

Alexa, welche Aktien sollte ich kaufen?

Natural Language Processing und
Sentiment Analytics für Use Cases in
Capital Markets

NEXGEN


NEXGEN Whitepaper
September 2021

Tristan Poetzsch
Patrick Gschwendtner

Einführung

Immer häufiger wird die Verarbeitung von menschlicher Sprache auch eine Aufgabe von Maschinen. Ob Alexa und Siri im Wohnzimmer, der Chatbot der eigenen Versicherung und bis hin zum Sportteil der eigenen Zeitung – Maschinen lernen nach und nach, mit uns zu sprechen. All das ist möglich, da unsere technologischen Möglichkeiten für künstliche Intelligenz (KI) aufgrund des Zugangs zu immer größeren Datenmengen und Rechenkapazitäten immer besser werden.

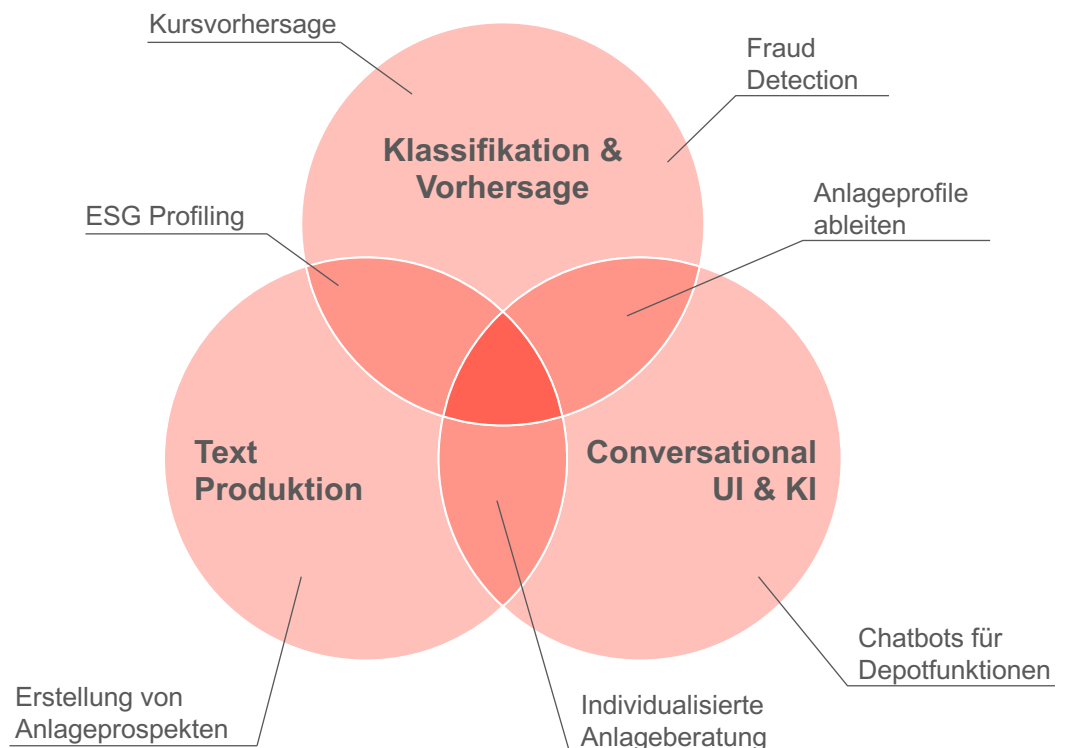
In den letzten Jahren ist daher die Disziplin des Natural Language Processing (NLP) immer wichtiger geworden, mit vielen Überschneidungen zu verwandten KI-Bereichen wie Machine Learning (ML) und Deep Learning (DL). Dabei sind die NLP-Modelle häufig von sehr hoher Komplexität. So wurde das GPT-3 Sprachmodell von OpenAI auf ungefähr einer Billionen Wörter trainiert (die Bibel im Vergleich besteht aus ungefähr 740.000 Wörtern). GPT-3 basiert dabei, wie viele andere Modelle auch, auf einer Technik namens „Transformer“. Dabei lernen diese Modelle im Wesentlichen die Eigenschaften und Merkmale der Sprache und berechnen dann mit statistischen Methoden die Wahrscheinlichkeiten, mit der eine bestimmte Folge von Wörtern in einem Text vorkommt. Damit lassen sich dann Sätze verstehen, aber vor allem auch von der KI erzeugte Sätze schreiben. Wie gut die Textgenerierung solcher Modelle ist, zeigte 2020 ein Informatik-Student der University of California in Berkeley: Er erstellte einen neuen Online-Blog mit Beiträgen von GPT-3 - und plötzlich landete einer seiner Artikel auf Platz 1 bei Hacker News. Nur die wenigsten Leser merkten, dass der Artikel von einer KI geschaffen wurde.





