

---

# Vorhersage von Aktienkursausschlägen mit Large Language Models auf Börsennachrichten: Eine Evaluation eines vortrainierten Modells anhand verschiedener Unternehmenskennzahlen

Bachelorarbeit zur Erlangung des akademischen Grades  
*Bachelor of Science (B.Sc.)*  
im Studiengang Wirtschaftsinformatik  
an der Fakultät für Informatik und Ingenieurwissenschaften  
der Technischen Hochschule Köln

vorgelegt von: Lennard Feuerbach  
Matrikel-Nr.: [entfernt]  
Adresse: [entfernt]  
lennard.feuerbach@smail.th-koeln.de

eingereicht bei: Prof. Dr. Johann Schaible (TH Köln)  
Zweitgutachter\*in: M.Sc. Lars Wißler (PWP Leeway UG)

Köln, 26.07.2024

## Kurzfassung

Im Bereich der Sprachmodelle existieren Methoden zur Analyse und Bewertung menschlicher Texte in Form eines *Sentiment-Score*, der die positive oder negative Stimmung eines Textes bewertet. Im Finanzsektor können solche Modelle auf Aktiennachrichten angewendet werden, um auf Basis dieses *Sentiment-Scores* Entscheidungen über den Kauf oder Verkauf von Aktien zu treffen. Allerdings birgt die Fokussierung auf die Stimmung das Risiko, dass wesentliche Informationen für die Kursentwicklung unberücksichtigt bleiben, was zur Folge hat, dass die Prognosen nicht so präzise sind, wie sie sein könnten. In dem vorangegangenen Praxisprojekt, das die Grundlage dieser Bachelorarbeit bildet, wurde dieses Prinzip überarbeitet und erweitert. Dabei wurde ein Sprachmodell entwickelt, das nicht mehr lediglich den *Sentiment-Score* berechnet, sondern direkt eine Kursänderung zu einem festgelegten Zieldatum auf Basis von Nachrichtenartikeln prognostiziert. Die vorliegende Bachelorarbeit greift diesen Ansatz auf und untersucht, inwieweit Unternehmen, die anhand der Größe ihrer Marktkapitalisierung, Dividendenrendite und Nettogewinnmarge in Gruppen eingeteilt wurden, eine stärkere Abhängigkeit von Nachrichten aufweisen. Darüber hinaus wird analysiert, wie sich diese Abhängigkeit auf die Genauigkeit der Kursänderungsprognosen auswirkt und in welchem Maße sie die erzielte Rendite beeinflusst. Die Analyse und Bewertung zeigt für alle untersuchten Unternehmen positive Tendenzen. Hervorzuheben ist, dass kleinere Unternehmen mit niedrigen Kennzahlenwerten signifikant bessere Ergebnisse erzielen als größere Unternehmen mit höheren Kennzahlenwerten.

**Schlagwörter:** Sprachmodelle, Sentiment-Analyse, Kursprognosen, Aktienmarkt, Aktiennachrichten, Unternehmenskennzahlen, Investmententscheidungen

## Abstract

In the field of large language models, there are methods for analyzing and evaluating human texts in the form of a sentiment score, which assesses the positive or negative sentiment of a text. In the financial sector, such models can be applied to stock news in order to make decisions about buying or selling stocks on the basis of this sentiment score. However, focusing on sentiment carries the risk that essential information for the price development is not taken into account, which means that the forecasts are not as precise as they could be. In the previous practical project, which forms the basis of this bachelor's thesis, this principle was revised and expanded. A language model was developed that no longer simply calculates the sentiment score, but instead directly predicts a price change on a specified target date on the basis of news articles. This bachelor's thesis takes up this approach and analyses the extent to which companies that have been divided into groups based on the size of their market capitalization, dividend yield and net profit margin are more dependent on news. Furthermore, the analysis examines how this dependence affects the accuracy of the price change forecasts and to what extent it influences the return achieved. The analysis and evaluation show positive trends across all companies. Notably, smaller companies with lower key figure values achieved significantly better outcomes than their larger counterparts.

**Keywords:** language models, sentiment analysis, price forecasts, stock market, stock news, company key figures, investment decisions

# Inhaltsverzeichnis

<b>Tabellenverzeichnis</b>	<b>V</b>
<b>Abbildungsverzeichnis</b>	<b>VI</b>
<b>Listingsverzeichnis</b>	<b>VII</b>
<b>Abkürzungsverzeichnis</b>	<b>VIII</b>
<b>1. Einleitung</b>	<b>1</b>
1.1. Problemstellung . . . . .	1
1.2. Zielsetzung . . . . .	3
1.3. Herangehensweise . . . . .	3
<b>2. Theoretische Grundlagen</b>	<b>5</b>
2.1. Einführung in das Konzept des Praxisprojektes . . . . .	5
2.2. Bewertung und Klassifizierung von Unternehmen . . . . .	7
<b>3. Methodik</b>	<b>9</b>
3.1. Auswahl und Begründung der Kennzahlen . . . . .	9
3.1.1. Definition Marktkapitalisierung . . . . .	9
3.1.2. Definition Nettogewinnmarge . . . . .	10
3.1.3. Definition Dividendenrendite . . . . .	11
3.2. Methodik des Programms . . . . .	12
3.2.1. Datenakquisition und -berechnung . . . . .	13
3.2.2. Nutzung des Sprachmodells . . . . .	15
3.2.3. Auswertung und Evaluation . . . . .	16
<b>4. Implementierung der Methodik</b>	<b>17</b>
4.1. Grundlegende Funktionen . . . . .	19
4.2. Datenakquisition und -berechnung . . . . .	20
4.3. Nutzung des Sprachmodells . . . . .	29
4.4. Auswertung und Evaluation . . . . .	30
<b>5. Evaluationsmethodik</b>	<b>31</b>
5.1. Kriterien . . . . .	31

5.2. Auswertung . . . . .	33
<b>6. Ergebnisse</b>	<b>36</b>
6.1. Metadaten . . . . .	36
6.1.1. Verteilung der Daten . . . . .	36
6.1.2. Verteilung der Kursänderungen . . . . .	38
6.1.3. Baseline der Gruppen . . . . .	40
6.2. Resultate Marktkapitalisierung . . . . .	44
6.3. Resultate Nettogewinnmarge . . . . .	48
6.4. Resultate Dividendenrendite . . . . .	52
6.5. Signalgenauigkeit . . . . .	56
<b>7. Diskussion</b>	<b>58</b>
7.1. Interpretation . . . . .	58
7.2. Limitierungen und Risiken . . . . .	61
<b>8. Fazit und Ausblick</b>	<b>63</b>
<b>Literatur</b>	<b>67</b>
<b>Linkverweise</b>	<b>69</b>
<b>A. Anhang</b>	<b>71</b>

## Tabellenverzeichnis

2.1. Datenstruktur bei Sentiment-Score . . . . .	6
2.2. Datenstruktur bei Kursänderung . . . . .	6
5.1. Bedeutung der verwendeten Symbole . . . . .	31
5.2. Ausschnitt aus der Simulationstabelle . . . . .	33
5.3. Beispielhafte Ergebnisse . . . . .	34
5.4. Beispielhafte Signalgenauigkeit . . . . .	35
6.1. Verteilung der Aktien nach Kennzahl und Gruppen . . . . .	37
6.2. Verteilung der Nachrichten nach Kennzahl und Gruppen . . . . .	37
6.3. Ergebnisse für Marktkapitalisierung nach Signal und Gruppe (3D) . . . . .	45
6.4. Ergebnisse für Marktkapitalisierung nach Signal und Gruppe (1W) . . . . .	46
6.5. Ergebnisse für Marktkapitalisierung nach Signal und Gruppe (2W) . . . . .	47
6.6. Ergebnisse für Nettogewinnmarge nach Signal und Gruppe (3D) . . . . .	49
6.7. Ergebnisse für Nettogewinnmarge nach Signal und Gruppe (1W) . . . . .	50
6.8. Ergebnisse für Nettogewinnmarge nach Signal und Gruppe (2W) . . . . .	51
6.9. Ergebnisse für Dividendenrendite nach Signal und Gruppe (3D) . . . . .	53
6.10. Ergebnisse für Dividendenrendite nach Signal und Gruppe (1W) . . . . .	54
6.11. Ergebnisse für Dividendenrendite nach Signal und Gruppe (2W) . . . . .	55
6.12. Signalgenauigkeit für Marktkapitalisierung nach Signal und Gruppe . . . . .	56
6.13. Signalgenauigkeit für Nettogewinnmarge nach Signal und Gruppe . . . . .	56
6.14. Signalgenauigkeit für Dividendenrendite nach Signal und Gruppe . . . . .	57

## Abbildungsverzeichnis

3.1. Ablauf der Methodik in graphischer Darstellung . . . . .	12
6.1. Histogramm der vorhergesagten und realen Kursänderungen (3D) . . .	38
6.2. Histogramm der vorhergesagten und realen Kursänderungen (1W) . .	39
6.3. Histogramm der vorhergesagten und realen Kursänderungen (2W) . .	40
6.4. Mittelwert für Marktkapitalisierung nach Gruppen und Zieldaten . . .	41
6.5. Std.Abw. für Marktkapitalisierung nach Gruppen und Zieldaten . . . .	41
6.6. Mittelwert für Nettogewinnmarge nach Gruppen und Zieldaten . . . .	42
6.7. Std.Abw. für Nettogewinnmarge nach Gruppen und Zieldaten . . . . .	42
6.8. Mittelwert für Dividendenrendite nach Gruppen und Zieldaten . . . .	43
6.9. Std.Abw. für Dividendenrendite nach Gruppen und Zieldaten . . . . .	43
6.10. Mittelwert der Summe für die Marktkapitalisierung . . . . .	44
6.11. Median der Summe für die Marktkapitalisierung . . . . .	44
6.12. Mittelwert der Summe für die Nettogewinnmarge . . . . .	48
6.13. Median der Summe für die Nettogewinnmarge . . . . .	48
6.14. Mittelwert der Summe für die Dividendenrendite . . . . .	52
6.15. Median der Summe für die Dividendenrendite . . . . .	52
8.1. Entscheidungsmatrizen nach Risiko und Handelsfrequenz . . . . .	64

## Listingsverzeichnis

4.1. Projektstruktur des GitHub-Repositories . . . . .	18
4.2. Pseudocode für das Laden der Nachrichtenartikel . . . . .	22
4.3. Pseudocode für das Laden und Berechnen der Kennzahlen . . . . .	24
4.4. Pseudocode für die Marktkapitalisierung und Dividendenrendite . . . . .	25
4.5. Pseudocode für die Nettogewinnmarge . . . . .	26
4.6. Pseudocode für das Beziehen der Kurswerte der Aktien . . . . .	28



# Abkürzungsverzeichnis

**API** Application Programming Interface.

**BERT** Bidirectional Encoder Representations from Transformers.

**DB** Datenbank.

**ETF** Exchange Traded Fund.

**GPT** Generative Pre-trained Transformer.

**HTML** Hypertext Markup Language.

**ISO** International Standards Organization.

**JSON** JavaScript Object Notation.

**LLaMA** Large Language Model Meta AI.

**LLM** Large Language Model.

**NaN** Not a Number.

**NLTK** Natural Language Toolkit.

**NYSE** New York Stock Exchange.

## Hinweis zur geschlechtsneutralen Sprache

Aus Gründen der Lesbarkeit wird in dieser Arbeit ausschließlich das generische Maskulinum verwendet. Dies geschieht, um den Textfluss nicht zu verkomplizieren und die Verständlichkeit zu erhöhen. Selbstverständlich sind alle Geschlechter gleichermaßen angesprochen.

# 1. Einleitung

Mit einer zeitlosen Einsicht in den Kern der Anlagestrategie betonte der ehemalige Fondsmanager Peter Lynch: „*Know what you own, and know why you own it*“<sup>1</sup>. Auch mehr als zwei Jahrzehnte später behält diese Weisheit in der heutigen schnelllebigen Finanzwelt ihre grundlegende Bedeutung und Relevanz.

## 1.1. Problemstellung

In einer Welt, in der Börsennachrichten innerhalb von Sekunden globale Marktreaktionen auslösen können, stellt die Fähigkeit, Informationen schnell und präzise zu interpretieren, einen fundamentalen Vorteil dar. Bisher mussten sich Analysten und Investoren auf traditionelle quantitative Analysen und ihr Bauchgefühl verlassen, um die Stimmung und mögliche Kursausschläge vorherzusagen. Doch das Aufkommen von Large Language Model (LLM)s, einer fortschrittlichen Form der künstlichen Intelligenz, die im Stande ist, menschliche Sprache zu verstehen und zu interpretieren, revolutioniert die Art und Weise, wie Börsennachrichten bewertet werden können. Dieser Paradigmenwechsel gibt Anlass zu der These, dass solche Modelle, spezialisiert auf die Analyse von Börsennachrichten, signifikante Aktienkursausschläge mit einer bisher unerreichten Präzision vorhersagen können. Anknüpfend an diese These, untersucht die vorliegende Bachelorarbeit die Wirksamkeit solcher Modelle durch eine umfassende Evaluation anhand verschiedener Unternehmenskennzahlen.

Diese Bachelorarbeit erweitert dazu das zugrundeliegende Praxisprojekt mit dem Titel: „Developing a BERT-based Language Model with Advanced Data Processing for Stock News Analysis“<sup>2</sup> das sich mit der Entwicklung und Feinabstimmung eines Sprachmodells beschäftigt. Das in dem Projekt verwendete Sprachmodell stützt sich auf Bidirectional Encoder Representations from Transformers (BERT) ein von Google im Jahr 2019 veröffentlichtes Modell. Dieses Modell basiert auf der Transformer-Architektur, welche einen grundlegenden Wandel in der Entwicklung von Sprachverarbeitungsmodellen eingeleitet hat [2]. Ziel des Praxisprojektes war es, auf Basis dieser Analysen, Prognosen über zukünftige Kursveränderungen der betrachteten Aktien abzugeben.

