



Wie wir
eine KI für
Kosmetik-
produkte
trainiert
haben

Die Schöne und das Biest

Ein Artikel über Herausforderungen und Fallstricke bei der Arbeit mit künstlicher Intelligenz (KI) in der Marktforschung. Das war von der Redaktion angefragt. „Oha“, dachten wir uns, „das könnte ein langer Artikel werden!“ Denn die Erschaffung eines Tools, das Machine Learning nutzt, und die stetige Weiterentwicklung dieser Methoden ist eine nicht enden wollende Kette von Herausforderungen. Um dem Artikel eine nachvollziehbare Struktur zu geben, haben wir uns entschlossen, uns auf zwei wesentliche Bereiche zu fokussieren: den Projektstart und die inhaltliche Spezialisierung des Modells. Am Beispiel von Cosmention – einem KI-basierten Tool, das wir selbst entwickelt haben – lassen sich die oben erwähnten Herausforderungen und mögliche Lösungswege anschaulich beschreiben. Diese Erfahrungen haben wir alle selbst gemacht, daher handelt es sich also nicht um theoretisches Wissen.

FOTO: STUTZ / PIXABAY; MONTAGE: PSA

Zum Projektstart werden grundsätzliche Fragen geklärt, die für den weiteren Verlauf entscheidend sind: die „Business Problem Analysis“ und die technologische Grundarchitektur. Der Kunde wollte eine KI-basierte Plattform für Social-Media-Analysen im Bereich Kosmetik.

Für einen Menschen kaum zu schaffen

Es sollten neue Trendmarken und -produkte entdeckt werden, um Aussagen treffen zu können, wie sich die Kategorien und Produkte – etwa Lippenstifte – im Lauf der Zeit entwickeln. Wir führten ein Social-Media-Monitoring für Kosmetikprodukte durch. Es zeigte sich: Wir mussten mehr als 5.000 Kosmetikmarken und rund 220.000 Produkte beobachten. Wir haben berechnet, wie lange ein Mensch brauchen würde, um diese in ein klassisches Monitoring-Tool händisch einzupflegen, also Search Queries zu schreiben. Und um zuvor die Produktnamen und Marken ausfindig zu machen und dabei sogenannte Homonyme – also Begriffe, die gleich heißen, aber eine unterschiedliche Bedeutung haben – mit besonderer Vorsicht zu behandeln. Bei einem Achtstundentag bräuchte ein Mensch zwölf Monate, um einmalig alle Queries zu erstellen.

Der Kosmetikbereich ist extrem dynamisch. In den Social-Media-Kanälen tauchten ständig neue Produkte auf, die wir zuerst recherchieren und dann zu den bestehenden Search Queries hinzufügen mussten. Wir befanden uns in einem permanenten „Rat Race“. Zudem sind klassische Monitoring-Tools nicht auf ein dauerndes Anwachsen der Suchanfragen ausgelegt, denn das würde zum unkalkulierbaren finanziellen Risiko für die Anbieter. Da es also kein Tool gab, haben wir selbst eines gebaut.

Abwägen: Qualität versus Skalierbarkeit

Das Business Problem war klar: Ein selbstlernendes System schaffen, das neue Produkte, Marken und Inhaltsstoffe aus dem Kosmetikbereich eigenständig in öffentlichen Social-Media-Posts erkennt und diese automatisiert unterschiedlichen Kategorien zuordnet. Klar haben auch wir ihn geträumt, den Traum von der unendlichen Skalierbarkeit und Übertragbarkeit eines allgemeinen Machine-Learning-Modells auf unterschiedliche Branchen. Aber nach dem Start wurden wir sehr schnell wieder in die Realität zurückkatapultiert. Ein Grund: Messy Data. Oder freundlicher



ausgedrückt: sehr spezielle Sprachcodes. Social-Media-Posts sind häufig unstrukturiert, grammatikalisch herausfordernd und im Beautybereich gibt es viele spezielle Hashtags, Produktbezeichnungen, Marken und Inhaltsstoffe. Deswegen ist eine Spezialisierung des Tools auf einen Bereich, hier Kosmetik, notwendig.