Doch mit den vielen Möglichkeiten ist der Raum an potentiellen Lösungen und Anwendungsfällen sehr groß. Insbesondere, da NLP nicht eingeschränkt ist auf bestimmte Algorithmusklassen wie Neuronale Netze, kann die Wiese aber durchaus etwas „zu grün“ wirken. Daher drängt sich die Frage auf: Wie schneidet man ein so weites Feld? Wie können Capital Markets Bereiche über die Anwendungsfälle nachdenken und diese klassifizieren?

Einen groben Überblick bietet die Strukturierung in die Bereiche Klassifikation & Vorhersage, Textproduktion und Conversational UI & KI. Obwohl ein End-2-End Anwendungsfall häufig mehrere dieser Komponenten nutzt, bietet die Unterteilung der Bausteine in diese Kategorien den Vorteil, dass es Anhaltspunkte für Referenzimplementierungen, Architekturen und Algorithmen gibt. Auf den folgenden Seiten werden einige dieser Anwendungsbeispiele noch einmal im Detail beleuchtet und ein konkreter Fall im Detail beleuchtet inklusive den Ergebnissen der NEXGEN Referenzimplementierung.



Experten im Interview

Gabriel Werner
Cloud Solution Architect FS bei Microsoft



Welche Rolle spielt NLP im Produktportfolio für Microsoft?

Gabriel: „Für Microsofts Produktstrategie im ML-Bereich ist NLP eine Schlüsseltechnologie. Dies wird durch strategische Investitionen untermauert, z.B. die Akquise von Nuance Communications im April oder die exklusive Lizenzierung von GPT-3 im Rahmen unserer laufenden Partnerschaft mit OpenAI.“

Wie hoch siehst du den Impact von NLP für Financial Services, zum Beispiel im Vergleich zu Themen wie Blockchain / Process Mining?

Gabriel: „Die Durchbrüche in der NLP-Forschung in den letzten Jahren, z.B. Transformers und Transfer learning, haben den Weg für neue Use Cases geebnet. Im Vergleich zu manchen anderen Forschungsgebieten gibt es hierfür viele konkrete Anwendungsfälle. Vielleicht bestehen wir sogar in absehbarer Zeit den Turing-Test, was für das Spektrum der Möglichkeiten noch weiter vergrößern würde.“

Was sind die größten Herausforderungen beim Einsatz von NLP für Financial Service Unternehmen?

Gabriel: „Natürlich sind die Aspekte Data Governance, Privacy und Security die dominanten Herausforderungen im Financial Services Bereich, vor allem auch in Kombination mit der Skepsis vieler Mitarbeiter:innen und Kund:innen gegenüber den primär cloud-basierten Implementierungen. Hier dominiert die Frage, wie sich die Offenheit gegenüber der Technologie fördern lässt. Und da das Einsatzfeld für NLP so weitläufig ist, ist auch das kreative Erschließen der Möglichkeiten eine immer wieder unerwartet große Herausforderung. Aber: Es hilft, immer wieder Ideen vorzuleben.“



Anwendungsbeispiel

Kursvorhersage auf Basis von Sentiment Analysis


Der erfolgreiche Handel an der Börse hängt von Informationen über ausgewählte Aktien ab. Basierend auf diesem Wissen können Händler entscheiden, ob sie eine Aktie kaufen, halten oder verkaufen sollen. Neben der Analyse von Geschäftszahlen, Marktpreise und Kredit-Ratings ist es wichtig zu wissen, was bestimmte Personen über diese Unternehmen sagen. Beispiele dafür sind Analysten und Short Seller, die Informationen über Social-Media Kanäle und Newslettern oder Blogs teilen oder die Reden von CEOs auf der Jahreshauptversammlung, welche eine allgemeine Stimmung im Unternehmen wiedergibt. Aber selbst Tweets mit Emojis können Kurse stark beeinflussen.