---

<sup>1</sup>Zitat Peter Lynch [Link], Abgerufen am 01.06.2024

<sup>2</sup>Praxisprojekt GitHub Repository [Link], Abgerufen am 01.06.2024

Sowohl das Praxisprojekt als auch diese Bachelorarbeit sind in Zusammenarbeit mit dem Startup Leeway<sup>3</sup> durchgeführt worden. Leeway spezialisiert sich auf die Analyse von Aktienmärkten mit Hilfe künstlicher Intelligenz. Für das Praxisprojekt und diese Arbeit hat das Unternehmen eine Application Programming Interface (API) zur Verfügung gestellt, die den Zugriff auf notwendige Kennzahlen sowie Fundamentaldaten der untersuchten Aktien ermöglicht. Diese Kooperation und technische Ressource waren essenziell für die Durchführung der Analyse und die Entwicklung des Sprachmodells. Die Analyse von Finanznachrichten mithilfe von Sprachmodellen repräsentiert ein dynamisch entwickelndes Forschungsfeld, welches bereits spezialisierte Modelle wie FinBERT [1] hervorgebracht hat. Diese sind präzise auf die Anforderungen der Domäne zugeschnitten. Ein Großteil der bisherigen Forschungsbemühungen und praktischen Anwendungen innerhalb dieses Bereichs fokussiert sich auf die Sentiment-Analyse [5]. In dieser werden die Texte einer eingehenden Analyse unterzogen und anschließend bestimmten Stimmungslagen oder -werten (*sentiments*) zugeordnet. Auf Basis dieser Stimmungsanalyse der Texte werden weitere Entscheidungen oder Prognosen getroffen, die meist in Kaufsignale oder prognostizierte Kursveränderungen umgesetzt werden. Allerdings mangelt es häufig an einer direkten Verbindung zwischen Nachrichtenartikeln und Kursänderungen, da die bestehende Forschung überwiegend auf das Konzept der Sentiment-Analyse operiert [7][8].

Das durchgeführte Praxisprojekt distanziert sich jedoch von diesem etablierten Ansatz der Sentiment-Analyse. Stattdessen erfolgt, wie oben beschrieben, eine direkte Zuordnung einer vorhergesagten Kursänderung zu einer spezifischen Finanznachricht. Diese methodische Abweichung markiert einen bedeutenden Unterschied zu den bisher existierenden Projekten und Forschungsansätzen. Obwohl ein beträchtlicher Teil der Forschung sich primär auf die Sentiment-Analyse konzentriert, existieren dennoch spezifischere Studien, die sich mit demselben oder einem ähnlichen Forschungsbereich wie die vorliegende Arbeit befassen. Diese unterstreicht sowohl die Notwendigkeit als auch das Potenzial von solchen Ansätzen, insbesondere angesichts der Entwicklungen in der relevanten Literatur. Dabei existieren einige Forschungsarbeiten, die sich aus verschiedenen Perspektiven mit den Themen der Finanzmarktanalyse und der direkten Prognosemethode auseinandersetzen. Ein exemplarisches Beispiel zu den Anfängen dieses Themenbereichs finden sich in den Studien von Gidfalvi [6], welcher den *Bayesian Text Classifier* nutzte, um Nachrichtenartikel und deren direkten kurzfristigen Einfluss auszuwerten. Dies markiert einen wichtigen Zeitpunkt in der Entwicklung des untersuchten Forschungsbereichs.

Die Bachelorarbeit erweitert das bisherige Projekt um den Aspekt der Analyse der direkten Vergleichbarkeit von Unternehmenskennzahlen, sowohl innerhalb festgelegter Grenzen und Gruppen als auch darüber hinaus. Dabei wird untersucht, ob bestimmte

---

<sup>3</sup>PWP Leeway UG [Link], Abgerufen am 01.06.2024

Gruppen eine bessere durchschnittliche oder mediane Rendite erzielen als andere und somit eine höhere Genauigkeit bei der Vorhersage von Kursänderungen auf Basis der Nachrichten aufweisen. Dies könnte auf eine Korrelation zwischen bestimmten Kennzahlenwerten und der korrekten Vorhersage von Aktienkursbewegungen hindeuten. Bisher mangelt es an detaillierten Studien, die systematisch den Einfluss finanzieller Leistungsindikatoren auf die Vorhersagegenauigkeit von Aktienpreisen beleuchten.

## 1.2. Zielsetzung

Im Kontext der Aktienanalyse stellen verschiedene Kennzahlen wesentliche Instrumente dar, durch die eine Beurteilung und Bewertung von Aktien erfolgen kann. Angesichts der umfangreichen Palette an finanziellen Kennzahlen, deren Nutzen je nach Kontext variiert, erfordert eine effektive Analyse eine sorgfältige Auswahl spezifischer Kriterien. Diese Kennzahlen können weiterhin in unterschiedliche Kategorien klassifiziert werden. In dieser Arbeit liegt der Schwerpunkt auf der detaillierten Analyse spezieller Bewertungskennzahlen: Der Marktkapitalisierung, der Nettogewinnmarge und der Dividendenrendite. Der Ökonom Viktor Heese definiert Bewertungskennzahlen, indem er betont, dass der Begriff der Bewertung weit über eine einfache numerische Bewertung hinausgeht. Er argumentiert, dass dieser Begriff auch die Kaufattraktivität einer Aktie umfassen sollte [4]. Diese Perspektive untermauert den Entscheidungsprozess, der den Einsatz solcher Kennzahlen rechtfertigt.

Ziel ist es, eine differenzierte Analyse hinsichtlich des möglichen unterschiedlichen Einflusses der verschiedenen Wertebereiche der Kennzahlen auf die Prognosegenauigkeit von Aktienkursbewegungen zu erarbeiten. Der Schwerpunkt liegt dabei auf der Untersuchung der Korrelation zwischen den genannten Kennzahlengruppen und der Vorhersagegenauigkeit sowie der durchschnittlichen beziehungsweise medianen Rendite dieser Gruppen. Es soll evaluiert werden, inwieweit diese Wertebereiche als Einflussvariablen für den Erfolg der Vorhersage dienen können. Diese Fokussierung basiert auf der grundlegenden Hypothese, dass eine systematische Analyse und Verständnis dieser Kennzahlen und deren Wertebereichen zu einer verbesserten Vorhersagegenauigkeit von Aktienkursbewegungen führen kann. Die Einschätzungen und Vorhersagen basieren dabei auf der Anwendung des im Praxisprojekts entwickelten Sprachmodells.

## 1.3. Herangehensweise

Zur Durchführung der empirischen Methode wird die API von Leeway herangezogen, um Zugang zu allen notwendigen Kennzahlen sowie zu den Fundamentaldaten der

betrachteten Aktien zu erhalten. Zur Gewährleistung einer adäquaten Vergleichbarkeit der ausgewählten Aktien werden diese gemäß der vordefinierten Unternehmenskennzahlen in diverse Kategorien eingeteilt. Es ist von essenzieller Bedeutung, dass alle weiteren Rahmenbedingungen und externen Einflussfaktoren weitestgehend homogen gehalten werden, um die Integrität der Vergleichbarkeit nicht zu gefährden. Anschließend erfolgt der Einsatz des im Rahmen des Praxisprojekts entwickelten und trainierten Sprachmodells, um Prognosen hinsichtlich der Kursentwicklungen einzelner, nach spezifischen Kennzahlen segmentierter Gruppen zu erstellen. Diese Gruppen werden dann einer vergleichenden Analyse unterzogen, bei der die durchschnittliche oder mediane Rendite einer Aktie in jeder Gruppe verglichen wird.

Die Bachelorarbeit gliedert sich im Weiteren wie folgt: Es wird zunächst das Konzept des zugrundeliegenden Praxisprojekts eingeführt, um eine solide Basis für das Verständnis der weiteren Nutzung und Erweiterung zu schaffen. Es folgt eine Erläuterung der Klassifizierung von Unternehmen und des damit verbundenen Mehrwerts. Die methodische Herangehensweise umfasst die Definition und Auswahl spezifischer Kennzahlen und erläutert den detaillierten Ablauf der Studie. In der Implementierungsphase wird die praktische Umsetzung dieser Methodik dargelegt. Im Folgenden wird die Evaluationsmethodik vorgestellt, die das Vorgehen und die anschließende Darstellung der Ergebnisse erläutert. Danach werden die Resultate präsentiert, gefolgt von einer Diskussion, die sowohl subjektive Meinungen als auch die Limitationen der Studie umfasst. Im Fazit wird die Arbeit mit einem Rückblick auf die initiale Problemstellung und einem Ausblick auf zukünftige Forschungsfragen abgerundet. Damit soll eine Brücke zwischen den gewonnenen Erkenntnissen und deren Relevanz für mögliche zukünftige Arbeiten geschlagen werden.

Der abschließende Erfolg dieser Bachelorarbeit wird anhand der Ermittlung von Divergenzen innerhalb der Korrelation zwischen Kennzahlenwertebereichen und der Genauigkeit der Vorhersage tatsächlicher Aktienkursänderungen, über zwei oder mehrere mittels einer Unternehmenskennzahl separierten Gruppen, gemessen. Um ein möglichst repräsentatives Ergebnis sicherzustellen, werden diverse Tests sowie vergleichende Analysen unter stets identischen Konditionen zwischen den Gruppierungen durchgeführt. Ein beispielhaftes Ergebnis einer solchen Analyse könnte sein, dass eine Erhöhung des Wertes  $x$  mit einer Verringerung der mittleren oder medianen Rendite einhergeht. Diese methodische Vorgehensweise ermöglicht es, tiefergehende Einsichten in die Dynamiken zwischen spezifischen Unternehmenskennzahlen und der Vorhersagepräzision von Aktienkursveränderungen zu gewinnen und trägt somit zur Erweiterung des Verständnisses bei, inwiefern solche Unternehmenskennzahlen zur Prognose von Marktbewegungen herangezogen werden können.

## 2. Theoretische Grundlagen

Im folgenden Kapitel wird das Konzept des Praxisprojektes vorgestellt, um eine solide Wissensbasis für das Verständnis dieser Arbeit zu schaffen. Anschließend werden das Prinzip der Unternehmensbewertung und die Kriterien, nach denen Unternehmen klassifiziert werden können, erläutert.

### 2.1. Einführung in das Konzept des Praxisprojektes

In dem vorliegenden Praxisprojekt kommt das BERT-Sprachmodell zum Einsatz, um auf der Grundlage von Finanznachrichten zukünftige Aktienkursbewegungen vorherzusagen. BERT basiert auf der Transformer-Architektur, welches revolutionär im Bereich der Modelle zur Sprachverarbeitung war [2]. Fortgeschrittenere Konzepte wie Generative Pre-trained Transformer (GPT)<sup>1</sup>, die in den ChatGPT-Versionen verwendet werden, nutzen genau diese Architektur, was ihre hohe Effizienz bei der Sprachverarbeitung und beim Textverstehen unterstreicht. BERT wurde darauf ausgelegt, tiefe bidirektionale Kontexte innerhalb eines Textes zu verstehen, indem es auf einen umfassenden Korpus vortrainiert wurde. Dadurch kann BERT feinere Nuancen der Sprache erfassen, was es im Vergleich zu früheren Modellen fortgeschritten macht. Für spezifische Anwendungen lässt sich BERT auf andere Datensätzen und neuen Themen weiter trainieren, was seine Flexibilität und Effektivität in diversen Einsatzgebieten erhöht [3]. Im Kontext dieser Arbeit wurde BERT speziell darauf angepasst, Nachrichtenartikel zu analysieren, mit einem Fokus auf finanzielle Berichte und Analysen der Aktienmärkte. Das Training auf einem solchen spezialisierten Korpus zielt darauf ab, die Fähigkeit des Modells zu verbessern, relevante Informationen und Trends innerhalb des Finanzsektors automatisiert zu extrahieren. Für diesen Zweck wird das vortrainierte BERT-Modell mittels eines Fine-Tuning-Prozesses an den spezifischen Anwendungskontext angepasst. Hierbei wurden insgesamt 250.000 Nachrichtenartikel genutzt, um das Modell präzise auf die Identifizierung und Prognose von kursrelevanten Informationen zu trainieren.

Traditionell wird für ein solches Vorhaben die Sentiment-Analyse genutzt, die darauf abzielt, die Stimmung innerhalb solcher Texte in Bezug auf Finanzmärkte zu erfassen und diese Stimmung in weiteren Schritten in Signale umzuwandeln. Dazu müssen die

---

<sup>1</sup>OpenAI ChatGPT [Link], Abgerufen am 21.07.2024

Nachrichtenartikel manuell durch Analysten bewertet und kategorisiert werden. Diese Analysten ordnen jedem Artikel einen *Sentiment-Score* zu, der auf einer Skala von -1 (negative Haltung) bis +1 (positive Haltung) für ein Finanzinstrument, in diesem Fall eine Aktie, variiert. Basierend auf dem erstellten Datenset, erfolgt das Trainieren des Modells mit dem Ziel, selbstständig *Sentiment-Scores* für zukünftig eintreffende, dem Modell unbekannte Daten zu prognostizieren. In der idealen Umsetzung erlangt das Modell durch dieses Training die Fähigkeit, eigenständig Evaluierungen hinsichtlich des *Sentiments* neuer Artikel vorzunehmen. In der folgenden Tabelle 2.1 wird die Datenstruktur für eine Sentiment-Analyse dargestellt. Diese umfasst den zu analysierenden Nachrichtenartikel, den zugehörigen Ticker sowie den *Sentiment-Score*.

Ticker	Artikel	Label (Sentiment-Score)
AAPL	Aktienkurs steigt nach Ankündigung...	+0,54
NVDA	Neue GPU-Serie löst gemischte...	-0,45
MSFT	Cloud-Sparte treibt Wachstum voran...	+0,12

Tabelle 2.1.: Datenstruktur bei Sentiment-Score

In Gegensatz zu dieser herkömmlichen Methoden der Sentiment-Analyse, die auf einer manuellen Bewertung der Stimmung in Finanznachrichten basieren, verfolgt das Praxisprojekt einen anderen Ansatz zur Vorhersage von Aktienkursbewegungen. Dabei orientiert sich die Erstellung der Trainingsdaten an einer objektiven Metrik: der prozentualen, relativen Veränderung des Kurses innerhalb eines festgelegten Zeitraums nach der Veröffentlichung einer Nachricht. Konkret werden die Nachrichten mit einem Label versehen, das die reale Kursänderung nach einer festgelegten Zeitspanne an einem zukünftigen Tag widerspiegelt. Die zeitliche Verzögerung, definiert als  $t$ , kann auf drei Tage, eine oder zwei Wochen nach der Veröffentlichung eines Artikels angesetzt werden. Diese Methode ermöglicht die Analyse der Auswirkungen von Informationen aus Artikeln auf kurz-, mittel- und langfristige Kursbewegungen. Für die Umsetzung dieses Ansatzes ist es notwendig, dass die Datenbasis auch historische Nachrichtenartikel sowie Kursbewegungen umfasst, um die erforderlichen Kursveränderungen für die Erstellung der Labels zu haben. In der nachstehenden Tabelle 2.2 wird die Datenstruktur für das Konzept dargestellt. Hierbei ist zu erkennen, dass anstelle des zuvor errechneten *Sentiment-Scores* direkt eine prognostizierte Kursänderung angegeben wird.