Als Marktforschungsunternehmen ist es nicht unsere Aufgabe, Grundlagenforschung zu betreiben. Zum Glück wird die Entwicklung von neuen Machine-Learning-Architekturen an Universitäten und in Forschungsabteilungen großer Technik-Unternehmen wie Meta und Google durchgeführt. Hugging Face Hub hat sich zu einer zentralen Plattform für Machine-Learning-Modelle entwickelt. Dort kann man Tausende Modelle online testen und kostenfrei herunterladen. Diese eignen sich ohne weitere Verfeinerung aber meist nicht für den direkten Einsatz etwa in der Produktgruppe Kosmetika.

Transfer Learning: Man muss nicht bei null anfangen

Durch das Konzept Transfer Learning können Modelle für einen Anwendungsfall verfeinert werden. Man nimmt ein vortrainiertes allgemeines Modell und trainiert es mit einer vergleichbar kleinen Zahl spezialisierter Beispiele. Im Fall unseres Projekts Cosmention haben wir ein Modell für Named Entity Recognition (NER) weiterentwickelt. Ein NER-Modell kann in einem Text die Nennungen von Entitäten verschiedener Art erkennen. In unserem Fall haben wir die Entitäten-Label „Produkt“, „Marke“ und „Inhaltsstoff“ festgelegt. Das allgemeine Modell war noch nicht in der Lage, Produkte oder Inhaltsstoffe zu erkennen, Marken hingegen schon.

Mit unseren Trainingsdaten haben wir die beiden neuen Labels hinzugefügt und die Genauigkeit der Erkennung von Kosmetikmarken im Besonderen verbessert.

Passgenaue Trainingsdaten beschaffen

Das Training eines Modells für einen speziellen Anwendungsfall erfordert repräsentative Trainingsdaten. Diesen Bedarf genau zu beschreiben, Rohdaten zu beschaffen, ein Team von Analytinnen und Analysten zu schulen und Prozesse zum Qualitätsmanagement zu implementieren, ist eine anspruchsvolle Aufgabe. Modelle sind immer nur so gut wie die zur Verfügung stehenden Trainingsdaten. Um diese zu erhalten, braucht es Regeln.

Wenn sich die Analytinnen und Analysten nicht einig sind, wie soll ein Modell dann lernen? In unserem Anwendungsfall liegt die Herausforderung in der enormen Vielfalt von Eigennamen der Kosmetikprodukte und der Menge an Inhaltsstoffen. Was kann man sich etwa unter „Advantage Skincare“, „Feel Free Cosmetics“ und „THEORIE“ vorstellen? Handelt es sich dabei um eine Marke oder ein gewöhnliches Wort? Bei diesen doppelten Bedeutungen (Homonymen) zeigt sich, dass es nicht reicht, den Text schlicht nach Marken- und Produktnamen zu durchsuchen. Die Fehlerrate wäre zu hoch. In klassischen Social-Media-Monitoring-Tools kann man sich mit Operatoren wie AND, OR und NEAR behelfen und mit viel Ausprobieren eine einigermaßen saubere Query schreiben. Ziel von NER ist es also, diese Arbeit mit einem Modell zu ersetzen. Um die Homonyme und andere Schwierigkeiten zu bewältigen, haben wir umfangreiche Codierregeln definiert und prüfen zudem jedes Beispiel durch zwei Analysten. Mit wachsender Erfahrung in unserem Spezialgebiet Kosmetik steigt die Genauigkeit und Effizienz.



Literatur

Devlin, J., Chang, M. W., Lee, K., & Toutanova, K. (2018). Bert: Pre-training of deep bidirectional transformers for language understanding. arXiv preprint arXiv:1810.04805. <https://arxiv.org/abs/1810.04805>.

Kreuzberger, D., Kühl, N., & Hirschl, S. (2022). Machine Learning Operations (MLOps): Overview, Definition, and Architecture. arXiv preprint arXiv:2205.02302.

MLOps: Prozesse über Modelle

In den vergangenen zehn Jahren gab es in Natural Language Understanding (NLU) stetig bessere allgemeine Modelle. Eine Verbesserung der allgemeinen Modelle erhöht den Wert der spezialisierten Trainingsdaten, denn mit ihnen kann nun ein noch besseres, spezialisiertes Modell trainiert werden. Für viele Anwendungsfälle lohnt es sich daher, Modell-agnostisch vorzugehen und sich auf die Qualität der Trainingsdaten zu konzentrieren.