Die klassischerweise, im Investment Prozess, Analysten vorbehaltene Aufgabe der Bewertung des öffentlichen Stimmungsbildes gegenüber des Marktes, kann durch Natural Language Processing unterstützt und sogar in Teilen automatisiert werden – vor allem weil die Real-Time-Verarbeitung z.B. von Twitter-Hashtags menschlich kaum mehr zu leisten ist. Große Herausforderung in der Sentiment Analyse ist und bleibt aber, dass eine Formulierung in unterschiedlichen Kontexten sehr unterschiedliches Gewicht tragen kann. So sind in wissenschaftlichen Publikationen Formulierungen wie „Es erscheint wahrscheinlich, dass“ quasi der stärkste mögliche Ausdruck, während dieselbe Formulierung im Kontext herkömmlichen Journalismus eher schwächer ist.

Noch einen Schritt weiter geht es, wenn nicht nur die Verarbeitung von Sprache, sondern auch von Audio- oder Videoinformationen ergänzt wird. So hatte Microsoft bereits 2018 einen Showcase, in dem Natural Language Processing und Facial Expression in einem Sentiment Algorithmus zusammengerechnet wurden, um ein noch besseres Ergebnis zu erzielen.

Was ist Sentiment Analysis?

Sentiment Analysis ist eine Disziplin des Natural Language Processing und beschäftigt sich mit der Extraktion von Emotionen und Einstellungen in Freitexten. Dabei wird versucht Wörtern oder Sätzen ein Label „positiv“, „negativ“ oder „neutral“ zuzuordnen. Ein typischer Anwendungsfall ist die Klassifizierung von Restaurantbewertungen.



Anwendungsbeispiel

Risikobewertung für Kredite

Banken können die Chancen einer erfolgreichen Kreditrückzahlung anhand einer Kreditrisikobewertung quantifizieren. In der Regel wird die Zahlungskapazität auf der Grundlage früherer Ausgabenmuster und früherer Kreditrückzahlungsdaten berechnet. Diese Informationen sind jedoch in einigen Fällen nicht verfügbar, zum Beispiel weil noch keine Kredithistorie vorliegt – und wird auch bei Vorhandensein sinnvoll weiter um NLP ergänzt.

In der direkten Bewertung der Kreditwürdigkeit kann Natural Language Processing verwendet werden, um auf Basis mehrerer (qualitativer) Datenpunkte das Ausfallrisiko zu bewerten. NLP kann beispielsweise die Einstellung und unternehmerische Denkweise bei Unternehmenskrediten messen, indem es Texte von Websites oder Veröffentlichungen scannt. Ebenso kann NLP für Plausibilitätsprüfungen genutzt werden und auf inkonsistente Daten in Dokumenten hinweisen, um diese einer genaueren Prüfung zu unterziehen. Darüber hinaus können subtile Aspekte wie die Emotionen des potentiellen Kreditnehmers während eines Kreditprozesses mitberücksichtigt werden.

Im Prozess der Bewertung kann NLP auch hilfreich sein, um Fehlerquellen zu minimieren und Zeit zu sparen: So können NLP-Mechanismen zum Beispiel Informationen automatisch aus Dokumenten extrahieren und in andere Prozessschritte einspeisen. Insbesondere bei der antragsinternen Referenzierung, zum Beispiel von Daten, Orten, beteiligten Parteien sowie deren Verhältnissen zueinander kann NLP relevante Informationen vollautomatisch mithilfe von Named Entity Recognition-Algorithmen (NER) erkennen und verarbeiten.