Ticker	Artikel	Label (Kursänderung)
AAPL	Aktienkurs steigt nach Ankündigung...	+1,46%
NVDA	Neue GPU-Serie löst gemischte...	-0,14%
MSFT	Cloud-Sparte treibt Wachstum voran...	+0,78%

Tabelle 2.2.: Datenstruktur bei Kursänderung



Die Neuausrichtung des Projekts zur Nutzung von automatisierten Labels, die auf der prozentualen, relativen Kursänderung basieren, bringt Vorteile mit sich. Ein zentraler Vorteil ist die Eliminierung des Risikos eines menschlichen Bias, der bei der manuellen Sentiment-Analyse unvermeidlich ist. Die subjektive Interpretation von Nachrichteninhalten durch Analysten kann zu einer inkonsistenten und verzerrten Datenbasis führen. Die objektiven automatisierten Labels, die direkt an messbaren Marktreaktionen ausgerichtet ist, gewährleistet eine neutrale Grundlage für das Training des Modells. Darüber hinaus adressiert dieser Ansatz effektiv eine der größten Herausforderungen in der Datenverarbeitung: den Zeitaufwand für die Datenannotation. Die traditionelle Methode des manuellen Labelings ist nicht nur anfällig für subjektive Verzerrungen, sondern erfordert auch einen erheblichen Zeitaufwand, der die Effizienz der Datenverarbeitung und Modellentwicklung einschränken kann.

Mit Hilfe der gegebenen API war es möglich, auf alle erforderlichen Daten für die Durchführung dieses Projektes zuzugreifen. Der Prozess der Datenerhebung erforderte die Festlegung spezifischer Parameter, die die Basis für den Datenbezug bildeten, darunter die Auswahl des zu analysierenden Exchange Traded Fund (ETF) und der Untersuchungszeitraum. Nach dem Definieren der Parameter, erfolgte das Laden der Daten, die anschließend in ein geeignetes Format konvertiert wurden, um sie für die nachfolgende Analyse aufzubereiten. Sobald die Daten in einem für die Analyse verwendbaren Format vorlagen, wurden sie zur Feinabstimmung des Sprachmodells genutzt. Dieser Schritt hatte zum Ziel, das Modell gezielt auf die Erkennung und Interpretation finanzspezifischer Semantiken innerhalb der Datensätze zu schulen. Nach Abschluss des Trainings ist das Modell in der Lage, auf einem separaten Testdatensatz angewendet zu werden. Diese Evaluierungsphase diente dazu, die Effektivität des Modells in der Praxis zu validieren, insbesondere seine Fähigkeit, anhand der ihm bisher unbekannt Daten korrekte Vorhersagen zu treffen.

Eine detaillierte Auseinandersetzung mit dem vollständigen Aufbau des Projektes, einschließlich der Erweiterungen, die für die Zwecke dieser Arbeit erforderlich waren, ist im folgenden Kapitel 3 dargelegt. Dort wird ein tiefergehender Einblick in die methodologische Herangehensweise gegeben, die für das Verständnis der durchgeführten Analysen und der erzielten Ergebnisse wesentlich sind.

## 2.2. Bewertung und Klassifizierung von Unternehmen

In der Einleitung dieser Arbeit wurde bereits darauf hingewiesen, dass die Unterteilung der Unternehmen in verschiedene Gruppen nach ausgewählten Kennzahlen vorgenommen wird. Diese Gruppen unterscheiden sich durch ihre Kennzahlenwerte: Unternehmen mit geringen Werten werden in die kleinste Gruppe eingeordnet, während

Unternehmen mit hohen Kennzahlenwerten in die Gruppe mit den höchsten Wertebereichen kommen. Die Kategorisierung von Unternehmen nach ihrer Größe verfolgt das Ziel, ein besseres Verständnis für die unterschiedlichen Reaktionen von Unternehmen auf Finanznachrichten zu entwickeln und somit eine tendenziell bessere Prognosefähigkeit von Kursänderungen auf Basis dieser zu ermöglichen. Es wird angenommen, dass kleinere Unternehmen empfindlicher auf negative Nachrichten reagieren als größere Unternehmen, wie zum Beispiel die *Magnificent Seven*<sup>2</sup>, welche unter anderem Apple, Microsoft und Nvidia umfassen. Letztere sind beziehungsweise könnten aufgrund ihrer Größe und finanziellen Polster in der Lage sein, negative Presse in größerem Umfang zu absorbieren. Die Unterscheidung zwischen den Größen von Unternehmen spielt eine wesentliche Rolle bei der Vorhersage der Auswirkungen von Nachrichtenartikeln. Ein solches Modell mag noch so fortschrittlich sein, wenn es die Unternehmensgröße nicht berücksichtigt, könnte es die Marktbewegungen basierend auf Nachrichten nicht korrekt einschätzen. Die vorliegende Arbeit geht dieser Frage nach, inwieweit die Größe eines Unternehmens dessen Anfälligkeit für die Auswirkungen von Finanznachrichten auf den Aktienkurs beeinflusst, und inwiefern ein Sprachmodell in der Lage ist, dies akkurat zu erkennen. Die systematische Kategorisierung und Analyse anhand definierter Kennzahlen ermöglicht es, differenzierte Aussagen über die Reaktionen unterschiedlich großer Unternehmen auf externe Nachrichten und Ereignisse zu treffen.

Unternehmen können anhand verschiedener Punkte und Kennzahlen klassifiziert werden. In der Fachliteratur und in anderen Quellen finden sich diverse Ansätze zur Differenzierung von Unternehmen. Diese Ansätze reichen von branchenspezifischen Kenngrößen, wie der Anzahl an Betten in einem Hotel oder der Zahl der jährlich beförderten Passagiere, über Beschäftigungszahlen bis hin zu finanziellen Kennzahlen wie dem Gewinn oder dem Eigenkapital eines Unternehmens. Ein Großteil dieser Kennzahlen führt zu einer vergleichbaren Verteilung, da Unternehmen ähnlicher Größe oft ähnliche Werte in diesen Kennzahlen aufweisen. Einen Ansatz für die Unterteilung von Unternehmen liefert das Statistische Bundesamt<sup>3</sup>, gemäß derer Definition sind Unternehmen als klein zu betrachten, wenn diese bis zu 49 Mitarbeiter beschäftigt und einen maximalen Jahresumsatz von 10 Millionen Euro erzielt. Mittelgroße Unternehmen beschäftigen bis zu 249 Mitarbeiter und erreichen einen Jahresumsatz von bis zu 50 Millionen Euro. Unternehmen, die mehr als 249 Mitarbeiter haben und einen Jahresumsatz von über 50 Millionen Euro generieren, werden der Kategorie der großen Unternehmen zugeordnet. Im Folgenden wird detailliert untersucht, aufgrund welcher spezifischen Kennzahlen und Kriterien Unternehmen in dieser Arbeit bewertet und klassifiziert werden können, wobei eine detaillierte Erklärung für die Auswahl dieser Indikatoren geboten wird (siehe Abschnitt 3.1).

---

<sup>2</sup>Magnificent Seven [Link], Abgerufen am 21.07.2024

<sup>3</sup>Statistisches Bundesamt [Link], Abgerufen am 01.06.2024

## 3. Methodik

In diesem Kapitel wird das methodische Vorgehen dieser Arbeit erläutert. Zu Beginn werden die drei verschiedenen Kennzahlen vorgestellt und definiert. Anschließend werden die methodischen Schritte des Projektes erläutert, grafisch dargestellt und zur besseren Nachvollziehbarkeit in einzelne Punkte unterteilt.

### 3.1. Auswahl und Begründung der Kennzahlen

Im Rahmen der Untersuchung des Einflusses verschiedener Determinanten auf die Prognostizierbarkeit von Aktienkursbewegungen wurden spezifische Kennzahlen als Analyseinstrumente ausgewählt: Marktkapitalisierung, Nettogewinnmarge und Dividendenrendite. Diese Entscheidung zur Selektion dieser Variablen, ihre jeweiligen Berechnungsmethoden und dem zugehörigen Nutzen für die vorliegende Analyse werden nachfolgend detailliert diskutiert. Bei der Marktkapitalisierung und der Dividendenrendite werden die Kennzahlenwerte berechnet, indem der Durchschnittswert pro Aktie über den gewählten Zeitraum berechnet wird. Bei der Nettogewinnmarge, die vierteljährlich veröffentlicht wird, wird die Summe über den gewählten Zeitraum gebildet. Für jede Aktie werden diese Kennzahlen berechnet und anschließend, basierend auf den vorab definierten Grenzwerten für niedrige, mittlere oder hohe Werte, pro Kennzahl in drei verschiedene Gruppen unterteilt. Diese Kategorisierung ermöglicht eine präzise Analyse der Korrelation zwischen den Kennzahlenwerten und der Vorhersagegenauigkeit der Aktienkursbewegungen, indem sie eine vergleichende Betrachtung der Performance innerhalb dieser Gruppen sowie eine übergreifende Evaluation zwischen den verschiedenen Kennzahlen unterstützt. Basierend auf den Inhalten des einleitenden Kapitels zur Klassifizierung von Unternehmen wurden die nachfolgenden Grenzen statisch, sowie teilweise basierend auf einer möglichst gleichmäßigen Verteilung, festgelegt. Diese Methodik zur Festlegung der spezifischen Grenzwerte für jede Kategorie wird im weiteren Verlauf der Untersuchung tiefergehend beschrieben.

#### 3.1.1. Definition Marktkapitalisierung

Die Marktkapitalisierung ist das Produkt des aktuellen Aktienkurses und der Gesamtzahl der ausstehenden Aktien, sie repräsentiert den aggregierten Marktwert eines

Unternehmens. Diese Größe dient als Indikator für die Marktwahrnehmung der Unternehmensgröße und Liquidität, welche wesentliche Faktoren für die Marktvolatilität und damit für die Vorhersagbarkeit von Aktienkursbewegungen sind [11][15].

$$\text{Marktkapitalisierung} = \text{Aktienkurs} \times \text{Ausgegebene Aktien}$$

Die Festlegung der Schwellenwerte für die Einteilung der Unternehmen in die Gruppen mit niedriger (Gruppe S), mittlerer (Gruppe M) und hoher (Gruppe L) Marktkapitalisierung erfolgte mit dem Ziel, eine annähernd gleichmäßige Verteilung der Datensätze über die definierten Gruppen zu erreichen. Diese methodische Vorgehensweise soll die Eignung erhöhen, indem Verzerrungen durch ungleiche Gruppengrößen minimiert werden. Als ersten Wert für die Grenze zwischen der Gruppe S und M, wurde auf Basis der gegebenen Daten  $1.82 \times 10^9$  berechnet, sowie  $7.72 \times 10^9$  für die Abgrenzung zwischen der Gruppe M und L. Es ist anzumerken, dass die Selektion dieser Grenzen auf Basis der Marktstruktur des New York Stock Exchange (NYSE) Composite vorgenommen wurde, bei der Anwendung auf andere Aktienindizes, ETFs oder anderweitige Strukturen müsste die Auswahl der Grenzen überdacht und neu berechnet werden.

$$\text{Gruppe S} < 1.82 \times 10^9 < \text{Gruppe M} < 7.72 \times 10^9 < \text{Gruppe L}$$

### 3.1.2. Definition Nettogewinnmarge

Die Nettogewinnmarge ist eine finanzielle Kennzahl, die das Verhältnis des Nettoeinkommens eines Unternehmens zu seinen Gesamteinnahmen (E) angibt. Sie misst, wie viel Prozent des Umsatzes als reiner Gewinn nach Abzug der Warenkosten (WK), aller Betriebskosten mit sonstiger Aufwendungen (B), Zinsen (Z) und Steuern (S) übrig bleiben. Die Nettogewinnmarge ist ein Indikator für die Effizienz und Rentabilität eines Unternehmens, da sie zeigt, wie gut das Unternehmen seine Ressourcen verwaltet, um Gewinn zu erzielen [12][16].

$$\begin{aligned} \text{Nettogewinnmarge} &= \left( \frac{E - WK - B - Z - S}{E} \right) \times 100 \\ &= \left( \frac{\text{Nettoeinkommen}}{\text{Gesamterlöse}} \right) \times 100 \end{aligned}$$

Die Definition der Schwellenwerte für die Klassifizierung der Unternehmen nach ihrer Nettogewinnmarge in die drei verschiedenen Kategorien beruht auf dem Bestreben, eine differenzierte Unterteilung der Unternehmensprofitabilität zu ermöglichen. Diese

Einteilung reflektiert die Variabilität der operativen Effizienz und der finanziellen Gesundheit innerhalb des Untersuchungsgegenstandes. Die Festlegung der Grenzen bei 0% und 10% verfolgt das Bedürfnis eine klare Abgrenzung zwischen Unternehmen zu schaffen, die gerade rentabel sind, jenen, die eine moderate Profitabilität aufweisen, sowie Unternehmen, die sich durch eine außerordentlich hohe Rentabilität auszeichnen. Die Auswahl dieser Grenzwerte wurde auf Basis der vorab beschriebenen Bewertung und Klassifikation von Unternehmen gewählt, sowie nach Referenzwerten und Definitionen aus [18]. Dabei wurde die Distribution der Nettogewinnmargen innerhalb des NYSE Composite und des gesamten Marktes berücksichtigt [14]. Ziel dieser Methode ist es, eine fundierte Basis für Vergleiche der Rentabilitätseffizienz zwischen den Gruppen zu schaffen.

$$\text{Gruppe S} < 0\% < \text{Gruppe M} < 10\% < \text{Gruppe L}$$

### 3.1.3. Definition Dividendenrendite

Die Dividendenrendite ist eine Kennzahl, die das Verhältnis der von einem Unternehmen ausgezahlten Dividenden zum aktuellen Aktienkurs angibt. Sie wird üblicherweise in Prozent ausgedrückt und zeigt, wie viel ein Investor in Form von Dividenden auf seine Investition in die Aktien des Unternehmens relativ zum Aktienpreis erhält. Die Dividendenrendite ist ein wichtiger Indikator für Einkommensinvestoren, die auf der Suche nach Aktien sind, die regelmäßige Erträge liefern [13][17].

$$\text{Dividendenrendite} = \left( \frac{\text{Jährliche Dividende pro Aktie}}{\text{Aktueller Aktienkurs}} \right) \times 100$$

Die Einteilung der Unternehmen nach ihrer Dividendenrendite in die verschiedenen Kategorien dient dazu, eine klarere Differenzierung im Hinblick auf die zu erwartenden Einkommensströme aus ihren Aktieninvestitionen zu bieten. Die Definition der Grenzwerte bei 0% und 2% spiegelt eine strategische Entscheidung wider, die darauf abzielt, jene Unternehmen zu identifizieren, die entweder gar keine, eine moderate oder eine relativ hohe Dividendenrendite aufweisen. Die Festlegung dieser spezifischen Grenzen basiert auf der Analyse historischer Dividendenrenditen, wobei sowohl branchenspezifische als auch marktweite Trends berücksichtigt wurden [14].

$$\text{Gruppe S} < 0\% < \text{Gruppe M} < 2\% < \text{Gruppe L}$$

## 3.2. Methodik des Programms

In der gegebenen graphischen Darstellung 3.1 wird der Ablauf der Methodik schrittweise visualisiert und auf Basis der Nummerierung zu den folgenden Textpassagen verknüpft.

