt-itsolutions.com

Über die MT.

Erfolgreich ist, wer auf der Höhe der Zeit agiert. Als Spezialist für individuelle IT-Lösungen unterstützen wir unsere Kunden bei der Gestaltung ihrer digitalen Zukunft. Mit modernsten individuellen IT-Lösungen erhöhen wir die Anpassungsfähigkeit unserer Kunden an aktuelle Marktbedingungen. Dafür bieten wir alle notwendigen Applications, Analytics und Services aus einer Hand.

Quellen.

- [1] <https://developer.here.com/>
- [2] <https://developers.facebook.com/docs/graph-api/>
- [3] <https://developers.google.com/places/web-service/overview>
- [4] Géron, Aurélien (2019), Hands-On Machine Learning with Scikit-Learn, Keras & Tensorflow: Concepts, Tools, and Techniques to Build Intelligent Systems (S. 26 f.), O'Reilly Media, Inc., Sebastopol, Canada
- [5] <https://scikit-learn.org/stable/modules/clustering.html#k-means> (Stand: 05.01.2021)
- [6] <https://scikit-learn.org/stable/modules/clustering.html#dbscan> (Stand: 05.01.2021)
- [7] <https://www.scikit-yb.org/en/latest/api/cluster/elbow.html> (Stand: 05.01.2021)
- [8] https://scikit-learn.org/stable/auto_examples/cluster/plot_kmeans_silhouette_analysis.html (Stand: 05.01.2021)
- [9] https://scikit-learn.org/stable/auto_examples/ensemble/plot_forest_importances.html (Stand: 07.01.2021)
- [10] Sebastian Raschka, http://rasbt.github.io/mlxtend/user_guide/frequent_patterns/fpgrowth/#frequent-itemsets-via-the-fp-growth-algorithm (Stand: 07.01.2021)

Bildnachweise.

Alle Bilder sind Eigentum der MT GmbH, außer:

Seite 1, Titelbild, [Istockphoto.com](https://www.istockphoto.com) (Stand: 07.06.2022)

<https://www.istockphoto.com/de/foto/lebensmittel-einkaufen-gm1069220964-286014286>

Seite 6, Facebook Logo (Stand: 07.06.2022)

<https://www.facebook.com/brand/resources/facebookapp/logo>

Seite 6, Google Logo (Stand: 07.06.2022)

<https://about.google/brand-resource-center/brand-elements/#google-logo>

Seite 6, Fotografie, [Pixabay.com](https://pixabay.com) (Stand: 07.06.2022)

<https://pixabay.com/de/photos/pizza-gebäck-tomate-makro-schöne-2973200/>

Seite 15, MockUp Smartphone, [Freepik.com](https://www.freepik.com) (Stand: 07.06.2022)

https://de.freepik.com/vektoren-kostenlos/digitalgeraet-modell_4122505.htm#query=mockup%20iphone&position=10&from_view=keyword

Impressum.

MT GmbH

Balcke-Dürr-Allee 9

40882 Ratingen

Geschäftsführung

Siegfried Lassak

Jürgen Allmich

Amtsgericht Düsseldorf

HRB 99238

USt-IdNr.: DE169583853