Das Paradigma MLOps (Machine Learning Operations) verschiebt den Fokus von der Modellarchitektur zu den Abläufen eines Machine-Learning-Projekts. Die These: In der Praxis scheitern Projekte eher an Mängeln bei den Prozessen als an der Lernfähigkeit der Modelle. MLOps beschreibt Best Practices von der Zieldefinition, über das Training, zur Überwachung von Modellen im Einsatz. Ziel ist es, Prozesse nachvollziehbar, reproduzierbar und automatisierbar zu gestalten. Dieser Prozessfokus hat uns auch bei Cosmention geholfen. Weiterhin unterschätzt bleiben die Prozesse zur manuellen Codierung von Trainingsbeispielen. Themen wie Inter-Coder-Reliabilität sind nicht neu, aber haben bei KI eine enorme Relevanz.

Eine wachsende Zahl von MLOps-Plattformen, beispielsweise Amazon SageMaker, Azure Machine Learning und Vertex AI (Google Cloud), machen es immer einfacher, zu einem Modell zu kommen, das Antworten per API liefert. Eine Zutat kann aber von den Cloud-Anbietern nicht geliefert werden: das passende Trainingsmaterial. Zwar gibt es auch dafür eine Vielzahl von Tools, durch die Codierung effizienter und genauer wird, doch die Verantwortung für die richtige Aufgabendefinition

und die Codierregeln lässt sich nicht abgeben. Auch das Definieren und Prüfen der Erfolgskriterien, wie der Genauigkeit des Modells, ist nicht delegierbar.

Wir haben in diesem Artikel zwei Bereiche – Projektstart und inhaltlicher Spezialisierungsschritt – innerhalb des komplexen Prozesses herausgegriffen, um einige Herausforderungen bei der Entwicklung eines KI-Tools wie Cosmention darzustellen.

Fazit: Wir haben ein schönes Monster erschaffen

Cosmention ist ein komplexes Gebilde, ein schönes Monster also, das im Hintergrund eine hohe Diversität an Datenquellen verarbeitet, aus unstrukturierten Daten ein strukturiertes Endprodukt schafft und für die Nutzerinnen und Nutzer ein intuitives Dashboard zur Verfügung stellt. Wer Analysen und Trendprognosen mit Cosmention durchführt, sieht diese Komplexität nicht. Die KI so zu verpacken, dass sie nicht komplex in der Anwendung ist, war ein weiteres wichtiges Ziel und führt zu einer höheren Nutzbarkeit. Die Einfachheit und intuitive Nutzung können allerdings dazu verleiten, dass die Komplexität und Qualität solcher Produkte nicht hinreichend geschätzt wird.

Eine weitere Beobachtung, die wir machen: KI weckt Begehrlichkeiten und die vielfältigen Analysemöglichkeiten können nicht nur in der Marktforschung genutzt werden. Marketing, Kommunikation, Produktentwicklung, Einkauf und Qualitätskontrolle sind mittlerweile Kundengruppen, die ein großes Interesse haben, KI-basierte Tools und Ansätze zu nutzen. Die Bedürfnisse und Erkenntnisinteressen werden dadurch diverser. Das sind für uns Chancen und neue Herausforderungen zugleich. ■

Die Autoren



FOTO: Q-AGENTUR FÜR FORSCHUNG

Paul Simmering ist Data Scientist bei Q! Agentur für Forschung. Er leitet die Entwicklung von Cosmention, dem KI-gestützten Social Media Monitoring Tool für Kosmetik. Daneben ist er an Projekten in FMCG und Pharma beteiligt und beschäftigt sich mit Natural Language Understanding und Data Engineering.

paul.simmering@teamq.de



FOTO: Q-AGENTUR FÜR FORSCHUNG

Oliver Tabino ist Gründer und Geschäftsführer von Q! Agentur für Forschung. Für ihn schließen sich qualitative Methoden und KI-basierte Tools nicht aus, sondern stellen eine spannende Ergänzung dar.

oliver.tabino@teamq.de

www.gessgroup.de



Alle Werkzeuge für eine Produktionsstraße . . .

Von **CESS Q** bis **CESS ChartFactory**: Die ganze Palette für alle Anforderungen der Marktforschung. GESS script sorgt dabei für den reibungslosen Ablauf.

CESS Q. – one script runs everywhere