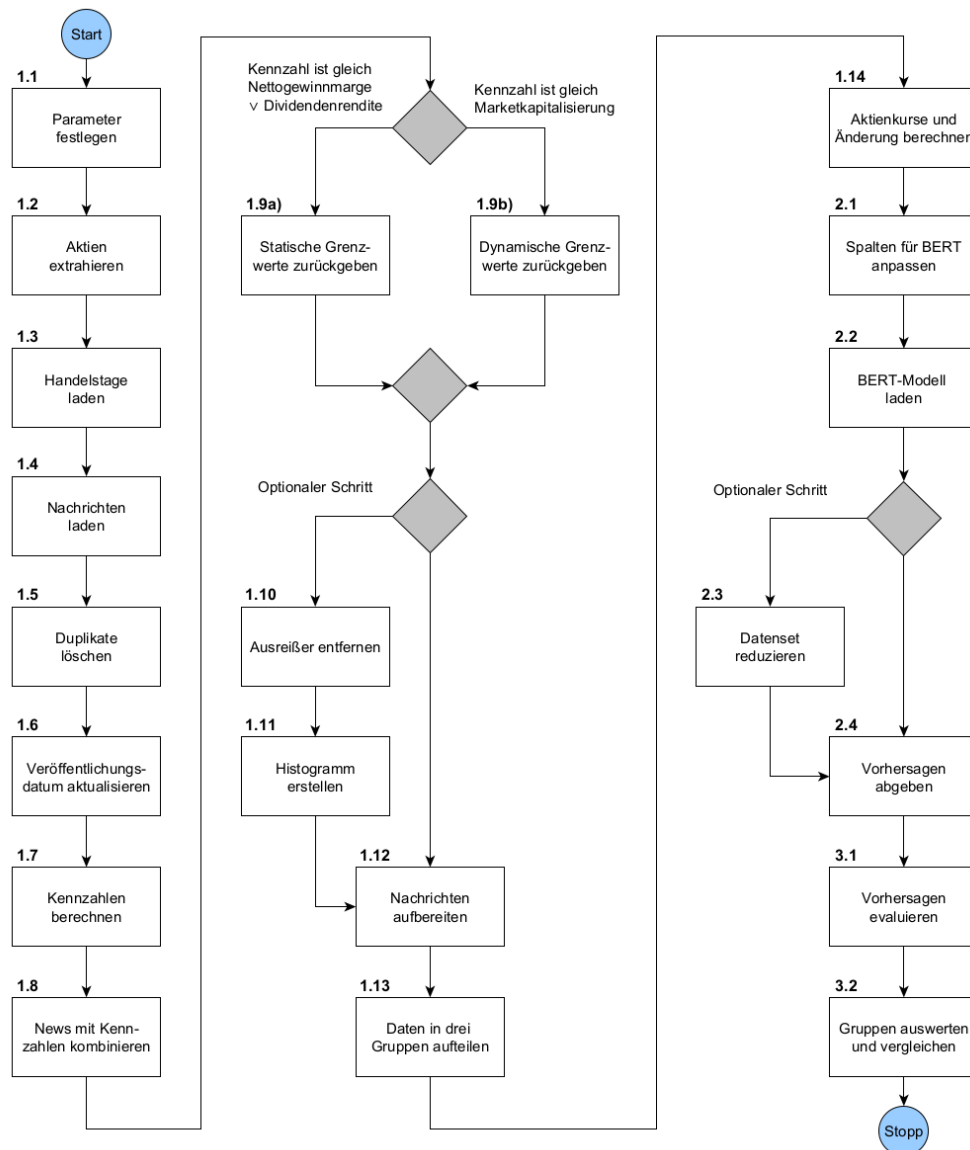


Abbildung 3.1.: Ablauf der Methodik in graphischer Darstellung

**1.1:** Um die Analyse effizient durchzuführen, müssen zunächst spezifische Parameter festgelegt werden. Diese umfassen die Auswahl des zu untersuchenden Index, die Festlegung des Untersuchungszeitraums, die Bestimmung der zu betrachtenden Börse, die Auswahl der zu analysierenden Kennzahl sowie das definierte Zeitintervall zwischen der Veröffentlichung einer Nachricht und dem Tag an dem die Kursänderung prognostiziert werden soll. Diese Festlegung der Parameter ist unumgänglich, da das Verfahren auf diesen Kriterien basiert und diese benötigt.

### 3.2.1. Datenakquisition und -berechnung

**1.2:** Anschließend werden basierend auf dem zuvor festgelegten Index die zugehörigen Aktien identifiziert und für die weitere Analyse extrahiert.

**1.3:** Auf Grundlage der definierten Börse und des festgelegten Untersuchungszeitraums, der durch das Start- und Enddatum bestimmt wird, erfolgt die Ermittlung aller validen Handelstage. Diese Bestimmung ist notwendig, da im weiteren Verlauf mehrfach auf diese Handelstage zugegriffen werden muss.

**1.4:** Für jede Aktie, die entweder aus dem gewählten Index oder dem entsprechenden ETF stammt, werden sämtliche über die verwendete API zugänglichen Nachrichten innerhalb des vorgegebenen Zeitraums gesammelt. Diese Sammlung von Nachrichten bildet die Grundlage für die nachfolgende Auswertung der Daten hinsichtlich ihres Einflusses auf die Aktienkurse.

**1.5:** Da das verwendete Sprachmodell vortrainiert auf den Aktien des Konsumgüter- (XLP) und Technologiesektor- (XLK) ETFs ist, besteht eine potenzielle Überschneidung von Nachrichtenartikeln zwischen der Trainings- und der Testphase. Diese Überschneidung könnte auftreten, weil die zu untersuchenden Aktien in der folgenden Testphase aus dem NYSE Composite stammen, wobei es sowohl Aktien in diesem Index als auch in den für das Training genutzten ETFs gibt. Um solche Überschneidungen zu vermeiden und die Validität der Arbeit zu gewährleisten, wird eine erneute Überprüfung durchgeführt. Datensätze, die in beiden Datensätzen vorkommen, werden eliminiert, um eine strikte Trennung zwischen Test- und Trainingsdaten zu garantieren.

**1.6:** Mithilfe der zuvor festgelegten gültigen Handelstage werden die Veröffentlichungsdaten der Nachrichten so angepasst, dass sie immer auf Tage fallen, an denen die Börse geöffnet ist. Wenn beispielsweise eine Nachricht an einem Sonntag veröffentlicht wurde, wird das Datum auf den letzten Handelstag vor der Veröffentlichung korrigiert. Diese Entscheidung beruht auf der Absicht, später die realen Kursänderungen zwischen dem Veröffentlichungsdatum und dem Vorhersagedatum zu berechnen. Durch die Wahl des

vorhergehenden Handelstags wird das Risiko vermieden, dass etwaige Marktbewegungen infolge der Veröffentlichung bereits in die Analyse einfließen könnten, was bei der Wahl des ersten Handelstags nach der Veröffentlichung der Fall sein könnte.

**1.7:** Im Folgenden wird auf Grundlage der festgelegten Kennzahlen der entsprechende Wert für jede Aktie berechnet. Dies umfasst die Ermittlung des Durchschnitts der Marktkapitalisierung je Aktie über den festgelegten Zeitraum, hier von Anfang 2021 bis Ende 2022. Ein ähnliches Vorgehen wird bei der Berechnung der Dividendenrendite angewendet. Es ist jedoch zu beachten, dass einige Unternehmen keine Dividende ausschütten. In solchen Fällen gibt die API-Anfrage keinen Wert zurück. Damit diese Unternehmen dennoch in der nachfolgenden Analyse berücksichtigt werden und nicht aufgrund ihrer fehlenden Werte ignoriert werden, wird für sie ein Wert von  $-0,05\%$  festgelegt, um eine korrekte Gruppeneinteilung zu ermöglichen. Bei der Nettogewinnmarge werden die quartalsweise ausgegebenen Werte über den vorgegebenen Zeitraum summiert. Da die genutzte API die Nettogewinnmarge nicht direkt zur Verfügung stellt, wird diese berechnet, indem das summierte Nettoeinkommen durch den summierten Umsatz über den Zeitraum geteilt wird. Für das Beispiel bedeutet dies, dass Werte von acht Quartalen addiert werden, da der Untersuchungszeitraum zwei Jahre umfasst.

**1.8:** Die gesammelten Nachrichten werden mit den zuvor berechneten Kennzahlen kombiniert, indem sie über die auf beiden Seiten vorhandene Tickerspalte verknüpft werden. Auf diese Weise ist sichergestellt, dass jeder Nachrichtendatensatz nun auch mit den entsprechenden Kennzahlen der zugehörigen Aktie versehen ist.

**1.9:** Im weiteren Verlauf werden die festgelegten Kennzahlen unterschiedlich behandelt. Bei der Dividendenrendite und der Nettogewinnmarge werden statische Werte als Grenzen festgelegt, die später zur Gruppeneinteilung verwendet werden. Im Gegensatz dazu werden die Grenzen bei der Marktkapitalisierung dynamisch gesetzt, um eine gleichmäßige Verteilung der Aktien über die Gruppen hinweg zu gewährleisten.

**1.10:** Zur Verbesserung der Darstellungsqualität eines Histogramms kann optional ein prozentualer Anteil der oberen oder unteren Ausreißer entfernt werden. Diese Anpassung zielt darauf ab, ein klareres Bild der Datenverteilung zu erhalten und deren Interpretierbarkeit zu erleichtern.

**1.11:** Die anschließende Erstellung des Histogramms gibt einen groben visuellen Überblick über die Verteilung der Daten und der festgelegten beziehungsweise berechneten Grenzwerte. Diese visuelle Darstellung kann zu einem besseren Verständnis der Datenstruktur beitragen.

**1.12:** Im weiteren Verlauf wird der Text der Nachrichtenartikel normalisiert und aufbereitet, um die weitere Nutzung mit dem BERT-Modell zu erleichtern. Dazu gehört die Entfernung bestimmter Symbole, sogenannter Stoppwörter (wie beispielsweise 'und', 'oder'), und die Eliminierung von Duplikaten in den Nachrichtenartikeln. Letzteres ist



notwendig, da die gleiche Meldung auf verschiedenen Portalen veröffentlicht worden sein kann. Diese Maßnahmen zur Normalisierung zielen darauf ab, die Datenmenge zu reduzieren und somit die Leistungsfähigkeit des Modells potenziell zu steigern.

**1.13:** Schließlich werden die zuvor berechneten Grenzwerte genutzt, um die Daten in drei verschiedene Kategorien zu unterteilen: In solche mit niedrigen, mittleren und hohen Kennzahlenwerten. Diese Kategorisierung ist für die folgenden Schritte von wesentlicher Bedeutung.

**1.14:** Anschließend wird die Kursänderung je Aktie zwischen dem Veröffentlichungsdatum  $x$  und dem Ziel-Datum  $x + t$ , wobei  $t$  die festzulegende Differenz zwischen Veröffentlichung und Vorhersage beschreibt, berechnet. Hierzu wird der Kurswert am Ziel-Datum  $x + t$  herangezogen und von diesem der Kurswert am Veröffentlichungsdatum  $x$  subtrahiert. Das Ergebnis dieser Differenz wird anschließend durch den Kurs am Tag  $x$  dividiert. Nach der Rechnung ist noch zur Ermittlung der Prozentangabe eine Multiplikation mit 100 erforderlich. Diese Berechnung liefert die relative rohe, aber noch nicht normalisierte, Kursänderung. Um jedoch eine differenzierte Aussage über die Kursentwicklung in Abhängigkeit von der spezifischen Gruppenzugehörigkeit einer Aktie und der dazu veröffentlichten Nachricht zu ermöglichen, wird ein weiterer Schritt in der Analyse vollzogen. Die ermittelte Kursänderung der einzelnen Aktie wird um die durchschnittliche Kursänderung innerhalb der jeweiligen Gruppe adjustiert. Das bedeutet, dass von der rohen Kursänderung jeder Aktie die mittlere Kursänderung der Gruppe, der diese Aktie zugeordnet ist, subtrahiert wird. Diese Adjustierung berücksichtigt sich ausschließlich den Mittelwert der Gruppe, nicht den der gesamte Daten. Durch dieses Vorgehen wird eine normalisierte Kursänderung berechnet, die eine präzisere Einschätzung der Auswirkung spezifischer Nachrichten auf die Kursentwicklung unter Berücksichtigung der Gruppenzugehörigkeit ermöglicht.

### 3.2.2. Nutzung des Sprachmodells

**2.1:** Im ersten Vorbereitungsschritt zur Nutzung von BERT werden notwendige Anpassungen an den Spaltennamen der Datensätze vorgenommen. Diese Anpassungen sind erforderlich, um die Kompatibilität mit den Eingabeanforderungen des Sprachmodells sicherzustellen und eine reibungslose Datenverarbeitung zu gewährleisten.