Was ist Named Entity Recognition?

Damit NLP-Algorithmen die Attribute im Text auch korrekt zuordnen können, müssen sie diese zuerst einmal erkennen. Hier greifen die Named Entity Recognition Bausteine. Mithilfe derer können NLP-Algorithmen erkennen, dass in dem Satz „Die Pizza bei Bella Italia schmeckt nach Schuhsohle“ „Bella Italia“ ein Eigenname ist.



Anwendungsbeispiel

Erstellung von ESG Profilen

Für viele Investoren nimmt der Fokus auf die nichtfinanziellen Aspekte ihrer Investments heutzutage einen viel größeren Fokus ein als noch vor einigen Jahren. Das ESG-Modell (Environmental, Social, Governance) dient hierbei als Ausgangspunkt und wird auch bereits von vielen Analysten zugrunde gelegt. Dabei bestehen diese Einschätzungen zu einem Teil aus quantitativen Scores und zu Teilen aus qualitativen Einschätzungen.

Die Erzeugung dieser Einschätzungen kann von Natural Language Processing gleich in zweierlei Hinsicht profitieren: Auf der einen Seite können die Algorithmen die Suche und Bewertung von Informationsmaterialien übernehmen. Vor allem, da viele Aspekte noch nicht umfassend quantifiziert sind und eher qualitativ dargelegt werden, kann hier maschinell vieles vorbereitet werden:

1. **Environmental:** Unternehmenseigene Veröffentlichungen wie Nachhaltigkeitsberichte können genauso herangezogen werden wie Meldungen aus der Presse, zum Beispiel über Investitionen in umweltfreundliche Technologien. Darüber hinaus können diverse Veröffentlichungen von NGOs herangezogen werden, welche ökologische Fußabdrücke bewerten.
2. **Social:** Soziale Bewertungen eines Unternehmens können neben den üblichen Medienberichten und Echos vor allem auch aus der Auswertung des Sentiments in sozialen Netzwerken abgeleitet werden. Auch Berichte von Aufsichtsräten mit Betriebsratsbeteiligungen und Veröffentlichungen von Gewerkschaften sollten hier berücksichtigt werden.
3. **Governance:** Wie gut die Governance eines Unternehmens aufgestellt ist, lässt sich einerseits aus den Publikationen aus dem Bereich Investor Relations und den Aufsichtsratsberichten im Rahmen von Hauptversammlungen ableiten, aber auch aus der Berichterstattung von Wirtschaftspresse.

Darüber hinaus können NLP-Algorithmen nach der Analyse auch in der Erstellung der Ratings unterstützen, indem sie die teilweise hochindividuellen Textteile erzeugen. Dabei können sie sowohl bekannte Schemata imitieren um Analysen kongruent zu halten, aber vor allem auch Bausteine für die individuellen Komponenten erzeugen.

Wie funktionieren NLP-Modelle technisch?

Für uns Menschen ist das Verstehen von Sätzen und deren Zusammenhängen kein Problem – schließlich haben wir das von klein auf gelernt. Doch wie bringt man Maschinen eine Sprache bei? Die Anforderung dabei ist es, dem Computer die Wörter und Sätze so darzureichen, dass er diese verarbeiten kann. Dafür gibt es kein standardisiertes Vorgehen, sondern eher eine Art Baukasten, aus dem man Steine zu einem Modell zusammensetzt.