**2.2:** Im Anschluss erfolgt, abhängig von den festgelegten Parametern, das Laden des vortrainierten BERT-Modells, welches die Grundlage für die weitere Analyse bildet.

**2.3:** Die Laufzeit des Sprachmodells kann optional durch Reduzierung der zu verarbeitenden Datenmenge verkürzt werden. Dabei ist auf eine gleichmäßige Verteilung der Anzahl der Nachrichten pro Ticker zu achten, um Verzerrungen der Vorhersageergebnisse zu vermeiden.

**2.4:** Nach der Datenverarbeitung mit dem geladenen BERT-Modell erfolgt die Ableitung von Handelssignalen auf Basis der getätigten Kursvorhersagen des Modells auf die Testdaten. Die generierten Signale: Kaufen, Verkaufen und Halten, basieren auf den vorhergesagten Werten und einem vorab in den Parametern festzulegenden Schwellenwert, der die Grenze zwischen den einzelnen Signalen definiert. Diese Phase ermöglicht die direkte Anwendung der aus den Nachrichtentexten gewonnenen Erkenntnisse auf Entscheidungen im Kontext des Aktienhandels, wobei jeweils eine adäquate Handlungsanweisung abgeleitet wird.

### 3.2.3. Auswertung und Evaluation

**3.1:** Um die Leistungsfähigkeit des Modells in Bezug auf die Genauigkeit seiner Vorhersagen zu bewerten, erfolgt eine Gegenüberstellung der vom Modell prognostizierten Kursänderungen mit den tatsächlich eingetretenen Kursentwicklungen. Diese Analyse umfasst die Berechnung des durchschnittlichen Fehlers sowie eine Bewertung der Angemessenheit der durch das Modell vergebenen Handelssignale. Weiterführend wird untersucht, inwiefern die vergebenen Kaufsignale zu einer möglichen Rendite geführt haben. Zu diesem Zweck werden die realen Kursänderungen für sämtliche Nachrichten je Signalkategorie kalkuliert und im Anschluss der Mittelwert sowie der Median ermittelt. Idealerweise sollten diese Werte positiv ausfallen. Bei der Analyse der Verkaufssignale erfolgt eine ähnliche Vorgehensweise, wobei der errechnete Mittel- und Medianwert den verhinderten Verlust darstellt und folglich negativ sein sollte. Diese Evaluierung trägt dazu bei, sowohl die Vorhersagegenauigkeit als auch die praktische Anwendbarkeit des Modells in Bezug auf Handelsentscheidungen zu ermitteln.

**3.2:** Abschließend werden die Ergebnisse der verschiedenen Gruppen innerhalb derselben Kennzahlenkategorie miteinander verglichen, wie beispielsweise die Gruppen S, M und L bei der Marktkapitalisierung. Darüber hinaus wird ein Vergleich zwischen den Gruppen unterschiedlicher Kennzahlen durchgeführt, beispielsweise zwischen der Gruppe S der Marktkapitalisierung und der Gruppe S der Nettogewinnmarge. Ziel dieses Schrittes ist es, mögliche Abhängigkeiten oder Muster zu erkennen, die darauf hindeuten könnten, dass bestimmte Wertegruppen, wie etwa niedrigere oder höhere Marktkapitalisierungen beziehungsweise Nettogewinnmargen, mit der Prognosegenauigkeit oder der Treffsicherheit der abgeleiteten Handelssignale zusammenhängen. Durch diesen Vergleich können tiefere Einblicke in die Daten gewonnen und mögliche Optimierungsansätze für die Modellanwendung und Strategieentwicklung im Aktienhandel abgeleitet werden.

## 4. Implementierung der Methodik

Im Zuge der Implementierungsphase dieses Projektes wurden diverse Funktionen entwickelt und diese werden nachfolgend präsentiert. Der Schwerpunkt liegt auf einer schriftlichen Erläuterung der meisten Funktionen, während für besonders komplexe Funktionen zusätzlich Pseudocode zur Veranschaulichung herangezogen wird. Um die Nachvollziehbarkeit zu gewährleisten, erfolgt eine systematische Nummerierung der Funktionen, welche eine direkte Verbindung zu den zuvor definierten methodologischen Schritten ermöglicht. Um die Lesbarkeit zu optimieren und den Formatierungsrichtlinien gerecht zu werden, waren partielle Anpassungen notwendig. Diese beinhalteten unter anderem die Kürzung von Variablen- und Parameternamen sowie die gezielte Streichung weniger relevanter Zeilen im Pseudocode. Ferner wurde die Reihenfolge einiger Funktionen adjustiert, um einen natürlicheren Lesefluss zu unterstützen und eine rein programmlogische Abfolge zu vermeiden. Der vollständige Quellcode ist im dazugehörigen GitHub-Repository<sup>1</sup> einsehbar, die entsprechenden Funktionen sind über Titel oberhalb der jeweiligen Codeblöcke auffindbar. Dabei werden die folgenden Funktions-, Parameter-, Datei- sowie Ordnernamen und weitere Fachbegriffe *kursiv* gesetzt, um das Verständnis und die Erkennbarkeit zu verbessern. Die nachstehenden Funktionen sind sowohl im Rahmen des Praxisprojektes implementiert, als auch teilweise komplett neu für die Bachelorarbeit entworfen und teils angepasst, worden.

Die strukturelle Organisation des Projektes, welche im folgenden Listing 4.1 dargestellt wird, wurde mit dem Ziel konzipiert, eine klare, leicht verständliche und auch für Dritte intuitive Anordnung zu gewährleisten. Im Ordner *venv* wird eine virtuelle Umgebung eingerichtet. Diese ermöglicht es, alle für das Projekt benötigten Pakete isoliert zu verwalten und eine separate Python-Version zu verwenden. Dadurch kann unabhängig von globalen Installationen gearbeitet und Interferenzen mit diesen vermieden werden. Der API-Schlüssel ist in der *credential.py*-Datei im *assets*-Ordner zu finden, welche aus Sicherheits- und Best-Practice-Gründen im GitHub-Repository nicht öffentlich zugänglich gemacht wurde. In dem *docs*-Verzeichnis sind die Dokumentations-Markdown-Dateien zu finden, die sich mit der Erklärung der Methodologie, sowie der Einführung in das vorausgehende Praxisprojektes beschäftigen. Die *models*-Sektion speichert die feinjustierten Sprachmodelle, wobei für jedes Zieldatum, das durch die Differenz zwischen Veröffentlichungstag und Vorhersagetag definiert ist, ein eigenes Sprachmodell trainiert wurde. Im *results*-Ordner werden währenddessen die

---

<sup>1</sup>Praxisprojekt GitHub Repository [Link], Abgerufen am 01.06.2024

fertiggestellten Jupyter Notebooks als Hypertext Markup Language (HTML)-Dateien gespeichert, die durch die Ausführung des *executor.py*-Skripts generiert wurden. Das *source*-Verzeichnis umfasst genutzte Enumerations und einen Paket-Installer, der für die Installation der in *requirements.txt* aufgelisteten Pakete zuständig ist, was die sofortige Nutzung des Programms für externe Anwender erleichtert. Der *executor.py* ist dabei nicht nur für die Ausführung und Umwandlungen von Jupyter Notebooks in HTML-Dateien gedacht, sondern auch für die Parametereinstellungen, sowie die Ausführung des vorher erwähnten Paket-Installers verantwortlich, so kann das Projekt ohne direkte Interaktion mit dem Code aufgesetzt und ausgeführt werden.

```

1 Stock-News-Analysis-with-BERT/
2 |-- .venv/
3 |   |-- [...]
4 |-- assets/
5 |   |-- credential.py
6 |-- docs/
7 |   |-- methodology.md
8 |   |-- README.md
9 |   |-- setup.md
10 |-- models/
11 |   |-- DBERT_2W_V1
12 |   |-- DBERT_1W_V1
13 |   |-- DBERT_3D_V1
14 |-- results/
15 |   |-- notebook_2W.html
16 |   |-- notebook_1W.html
17 |   |-- notebook_3D.html
18 |-- source/
19 |   |-- enums.py
20 |   |-- execution.py
21 |   |-- packages.py
22 |-- executor.py
23 |-- requirements.txt
24 |-- nb_bachelorthesis.ipynb
25 |-- nb_practicalproject.ipynb

```

Listing 4.1: Projektstruktur des GitHub-Repositories

Das Kernstück dieser Arbeit stellt das *nb\_bachelorthesis.ipynb*-Notebook dar, welches alle Anpassungen am bestehenden Code sowie neue Funktionalitäten im Vergleich zum vorherigen Praxisprojekt beinhaltet. Es bündelt alle Neuerungen und greift auf Funktionen aus *nb\_practicalproject.ipynb* zurück. In der folgenden Implementierung wird für jede Funktion angegeben, in welchem Notebook sie zu finden ist. Zur Kennzeichnung werden die Abkürzungen *nb\_pp* für *nb\_practicalproject.ipynb* und *nb\_bt* für *nb\_bachelorthesis.ipynb* verwendet, die neben dem Namen der Funktion stehen.

## 4.1. Grundlegende Funktionen

Zum besseren Verständnis und zur Vermeidung von Wiederholungen werden im Folgenden die wichtigsten Funktionen im Detail erläutert und definiert:

**leeway<sup>nb\_pp</sup>**: Diese Funktion dient als dynamische Schnittstelle, um Anfragen an die API einfach und schnell zu stellen. Bei jedem Zugriff auf die API wird die Funktion *leeway* verwendet, um durch einfache Angabe von Parametern den Zugriff auf alle für das Projekt relevanten Funktionen zu ermöglichen. Ein Mapping-Mechanismus lädt die entsprechende API-Sub-URL, die mit den übergebenen Parametern gefüllt wird. Hierbei ist darauf zu achten, dass die korrekten und auch alle geforderten Parameter für die jeweilige Funktion angegeben werden. Die Sub-URL wird mit der Basis-URL kombiniert und mittels HTTP-Requests eine Anfrage an die zusammengesetzte URL gesendet. Die Option besteht, eine Session zu spezifizieren, die eine persistente Verbindung etabliert, ein Vorteil hinsichtlich der Effizienz bei mehreren sequentiellen Anfragen. Werden Daten gefunden, erfolgt die Rückgabe als JavaScript Object Notation (JSON)-Objekt, andernfalls wird *None* zurückgegeben.

**split\_data\_to\_db/save\_to\_db<sup>nb\_pp</sup>**: Zur Reduzierung der Ausführungszeiten und zum Speichern bereits verarbeiteter Daten wurde eine Mongo-Datenbank (DB) eingesetzt. Es wurde darauf geachtet, Daten in verhältnismäßig kleinen Batches zu speichern, da MongoDB mit kleineren Dateneinheiten am effizientesten arbeitet<sup>2</sup>. Hierzu wurden zwei Funktionen entwickelt: *save\_to\_db* ermöglicht das direkte Speichern von Daten in der Datenbank, während *split\_data\_to\_db* Datenmengen nach vorgegebener Größe in kleinere Batches aufteilt und diese speichert. Bei einer beispielhaften Teilung eines Datensatzes von 6000 Einträgen in Batches von jeweils 2000 Zeilen entstehen dementsprechend drei Batches. Die Anzahl der Batches wird unter dem als Parameter angegebenen Namen (ohne Suffix) gespeichert, während die einzelnen Batches unter *name\_x* abgelegt werden, wobei *x* die jeweilige Batch-Nummer repräsentiert. Werden Daten ohne vorherige Aufteilung gespeichert, erfolgt die Speicherung direkt unter dem Parameter *name*.

**combine\_data\_from\_db/load\_from\_db<sup>nb\_pp</sup>**: Beim Laden von Daten aus der Datenbank können, sofern keine Aufteilung in Batches erfolgt ist, diese direkt unter Angabe des Parameters *name*, mit Hilfe der *load\_from\_db*-Funktion, abgerufen werden. Für in Batches aufgeteilte Datenstrukturen ist eine Rekonstruktion der Datensätze erforderlich. Dabei wird zunächst die Anzahl der Batches anhand des angegebenen Namens ermittelt. Danach werden mittels einer Schleife alle Batches unter Verwendung des Batch-Identifiers *x* abgerufen, kombiniert und als zusammengesetztes Datenset zurückgegeben, umgesetzt wird dies durch die *combine\_data\_from\_db*-Funktion.

---

<sup>2</sup>MongoDB: Bloated Documents [Link], Abgerufen am 01.07.2024

**format\_date**<sup>nb-pp</sup>: Die Funktion `format_date` standardisiert Datumsangaben auf ein einheitliches Format, in dem Fall auf das International Standards Organization (ISO) 8601 Format (`YYYY-MM-DD`)<sup>3</sup>, um die Konsistenz der Daten zu gewährleisten und mögliche Formatkonflikte zu vermeiden. Dies ist insbesondere relevant, da unterschiedliche Datenquellen teilweise verschiedene Datumsformate verwenden. Die Konvertierung erleichtert die Datenverarbeitung und -analyse, indem sie eine einheitliche Datumsdarstellung über verschiedene Quellen hinweg sicherstellt. Die zu konvertierenden Werte, welche in den DataFrames als Zeichenketten vorliegen, werden zunächst in eine Liste umgewandelt, um Flexibilität im Umgang mit den Funktionsargumenten zu ermöglichen. Anschließend erfolgt die Homogenisierung aller relevanten Spalten auf das Format `YYYY-MM-DD`.

## 4.2. Datenakquisition und -berechnung

In dieser Kategorie werden die Funktionen aufgelistet, die sich mit der Beschaffung, Aufbereitung und Berechnung der relevanten Daten sowie den daraus resultierenden Kennzahlen befassen.

**(1.1)**<sup>nb-bt</sup>: Die Ausführung des Codes erfordert die Angabe spezifischer Parameter. Diese legen die Kriterien für das Laden von Daten sowie die Durchführung von Berechnungen durch das Programm fest. Zu den festzulegenden Parametern gehören der zu analysierende Aktienindex, der betrachtete Zeitraum (definiert durch Start- und Enddatum), der Marktkalender zur Identifizierung relevanter Feiertage, die auszuwertende Kennzahl sowie das Zieldatum, auf dessen Differenz die Vorhersagen basieren. Des Weiteren wird hier der Schwellenwert für die Identifizierung von Ausreißern festgelegt, um eine effektive und visuell ansprechendere Histogramm-Darstellung zu ermöglichen. Im Kontext des BERT-Sprachmodells werden weitere Parameter benötigt, deren Einführung im folgenden Unterkapitel 4.3 erfolgt. Diese dienen unter anderem zum Training oder Laden des Modells, aber auch zur Simulation und Evaluierung der Vorhersagen. Die Einführung der Parameter erfolgt bewusst zu einem späteren Zeitpunkt, da sie sowohl strukturell sinnvoller als auch im zukünftigen Kontext angemessener sind.

**extract\_from\_index (1.2)**<sup>nb-bt</sup>: Für die nachfolgende Verarbeitung ist es essentiell, die Aktien des spezifizierten Indexes zu ermitteln. Hierfür wird eine Anfrage mittels der API über die `leeway`-Funktion gestellt, um Zugang zu den Fundamentaldaten der betrachtenden Aktie zu erhalten. Durch die konsistente Antwortstruktur der API, kann über statische definierte Indize-Zugriffe auf die JSON-Antwort dieser, die nötigen Daten geladen und in einem DataFrame abgespeichert werden. Der abzuspeichernde

---

<sup>3</sup>ISO 8601: Date and time format [Link], Abgerufen am 14.06.2024

Name je Aktie, setzt sich aus dem Aktiencode (*Ticker*), sowie dem betrachtenden Börsensymbol zusammen, in diesem Fall *US*. Dies vereinfacht zukünftige Arbeitsschritte, da die Leeway-API bei Anfragen konsequent den Aktiencode in Kombination mit dem Börsensymbol erfordert. Nicht benötigte Spalten werden anschließend entfernt.

**get\_trading\_days (1.3)<sup>nb\_pp</sup>**: Anhand des initial definierten Marktcalenders und Zeitraums werden alle validen Handelstage ermittelt und in der Datenbank gespeichert, um wiederholte Berechnungsanfragen zu vermeiden und die Ausführungszeit zu minimieren. Dies erfolgt unter Verwendung des Pandas-Market-Calendar Packages<sup>4</sup>, das alle Feiertage für eine Vielzahl von Börsen bereitstellt. Mit Hilfe dieses Pakets und des definierten Zeitraums werden die Handelstage ermittelt, wobei ausschließlich Tage, die als *market\_open*, in der JSON-Antwort von dem Package, gekennzeichnet sind, berücksichtigt werden. Anschließend werden diese ins korrekte ISO-Datumsformat konvertiert, in der Datenbank gespeichert und bereitgestellt.

**get\_content (1.4)<sup>nb\_pp</sup>**: Das nachfolgende Listing 4.2 illustriert, in Form von einer vereinfachten Pseudocode-Darstellung, den Prozess des Ladens von Nachrichten für die bestimmten Aktien innerhalb des spezifizierten Zeitrahmens. Durch den Einsatz von Multithreading (vgl. Zeilen 3 - 5) wird eine hohe Anzahl von API-Anfragen pro Sekunde, je Ticker ermöglicht. Dies ist notwendig, da bei fast 600.000 resultierenden Datensätzen, dieser Prozess ohne parallele Ausführung, zu langen und hinderlichen Ausführungszeiten führen würde. Die Hilfsfunktion *retrieve\_and\_combine\_news* abstrahiert einen Teil der Ausführungslogik, einschließlich der zeilenweisen Verarbeitung und der Ergänzung des Tickers als Spalte zum DataFrame. Ein bedeutender Aspekt dieser Funktion ist die Bewältigung des Antwortlimits der API, wobei maximal 1000 Datensätze pro Anfrage zurückgegeben werden können. Wird dieses Limit überschritten, was bei einem Zeitraum von zwei Jahren häufig der Fall ist, löst die Funktion *get\_news\_per\_row* das Problem, indem sie Schleifendurchläufe ausführt, die kontinuierlich weitere Anfragen an die API stellen. Der Zeitraum, über welchen die API-Anfrage die Nachrichten bezieht, wird für jeden Schleifendurchlauf immer weiter angepasst, bis final der ganze Zeitraum abgedeckt wurde. Diese Schleife endet dann, wenn das Startdatum des gesamten Untersuchungszeitraums dem Startdatum der letzten API-Anfrage entspricht (vgl. Zeile 25), dies gewährleistet die Vollständigkeit der Daten. Es wird außerdem der Sonderfall abgedeckt, dass das Szenario eintreten kann, dass sich das *first\_date* in einem folgenden Schleifendurchlauf nicht ändert. Dies kann auf Basis von nicht vollständigen Daten entstehen kann. In diesem Szenario wird, bei gleichbleibendem Datum in einer aufeinander folgendem Schleifendurchlauf, die Schleife verlassen (vgl. Zeile 36). Würde dieser Fall nicht angegangen werden, so würde die Ausführung in einer Endlosschleife resultieren.

---

<sup>4</sup>Pandas-Market-Calendar 4.4.0 [Link], Abgerufen am 04.06.2024

```

1 funktion get_content(aktien_df, start_date, end_date):
2     Fuer jede zeile in aktien_df:
3         nachrichten_df := Parallel ausfuehren von
4             retrieve_and_combine_news
5             mit (zeile, start_date, end_date)
6
7     Gebe nachrichten_df zurueck
8
9 funktion retrieve_and_combine_news(zeile, start_date, end_date):
10    news_df := Ausfuehren von get_news_per_row
11           mit (ticker, start_date, end_date)
12
13    Fuege die ticker, etf von zeile als Spalten zu news_df hinzu
14    Gebe news_df zurueck
15
16 funktion get_news_per_row(ticker, start_date, end_date):
17    Falls Daten noch nicht auf der Datenbank gespeichert sind
18        news_df := Stelle Anfrage an die API
19                mit (ticker, start_date, end_date)
20
21    Falls das news_df nicht leer ist
22        first_date := Lade Datensatz mit
23                   aeltesten Datum aus news_df
24
25    Solange wie first_date != start_date ist
26        news_df_2 := Stelle Anfrage an die API mit
27                  (ticker, start_date, end_date)
28
29    Falls news_df_2 nicht leer ist
30        first_date_2 := Lade Datensatz mit
31                      aeltesten Datum aus
32                      news_df_2
33
34    news_df := Kombiniere news_df und news_df_2
35
36    Falls first_date == first_date_2
37        Verlasse die Schleife
38
39    first_date := first_date_2
40
41    Loesche Duplikate fuer Spalte [ticker] aus news_df
42    Speichere news_df auf der Datenbank
43    Gebe das news_df zurueck
44
45    Andernfalls:
46        news_df := Lade Daten von der Datenbank
47        Gebe news_df zurueck

```

Listing 4.2: Pseudocode für das Laden der Nachrichtenartikel



**drop\_duplicates (1.5)<sup>nb\_bt</sup>**: Um Überschneidungen zwischen den Trainings- und Testdatensätzen zu verhindern, erfolgt die Entfernung von Datensätzen mit identischen Daten in Bezug auf den Inhalt und den Ticker. In diesem Prozess werden die Indizes beider betreffender DataFrames auf diese beiden Spalten gesetzt. Das zur Testung vorgesehene DataFrame wird anschließend gefiltert, indem Einträge entfernt werden, deren Indizes bereits im für Training und Validierung genutzten DataFrame enthalten sind. Anschließend wird der Index wieder zurückgesetzt, um ein DataFrame mit einem standardmäßigen, null-basierten numerischen Index zu gewährleisten.

**update\_dates (1.6)<sup>nb\_pp</sup>**: Zur Anpassung der Veröffentlichungsdaten der Nachrichten werden die folgend definierten Funktionen eingesetzt. Die *update\_dates* Funktion wendet die *find\_nearest\_date* Methode auf alle definierten Datumsspalten innerhalb des übergebenen DataFrames an. Fällt bei der Abarbeitung dieser Funktion das betrachtete Datum auf einen gültigen Handelstag, so wird dieses Datum beibehalten und die Funktion nicht ausgeführt, wodurch Ressourcen gespart werden. Andernfalls wird für jede relevante Zeile die *find\_nearest\_date\_before* Methode angewendet. Die Methode nimmt eine Liste aller gültigen Handelstage innerhalb des betrachteten Zeitraums entgegen, die zuvor mit der *get\_trading\_days*-Funktionen bezogen wurden. In der Funktion wird diese Liste so gefiltert, dass nur noch die Daten enthalten sind die vor dem betrachteten Datum liegen. Mit Hilfe der *.max*-Funktion wird dann das nächste Datum zu diesem geladen und, falls vorhanden, zurückgegeben. Falls kein früheres gültiges Datum vorhanden ist, werden alle nachfolgenden Handelstage betrachtet und mithilfe der *.min*-Funktion das nächstliegende zukünftige Datum ausgewählt. Dieses Vorgehen ist effizienter als eine iterative Suche und spart somit Zeit.

**calculate\_keyfigure (1.7)<sup>nb\_bt</sup>**: Für die im Index identifizierten Aktien wird die zuvor definierte Kennzahl mithilfe der in den Listings 4.3, 4.4 und 4.5 per Pseudocode beschriebenen Funktionen berechnet. Zunächst wird überprüft, ob die benötigten Daten bereits in der Datenbank vorhanden sind. Sollte dies nicht der Fall sein, initiiert die Hilfsfunktion *get\_keyfigures\_for\_df* über Multithreading die Funktion *get\_keyfigures\_for\_stock* die für jeden Ticker im DataFrame, die definierte Kennzahl berechnet. Je nachdem, welche Kennzahl ausgewählt wurde, werden jeweils unterschiedliche Mappings (vgl. Zeilen 21 - 25) geladen, die die passenden Attribute, so wie die zur Berechnung verwendete Funktion, umfassen. Eine detaillierte Erläuterung zu den Kennzahlen spezifischen Funktionen folgt in nachfolgenden Abschnitten mit den Listings 4.4 und 4.5. Nach der Berechnung erfolgt mittels der Funktion *finalize\_data* die Bereinigung von Not a Number (NaN)-Werten und das Entfernen von irrelevanten Spalten. Zudem wird für Dividendenrendite und Marktkapitalisierung der Durchschnittswert je Aktie berechnet. Für die Nettogewinnmarge wird eine Filterung von Werten über 1 beziehungsweise unter -1 vorgenommen, da solche Werte nur auf Basis von fehlerhaften Daten entstehen konnte und deshalb entfernt werden.

```

1 funktion calculate_keyfigure(df, keyfigure, start_date, end_date):
2   keyfigure_dict := Lade Daten von der Datenbank
3   Falls keyfigure_dict leer ist:
4     keyfigure_dict := Ausfuehren von get_keyfigures_for_df
5                       mit (df, keyfigure, start_date, end_date)
6     Speichere keyfigure_dict auf die Datenbank
7
8   keyfigure_df := Konvertiere keyfigure_dict in ein DataFrame
9   Gebe keyfigure_df zurueck
10
11 funktion get_keyfigures_for_df(df, kf, start_date, end_date):
12   tickers := Alle Ticker aus df
13   Fuer jeden ticker in tickers:
14     results_df := Parallel ausfuehren von get_keyfigures_for_stock
15                 mit (ticker, kf, start_datum, end_datum)
16
17   finalized_df := Ausfuehren von finalize_data mit (results_df, kf)
18   Gebe finalized_df zurueck
19
20 funktion get_keyfigures_for_stock(ticker, kf, start_d, end_d):
21   kf_details = {
22     "marketcap": {"function": ..., "handler": ..., "column": ...},
23     "dividendyield": {...},
24     "netprofitmargin": {...},
25   }
26
27   details := Lade aus kf_details-Mapping mit kf
28   function := Lade Funktion aus details
29   handler := Lade handler aus details
30   column := Lade column aus details
31   df := Rufe spezifische handler-Funktion mit (function,
32         ticker, start_date, end_date, kf, column) auf
33
34   df["ticker"] := Fuege ticker als Spalte hinzu
35   Gebe df zurueck
36
37 funktion finalize_data(df, keyfigure):
38   df := Behalte nur Spalte [ticker, keyfigure] in df
39   df := Entferne alle NaN-Values aus df
40   Falls keyfigure == "netprofitmargin":
41     kf_f := Entferne Zeilen aus df wo keyfigure > 1 oder < -1
42   Andernfalls:
43     kf := Gruppieren das df nach Ticker
44     kf_f := Berechne je Gruppe den AVG-Kennzahlenwert
45
46   kf_dict := Konvertiere kf_f in ein dict
47   Gebe kf_dict zurueck

```

Listing 4.3: Pseudocode für das Laden und Berechnen der Kennzahlen

Im Listing 4.3 wird in den Zeilen 31 - 32, über das definierte Mapping eine spezifische *handler*-Funktion geladen, die in Abhängigkeit der jeweiligen Kennzahl variiert. Aufgrund der Diversität in den Berechnungs- und Ladeprozessen werden diese in separate Funktionen ausgelagert. Wie im Listing 4.4 verdeutlicht, erfolgt die Berechnung der Marktkapitalisierung und Dividendenrendite auf Basis einer Anfrage an die API, wobei anschließend die resultierende Spalte entsprechend nach der Kennzahl umbenannt wird. Für Unternehmen, die bezüglich der Dividendenrendite keine Werte liefern, wird alternativ der Wert -0,05% zugewiesen. Dies gewährleistet, dass diese Daten in der Analyse Berücksichtigung finden und den Unternehmen zugeordnet werden, die keine Dividenden ausschütten. Ohne diese Anpassung gingen derartige Daten bei der Bereinigung von Nullwerten verloren. In beiden Funktionen wird das Ergebnis als DataFrame zurückgegeben.

```

1  funktion dy_handler(function, ticker, start_date, end_date, kf, col):
2      data_df      := Stelle Anfrage an die API mit
3                    (function, ticker, start_date, end_date)
4      df_renamed  := Benenne Spalte 'col' in data_df zu 'kf' um
5
6      Falls df_renamed leer:
7          Gebe ein DataFrame zurueck mit [kf: -0.05]
8
9      Gebe df_renamed zurueck
10
11 funktion mc_handler(function, ticker, start_date, end_date, kf, col):
12     data_df      := Stelle Anfrage an die API mit
13                   (function, ticker, start_date, end_date)
14     df_renamed  := Benenne Spalte 'col' in data_df zu 'kf' um
15
16     Gebe df_renamed zurueck