- Einfache Modelle sind zum Beispiel das *bag-of-words Modell*, bei dem die Häufigkeit jedes auftretendes Wortes als Merkmal zum Trainieren eines Klassifikators verwendet wird. Da nicht alle Wörter relevant sind und z.B. „Glück“ und „glücklich“ gleich behandelt werden sollen, werden Techniken wie die *Lemmatisierung* und *Stopping words* verwendet. Der Nachteil dieser Modelle ist, dass nur die Anzahl der auftretenden Wörter betrachtet wird und nicht deren Zusammenhänge. Für weniger anspruchsvolle Analysen vor allem mit geringer Komplexität in den auszuwertenden Texten sind die aber häufig zielführend.
- Komplexere Modelle, die Zusammenhänge berücksichtigen, sind zum Beispiel *Part-of-Speech Tagging* basierend auf dem *Hidden Markov Modell*, oder Transformer Modelle wie Google's *BERT*. *BERT* ist ein unüberwachtes Modell, dass durch Millionen von Sätzen die Zusammenhänge einer Sprache lernt. Mittlerweile stellen Firmen wie Google und OpenAI vortrainierte Modelle zur Verfügung, die die Grundstruktur einer Sprache verstehen und „sprechen“, aber noch nicht an Industrien angepasst sind. Diese Modelle lassen sich mit z.B. Finanztexten und -sentiments noch optimieren und so für den benötigten Use Case anpassen.

Case Study

Vorhersage von Indexrenditen auf Basis der Sentiments von institutionellen Veröffentlichungen

In dieser Case Study hat NEXGEN institutionelle Veröffentlichungen des ifo Institutes und der BaFin als Datenquelle verwendet, um auf Basis der daraus abzuleitenden Sentiments die monatliche Rendite des DAX vorherzusagen. Dazu wurden die Veröffentlichungen ifo Schnelldienst und BaFin Journal über den Zeitraum der letzten 20 Jahre herangezogen. Theorie des Use Cases war, dass die großen Publikationen eine Vorhersagekraft, ja vielleicht sogar einen Einfluss auf die Renditenentwicklung hat. Also ein positiver Bericht des ifo-Instituts unterstützt zum Beispiel die Zuversicht der Anleger. Um diese Theorie einem Test zu unterziehen, haben wir ein NLP-gestütztes Modell gebaut und damit gleichzeitig eine Referenzarchitektur entwickelt.




Zur Ermittlung von Sentiment Scores wurde *FinBERT* genutzt. *FinBERT* ist eine künstliche Intelligenz auf Basis von *BERT / Tensorflow*, die zusätzlich mit Texten aus der Finanzbranche und gelabelten Sentiment Daten trainiert wurde. Mithilfe dieses Modells wurde jedes Wort aus jedem Dokument nach „positiv“, „negativ“ und „neutral“ klassifiziert. Mit der Anzahl der Klassifizierungen wurde für jedes Dokument ein Sentiment Score berechnet und damit ein lineares Regressionsmodell trainiert um die Rendite des DAX vorherzusagen.

Die Case Study wurde in einem hybriden Setup gebaut, das sowohl Teile on-premises wie auch in der Cloud laufen lässt. Hiermit lässt sich gut simulieren, wie persistente Daten in der eigenen Kontrolle gehalten werden können und trotzdem die skalierbare Rechenkapazität der Cloud herangezogen werden kann.