```

Listing 4.4: Pseudocode für die Marktkapitalisierung und Dividendenrendite

Das folgende Listing 4.5 zeigt, wie die Nettogewinnmarge berechnet wird. Aufgrund der komplexeren Verarbeitung der API-Antworten wurde die Funktionalität der Berechnung in die Hilfsfunktion *get\_netprofitmargin* ausgelagert. Durch Indexzugriffe werden verschachtelte Werte aus der API-Antwort extrahiert und anschließend werden sowohl Nullwerte als auch Daten außerhalb des festgelegten Zeitraums eliminiert. Die Nettogewinnmarge, die nicht direkt in den Fundamentaldaten zu finden ist, wird mit der Division des Nettoeinkommens durch den Gesamtumsatz berechnet. Vorab werden die Werte über den festgelegten Zeitraum summiert. Für ein Zeitfenster von zwei Jahren entspricht dies der Addition von acht Werten, bedingt durch die quartalsweise Veröffentlichung. Um die Division durch Null zu vermeiden, wird in einem derartigen Fall der Wert Null zurückgegeben. Das resultierende Ergebnis wird zur vereinfachten Verarbeitung als einzeliges DataFrame formatiert und zurückgeliefert.

```

1 funktion npm_handler(function, ticker, start_date, end_date, kf, _):
2     data      := Stelle Anfrage an die API mit (function, ticker)
3     npm       := Ausfuehren von get_netprofitmargin
4                 mit (data, start_date, end_date)
5     npm_df    := Wandel npm in ein DataFrame mit
6                 den Spalten [keyfigure | npm] um
7
8     Gebe npm_df zureck
9
10 funktion get_netprofitmargin(json_data, start_date, end_date):
11     data      := Lese die verschachtelten Daten aus json_data
12
13     filt_json := Filtere alle Daten aus data raus
14                 die ausserhalb von Start und End_Date
15                 sind, loesche alle nicht vorhandenen Werte
16
17     Fuer jedes item in filt_json:
18         total_net_income := Addiere item["netIncome"] zusammen
19         total_revenue    := Addiere item["totalRevenue"] zusammen
20
21     Falls total_revenue == 0:
22         Gebe 0 zurueck
23
24     Gebe total_net_income / total_revenue zurueck

```

Listing 4.5: Pseudocode für die Nettogewinnmarge

(1.8)<sup>nb\_bt</sup>: Im Anschluss erfolgt die Kombination der separat berechneten Kennzahlen mit den Nachrichtendaten, welche aus zwei unterschiedlichen DataFrames stammen. Der Verknüpfungsprozess wird über die beidseitig vorhandene Spalte *ticker* mittels eines Join-Vorgangs, in Python durch die *.merge*-Funktion realisiert, durchgeführt.

**get\_threshold** (1.9)<sup>nb\_bt</sup>: Die spätere Klassifizierung der mittels Kennzahlen gelabelten Daten in drei Gruppen erfordert die Bestimmung spezifischer Schwellenwerte. Für die Dividendenrendite werden statische Werte mit 0,0 und 0,2 festgelegt, während für die Nettogewinnmarge Grenzwerte von 0,0 und 0,1 angewandt werden. Diese vordefinierten Werte können mittels eines Mappings geladen werden. Die Festlegung der Grenzwerte für die Marktkapitalisierung erfolgt durch die Berechnung des 1/3-beziehungsweise 2/3-Quantils aus der entsprechenden Spalte der Kennzahlen, um eine gleichmäßige Verteilung der Daten zu gewährleisten.

**remove\_outliers** (1.10)<sup>nb\_bt</sup>: Es besteht die Option, zur Verbesserung der Klarheit von Histogrammen, Ausreißerwerte zu eliminieren. Es ist zu betonen, dass die Eliminierung lediglich eine Veränderung der visuellen Darstellung darstellt, während sämtliche weiterführenden Berechnungen davon unberührt bleiben. Der als prozentualer Anteil interpretierte *Cutoff*-Parameter dient dabei zur Bestimmung einer Grenze mittels

Quantilberechnung, sodass die angegebene Prozentzahl der Datenpunkte ausgeklammert wird. Das gefilterte DataFrame wird nach der Berechnung zurückgegeben.

**plot\_distribution\_keyfigure (1.11)**<sup>nb\_bt</sup>: Die Visualisierung der Kennzahlenverteilung wird durch die Erstellung eines Histogramms mittels der Matplotlib-Bibliothek<sup>5</sup> erreicht. Zusätzlich werden die zuvor bestimmten Grenzwerte in der Grafik hervorgehoben, um eine klare Unterscheidung der drei definierten Gruppen zu ermöglichen.

**preprocess (1.12)**<sup>nb\_pp</sup>: Die Vorverarbeitung des Nachrichteninhalts zielte darauf ab, ihn für die Analyse mittels des BERT-Modells aufzubereiten. Die *preprocess*-Funktion umfasst mehrere Funktionalitäten, die in verschiedene Unterfunktionen ausgelagert wurden. Diese Unterfunktionen werden anschließend mit der DataFrame-spezifischen Funktion *.apply* auf die Spalte der Nachrichteninhalte angewendet. Zu dieser Funktionsgruppe gehört *remove\_symbols*, welche mittels eines regulären Ausdrucks nicht valide Symbole identifiziert und diese aus dem Text entfernt. Zudem wird durch die Funktion *remove\_stops* eine Liste von Stopwörtern, bereitgestellt durch das Natural Language Toolkit (NLTK)<sup>6</sup> Package, geladen und entsprechend aus dem Text gefiltert. Funktionen zum Stemmen oder Lemmatisieren der Texte wurden definiert, kamen jedoch in der Trainingsphase des Modells nicht zum Einsatz. Sie könnten allerdings in zukünftigen Projekten von Nutzen sein. Abschließend sorgt die Funktion *split\_text* für eine Begrenzung der Textlänge auf maximal 512 Wörter, entsprechend der Limitation durch BERT. Hierbei wird für jeden Datensatz, dessen Inhalt diese Grenze überschreitet, bestimmt, wie viele zusätzliche Datensätze für diesen Inhalt benötigt werden, um diesen vollständig darzustellen. Dazu wird eine zu lange Nachricht auf mehrere Teildatensätze aufgeteilt. Jeder Wert des Teildatensatzes bleibt identisch, mit Ausnahme des Inhalts, der getrennt über die einzelnen Teildatensätze verteilt wird. Dies resultiert in einem DataFrame, in dem alle Textinhalte die Limitierung von BERT einhalten und einige Nachrichten über mehrere Datensätze repräsentiert werden.

**split\_by\_keyfigure (1.13)**<sup>nb\_bt</sup>: Basierend auf den zuvor bestimmten Grenzwerten wird das gesamtumfassende DataFrame in drei kleinere DataFrames aufgeteilt, die jeweils die Gruppen S, M oder L, abhängig von ihrer Kennzahlengröße, darstellen. Diese drei DataFrames werden anschließend als Tupel zurückgegeben.

**get\_values (1.14)**<sup>nb\_bt</sup>: Im dargestellten Listing 4.6 wird erläutert, wie für alle im übergebenen DataFrame vorhandenen Ticker per Multithreading der Aktienwert für jeden Tag des gesamten definierten Zeitraums bezogen wird. Dies erfolgt unabhängig davon, ob die Daten für jeden Tag benötigt werden, da der Bezug effizient mittels einer einzelnen Anfrage pro Ticker an die API realisiert werden kann. Zu Beginn werden drei Monate zum Ende des Intervalls addiert, wie in Zeile 2 gezeigt. Damit wird sichergestellt,

---

<sup>5</sup>Matplotlib [Link], Abgerufen am 04.06.2024

<sup>6</sup>NLTK Stopwords [Link], Abgerufen am 14.06.2024

dass für jedes verwendete Zieldatum die Kursänderung berechnet werden kann, ohne auf nicht vorhandene Werte zu stoßen. Andernfalls könnte sich das Problem ergeben, dass am Ende des Zeitintervalls gearbeitet wird und ein angestrebtes Zieldatum über das Ende des Intervalls hinausgeht. Wenn die Daten in der Datenbank vorhanden sind, werden sie geladen, ansonsten erfolgt der Bezug über die API. Aus der Antwort wird ausschließlich der adjustierte Schlusskurs (*adjusted\_close*) neben dem Datum behalten, da dieser den realen Kurswert am ehesten widerspiegelt. Das resultierende Dictionary wird dann in der Datenbank gespeichert, dargestellt in der Funktion *get\_values\_per\_ticker*. Abschließend erfolgt mittels der Funktion *collect\_valid\_data* eine Datenbereinigung (vgl. Zeile 10), um die Datenintegrität zu gewährleisten.

```

1 funktion get_values(df, start_date, end_date):
2     adj_end_date := Addiere drei Monate auf end_date drauf
3     unique_tickers := Beziehe jeden Ticker einmal aus df
4
5     Fuer jeden ticker aus unique_tickers:
6         stock_data := Parallel ausfuehren von
7             get_values_per_ticker mit
8             (ticker, start_date, adj_end_date)
9
10    stock_prices := Ausfuehren von collect_valid_data mit (stock_data)
11
12    Gebe stock_prices zurueck
13
14 funktion get_values_per_ticker(ticker, start_date, end_date, session):
15    value_dict := Lade Daten von der Datenbank
16    Falls value_dict leer ist:
17        value_json := Stelle Anfrage an die API mit
18            ("VALUE", ticker, start_date, end_date, session)
19        value_dict := Iteriere ueber alle Eintraege in value_json
20            und speichere "date" mit "adjusted_close"
21
22    Speichere value_dict auf die Datenbank
23
24    Gebe value_dict zurueck
25
26 funktion collect_valid_data(data):
27    filtered_data := Entferne alle None, NaN oder False Werte
28
29    Gebe filtered_data zurueck

```

Listing 4.6: Pseudocode für das Beziehen der Kurswerte der Aktien

**calc\_adj\_change (1.14)<sup>nb</sup>–<sup>bt</sup>**: Auf Basis der zuvor abgerufenen Aktienkurse wird für jede Zeile im DataFrame von dem Veröffentlichungstag der Nachricht  $x$  bis zum festgelegten Zielzeitpunkt  $x + t$ , wobei  $t =$  drei Tage, eine Woche oder zwei Wochen sein kann, die normalisierte Kursänderung ermittelt. Normalisiert bedeutet in diesem

Zusammenhang, dass die Kursänderung um die durchschnittliche Änderung der entsprechenden Gruppe bereinigt wird. Dies relativiert jede Änderung im Kontext der Gruppe und ermöglicht eine differenziertere Bewertung. Zur Umsetzung wird zunächst die nicht-normalisierte Kursänderung berechnet, indem überprüft wird, ob sowohl der Ticker als auch die jeweiligen Datenpunkte ( $x$  und  $x + t$ ) in den geladenen Kursdaten aus der Funktion `get_values` vorhanden sind. Sollten diese Daten verfügbar sein, werden sie bezogen und durch einfache Subtraktion, gefolgt von einer Umwandlung in eine prozentuale Angabe, ermittelt. Nachdem dies für den gesamten Datensatz der Gruppe durchgeführt wurde, erfolgt die Bereinigung um den Durchschnittswert der Gruppe, um die normalisierte Änderung zu erhalten. So wird beispielsweise eine Änderung von 15% im Kontext einer durchschnittlichen Gruppenänderung von 10% nur noch mit einem normalisierten Wert von 5% bewertet.

### 4.3. Nutzung des Sprachmodells

Wie anfänglich in der Implementierung zu Einführung der Parameter 1.1 erwähnt, wurden nicht alle erforderlichen Parameter eingeführt, diese werden hier nun ergänzt. Es bedarf der Definition des Namens des zu ladenden Sprachmodells. Für das Neutrainieren eines Sprachmodells sind weitere trainingsrelevante Parameter zu berücksichtigen, die hier allerdings außen vor bleiben. Für die Simulationen und Auswertungen muss außerdem der Berechnungsmodus für die Grenzwerte der Signale festgelegt werden. Optional können zudem die Stichprobengröße, die das Set bei gleichbleibender Verteilung reduziert, sowie ein *Random Seed* für die Reproduzierbarkeit angegeben werden.

**get\_label\_for\_target (2.1)<sup>nb-pp</sup>**: Diese Funktion ermöglicht es, dynamisch und ohne Notwendigkeit einer manuellen Nutzeranpassung der Variablen, die adäquaten Spaltennamen für die Verarbeitung im Sprachmodell zu bestimmen. Dies erfolgt durch ein einfaches Mapping der drei Zieldate. Als Ergebnis wird ein Tupel zurückgegeben, das alle für die weitere Verarbeitung notwendigen Spalten umfasst.

**adjust (2.2)<sup>nb-pp</sup>**: Um die Kompatibilität mit dem Modell zu gewährleisten, erfolgt eine Anpassung der Spaltennamen des DataFrames. Die Spalte *content* wird in *text* umbenannt, da BERT diese Bezeichnung für die Analyse verwendet. Die Spalte *actual change* wird zu *label* umbenannt, da sie für Trainings- und Validierungszwecke sowie zur Überprüfung der Richtigkeit der Vorhersagen genutzt wird.

**sample\_rows (2.3)<sup>nb-pp</sup>**: Optional kann zur Reduzierung der Ausführungszeit des Sprachmodells die Größe des Testdatensatzes verringert werden. Um die Repräsentativität der Daten zu sichern, wird die Verteilung der Aktien beibehalten. Basierend auf der angegebenen Anzahl der *total\_rows* wird die benötigte Anzahl an Zeilen pro Ticker ermittelt. Bei einem Wert von 1000 *total\_rows* und 100 Tickern ergäbe sich

ein Wert von zehn `rows_per_ticker`. Der Wert `rows_per_ticker` kann minimal eins betragen, da mindestens eine Nachricht pro Ticker vorhanden sein muss, während das Maximum durch die variierende Anzahl an Nachrichten pro Ticker bestimmt wird.