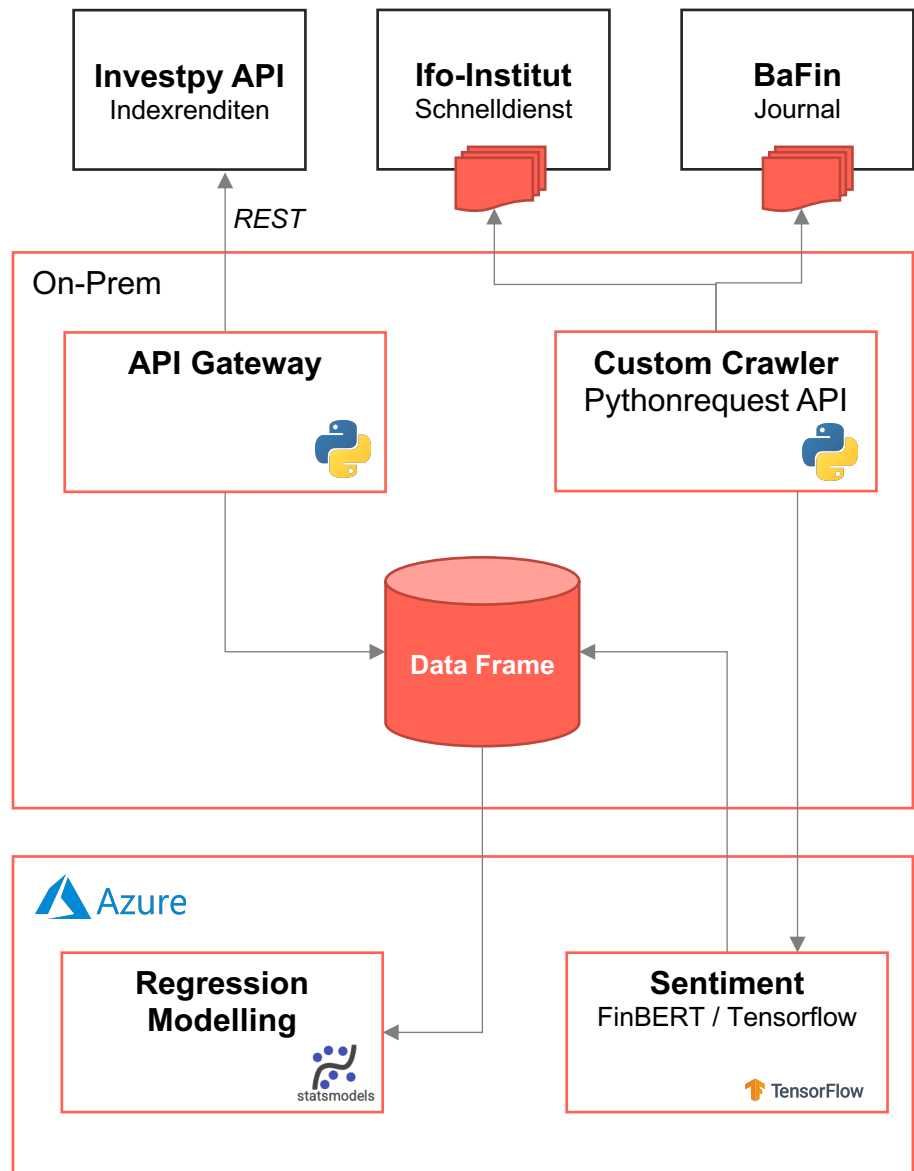
Interpretation der Ergebnisse

Wie das Schaubild unten verdeutlicht, folgt die Stimmungsreaktion in der Veröffentlichungen erst nach der Rendite. Auf den ersten Blick ist das nicht besonders intuitiv. Das liegt vor allem daran, dass Menschen sich leicht beeinflussen lassen und deshalb dazu tendieren, positive bzw. negative Situationen zu über- bzw. unterbewerten. Bei aufeinanderfolgenden, positiven Renditen nehmen Menschen einzelne Verluste hin, erst wenn diese sich häufen reagiert er und erkennt, dass die Verluste keine Ausnahmen sind. Selbiges gilt, wenn nach einer Phase von Verlusten wieder Gewinne folgen. Auch hier ist der Mensch zunächst in seinem Verhalten und seinen Äußerungen vorsichtig und wartet ab, ob dies nur eine kurze Phase des Gewinns oder eine langfristige Erholung des Marktes ist.

Doch genau diese auf den ersten Blick unintuitive Einsicht ist, was maschinelle Modelle den menschlich modellierten Vorhersagen voraus haben: Sie erkennen Muster früher, adaptieren und helfen dabei, bessere Anlageentscheidungen zu treffen. Somit kann unser Use Case zwar nicht wie initial vermutet, aber doch mit einem absolut wichtigen Ergebnis aufwarten und verdeutlicht einmal mehr, welche Rolle NLP für die Zukunft in Capital Markets spielt.



Architektur des Use Cases



**Interessiert an mehr?
Ihre Ansprechpartner:**



Tristan Poetzsch

Manager

tristan.poetzsch@nexgenbc.com



Patrick Gschwendtner

Consultant

patrick.gschwendtner@nexgenbc.com



NEXGEN

Dieses Werk ist urheberrechtlich geschützt. All rights reserved.

NEXGEN Business Consultants GmbH
Grüneburgweg 101
60323 Frankfurt am Main