**`simulate_predictions` (2.4)<sup>nb-pp</sup>**: Mit dem geladenen Sprachmodell können nun Vorhersagen zu Kursänderungen der betrachteten Aktien auf Grundlage der zugehörigen Nachrichten gemacht werden. Mittels der `predict_df` werden die Vorhersagen auf Basis der relevanten Spalten des übergebenen DataFrames durchgeführt. Hierbei wird auch der im Training verwendete Tokenizer von Hugging Face<sup>7</sup> geladen, um die Daten des DataFrames passend aufzubereiten. Nachdem die Vorhersagen erfolgt sind, werden diese in einem DataFrame zusammengeführt. Zusätzlich wird die Methode zur Grenzwertbestimmung durchgeführt, um Kauf-, Verkaufs- und Haltesignale zu vergeben. Dabei wird zwischen einer statischen Vergabe und einer prozentualen Vergabemethode unterschieden. Bei der prozentualen Methode wird ein Prozentsatz  $x$  definiert. Darauf basierend werden die oberen und unteren  $x$  Prozent der Vorhersagen als Kauf- beziehungsweise Verkaufssignale klassifiziert. Die Grenzwerte werden über die Funktion `calculate_auto_threshold` bestimmt, welche das Percentile-Verfahren verwendet, um anhand des gegebenen Prozentsatzes adäquate Grenzwerte aus den Vorhersagen zu ermitteln. Abhängig davon werden dann die Signale zugeteilt.

### 4.4. Auswertung und Evaluation

**`evaluate_performance` (3.1)<sup>nb-bt</sup>**: Die Evaluierung der Prognosegenauigkeit erfolgt auf Basis der zugewiesenen Signale, welche im Rahmen der zuvor durchgeführten Simulationsfunktion generiert wurden. In Abhängigkeit von den ermittelten Kauf- oder Verkaufssignalen erfolgt eine Aufteilung des Ausgangs-DataFrames in zwei separate DataFrames. In der Folge wird auf die zuvor erstellten DataFrames jeweils die Funktion `calculate_mm_change` angewendet, um für die Datensätze des jeweiligen Signals den Mittelwert und Median der realen Kursänderungen zu ermitteln. Resultierend daraus weist eine Nachricht mit einem Kaufsignal im Mittel- beziehungsweise Medianwert den berechneten Wert auf, welcher idealerweise einen potenziellen prozentualen Gewinn darstellt. Analog dazu stellen Verkaufssignale den potenziellen vermiedenen Verlust im Mittel- beziehungsweise Medianwert dar. In einem letzten Schritt wird die Funktion `find_best_worst_predictions` ausgeführt, welche die treffendsten und ungenauesten Vorhersagen identifiziert sowie den durchschnittlichen Fehler, die Fehlergesamtsumme und die Anzahl der Ticker ermittelt. Weiterführende Informationen dazu sind im Kapitel 5.2 zu finden.

---

<sup>7</sup>Hugging Face [Link], Abgerufen am 14.06.2024



## 5. Evaluationsmethodik

In diesem Kapitel erfolgt die Erläuterung der ausgewählten Kriterien, die für die Ausführung des Programms herangezogen wurden, sowie die Darlegung der Beweggründe für deren Auswahl. Des Weiteren werden die zu analysierenden Werte im Rahmen der Auswertung vorgestellt, die zur Messung des Erfolgs des Experiments und zur Gewinnung von Erkenntnissen herangezogen werden. In der folgenden Tabelle 5.1 sind die in den nachfolgenden Kapiteln verwendeten Symbole aufgeführt und erläutert.

Symbol	Bedeutung
<i>Buy</i>	Im Programm genutztes Signal für den <u>Kauf</u> einer Aktie
<i>Sell</i>	Im Programm genutztes Signal für den <u>Verkauf</u> einer Aktie
<i>Hold</i>	Im Programm genutztes Signal für das <u>Halten</u> einer Aktie
3D	<u>Drei Tage</u> Differenz zwischen Veröffentlichung und Vorhersage
1W	<u>Eine Woche</u> Differenz zwischen Veröffentlichung und Vorhersage
2W	<u>Zwei Woche</u> Differenz zwischen Veröffentlichung und Vorhersage

Tabelle 5.1.: Bedeutung der verwendeten Symbole

### 5.1. Kriterien

Für die Durchführung des Experiments wurden Parameter definiert, die nachfolgend dargestellt sind. Als Untersuchungsgegenstand diente der Aktienindex *NYSE Composite*, welcher alle an der New Yorker Börse gelisteten Unternehmen umfasst<sup>1</sup>. Die Auswahl dieses Indexes erfolgte aufgrund seiner umfassenden Repräsentation unterschiedlicher Aktien, die ein breites Spektrum an Merkmalen und Unternehmensgrößen abbilden. Eine solche Diversität ist für eine umfangreiche Analyse unerlässlich.

Der Untersuchungszeitraum erstreckte sich vom 1. Januar 2021 bis zum 31. Dezember 2022. Dabei wurde darauf geachtet das der Zeitraum übereinstimmt mit dem der zur Modelltrainierung verwendeten wurde, um Konsistenz zu gewährleisten. Die

<sup>1</sup>NYSE Composite [Link], Abgerufen am 01.07.2024

initiale Wahl dieses Zeitrahmens für das Modelltraining war darauf ausgerichtet, die direkten Auswirkungen der Corona-Pandemie auf Kursänderungen zu minimieren, während gleichzeitig möglichst aktuelle Daten herangezogen wurden. Entsprechend der Fokussierung auf den genannten Index kam der Kalender der New York Stock Exchange zur Bestimmung relevanter Feiertage zum Einsatz. Zur effektiven Visualisierung wurde der Ausschluss der oberen 1% der Ausreißer festgelegt.

Weiterhin wurde die Festlegung des Ziels, welches die Differenz zwischen der Veröffentlichung einer Nachricht und dem Zeitpunkt der Vorhersage beschreibt, vorgenommen. Dargestellt wird dieses Kriterium mit dem Parameter *target*. Hierbei wurden diese verschiedenen Zeitdifferenzen als Parameter gewählt: drei Tage (3D), eine Woche (1W) und zwei Wochen (2W), wobei für jeden dieser Werte das Notebook separat ausgeführt wurde. Dies gilt auch für die Kennzahlen: Marktkapitalisierung (*marketcap*), Dividendenrendite (*dividendyield*) und Nettogewinnmarge (*netprofitmargin*), für die das Notebook mehrfach ausgeführt wurde. Jede Kennzahl wurde somit in Kombination mit jedem Zielwert untersucht, was in insgesamt neun Durchläufen resultierte. Die Ergebnisse dieser Analysen werden im nachfolgenden Kapitel 6 detailliert vorgestellt.

Im Zuge eines Zwischenschritts wurde eine Eliminierung potenzieller Überschneidungen zwischen den Trainings- und Testdaten vorgenommen. Zu diesem Zweck erfolgte eine Definition der ETFs, die während des Trainings verwendet wurden. Dies umfasst den Konsumgüter-ETF (XLP), sowie den ETF für den Technologiesektor (XLK).

Zudem war das Laden des definierten Sprachmodells erforderlich. Die Benennung des gewählten Modells generiert sich automatisch aus dem jeweiligen Zielwert in Kombination auf Basis eines vordefinierten Namensschemas. Diese Differenzierung basiert auf der angenommenen Prämisse, dass die vortrainierten Modelle aus einem Praxisprojekt für unterschiedliche Zielsetzungen spezifisch angepasst wurden. Für ein erneutes Training des Modells müssten diverse Parameter definiert werden, darunter Lernrate, Anzahl der Epochen, Batchgröße, Gewichtsverlust und das Basis-Modell. Eine tiefere Beschreibung der Parameterfindung ist im Skript *executor.py*<sup>2</sup> zu finden.

Zur Realisierung der Simulationen und zur Bewertung der durchgeführten Analysen mussten ferner Entscheidungen bezüglich der Methode zur Berechnung von Kauf- beziehungsweise Verkaufssignalen gefällt werden. Es wurde eine prozentbasierte Methode gewählt, bei der die oberen 10% der vorhergesagten Kursänderungen ein Kaufsignal (*Buy*) und die unteren 10% ein Verkaufssignal (*Sell*) erhalten, alle übrigen Werte wurden als Halteposition (*Hold*) klassifiziert. Aufgrund von Hardwarebeschränkungen war eine Verarbeitung des gesamten Datensatzes, der mehr als 500.000 Einträge umfasst, nicht möglich. Stattdessen wurde ein kleineres Testdatenset erstellt, welches die Datenmenge pro Gruppe auf 10.000 begrenzt, wobei darauf geachtet wurde, dass die

---

<sup>2</sup>GitHub: [executor.py](#) Skript [Link], Abgerufen am 01.07.2024

Gesamtverteilung dem originalen Datenset entspricht. Aktien mit mehr Nachrichten behalten somit auch im kleineren Testdatenset eine höhere Gewichtung. Für die konsistente Auswahl der Daten kam ein identischer Zufallszahlengenerator, dargestellt mit dem Parameter *random\_seed*, zum Einsatz, der eine gleichbleibende Verteilung gewährleistet.

## 5.2. Auswertung

Zur Bewertung des Erfolges der Arbeit werden die Ergebnisse initial in zwei Hauptkategorien klassifiziert. Diese erfolgt unter Zuhilfenahme eines DataFrames, welches die mittels der vorab durchgeführten Simulation erstellten Vorhersagen und Signale umfasst. In dieser Simulation wurden Vorhersagen auf die Kursänderungen, auf Basis der Nachrichten, getätigt und in ein Signal umgewandelt. Die Tabelle 5.2 zeigt exemplarisch einen Ausschnitt der Daten nach der Simulation. Aus Gründen der Übersichtlichkeit erfolgte eine Abkürzung der Spaltennamen. Es sei angemerkt, dass die Begriffe *actual* und *predicted* in diesem Zusammenhang für *actual change* beziehungsweise *predicted change* stehen. Die Werte in diesen Spalten sind bereits in prozentualer Darstellung und bedürfen keiner Umwandlung.

ticker	title	date	predicted	future date	actual	signal
TRC.US	[...]	2022-03-03	0,16	2022-03-04	2,00	Buy
MKFG.US	[...]	2022-11-28	0,04	2022-12-01	-5,10	Hold
PBH.US	[...]	2022-09-26	0,01	2022-09-29	-2,18	Sell

Tabelle 5.2.: Ausschnitt aus der Simulationstabelle

Die Nachrichten, die mit einem *Hold*-Signal versehen sind, werden ausgeklammert, woraufhin das DataFrame in zwei separate DataFrames aufgeteilt wird: eines, das sämtliche Nachrichten mit *Buy*-Signalen enthält, und eines für die Nachrichten mit *Sell*-Signalen. Für diese beiden DataFrames wird jeweils der Mittelwert sowie der Medianwert der tatsächlichen Kursänderung, repräsentiert durch die Spalte *actual change*, berechnet. Die Berechnungen erfolgen nach den folgenden Formeln, wobei  $n$  die Anzahl der Datensätze darstellt:

$$\text{average} = \frac{1}{n} \sum_{i=1}^n \text{actual change}_i$$

$$\text{median} = \begin{cases} \text{actual change}_{(\frac{n+1}{2})} & \text{falls } n \text{ ungerade} \\ \frac{1}{2} \left( \text{actual change}_{(\frac{n}{2})} + \text{actual change}_{(\frac{n}{2}+1)} \right) & \text{falls } n \text{ gerade} \end{cases}$$

Für jedes der beiden DataFrames wird anschließend der mittelwertige beziehungsweise mediane Summenwert ermittelt, indem die jeweiligen Mittel- oder Medianwerte zusammengefasst werden. Im Folgenden dargestellt:

$$\text{average}_{\text{summe}} = \text{average}_{\text{buy}} + (-\text{average}_{\text{sell}})$$

$$\text{median}_{\text{summe}} = \text{median}_{\text{buy}} + (-\text{median}_{\text{sell}})$$

Es ist von essenzieller Bedeutung, das Vorzeichen der *Sell*-Signale im Kontext der Berechnung der Summe umzukehren. Ein negativer Wert ist, wenn alleinstehend, als positiv zu bewerten, da er einen vermiedenen Verlust darstellt. Für eine korrekte Berechnung der Summe ist jedoch eine Anpassung dieses Vorzeichens erforderlich.

Anhand des folgenden Beispiels lassen sich die Werte weiterführend verdeutlichen. Hierfür wird ein Ausschnitt ausgewählt, der sich auf das Zieldatum von drei Tagen bezieht, unterteilt nach der Marktkapitalisierung. Exemplarisch wird hier ausschließlich die Gruppe S betrachtet, dargestellt in Tabelle 5.3. Die vollständige Tabelle mit den detaillierten Ergebnisbeobachtungen findet sich im darauffolgenden Kapitel 6. Eine Nachricht bezüglich einer Aktie, die ein *Buy*-Signal erhalten hat und Teil der Gruppe S ist, verzeichnet im Mittelwert eine tatsächliche Kursänderung von 0,82% und im Median einen realen Änderung von -0,20%. Für Nachrichten innerhalb dieser Gruppe S, die *Sell*-Signale aufweisen, liegt die mittelwertige tatsächliche Kursänderung bei -0,47% und der Median der Kursänderung bei -0,40%. Die resultierende Kennzahl, Summe, repräsentiert nun eine kombinierte mittelwertige Kursbewegung, die beide Signaltypen (*Buy* und *Sell*) in einer positiven Dimension zusammenfasst. Bei einer gleich verteilten Berücksichtigung von sowohl *Buy*- als auch *Sell*-Signale, resultiert der Mittelwert der aufsummierten Rendite bei 1,29% und im Median bei 0,20%.

Signal	Gruppe	Mittelwert	Median
Buy-Signale	S	0,8236%	-0,2000%
Sell-Signale	S	-0,4703%	-0,4020%
Summe	S	1,2939%	0,2021%

Tabelle 5.3.: Beispielhafte Ergebnisse

Angesichts der Durchführung des Modells zu insgesamt neun Durchläufe, jeweils für jede Kennzahl mit jedem definierten Zieldatum, und der Unterteilung innerhalb der Durchführung nach den drei Gruppengrößen, wird für die Darstellung der aggregierten Ergebnisse (Summe) zu Beginn der folgenden Ergebnisunterkapitel eine Matrix verwendet. Diese dient dazu, kategorisch nach Kennzahlen geordnet, die verschiedenen Gruppengrößen S, M und L, welche in jeder Ausführung, für jede Kombination der

Kennzahlen und Zieldaten mit berechnet wurden, in Relation zu den unterschiedlichen Zieldaten zu setzen. Diese Matrix bietet eine klare Übersicht über die kombinierten Summenresultate der Kauf- (*Buy*) und Verkaufssignale (*Sell*) und legt den Grundstein für die anschließende feingranulare Darstellung dieser Daten. Diese detaillierte Präsentation der Ergebnisse erfolgt in Tabellenform, welche sowohl die Mittel- als auch die Medianwerte der Kauf- und Verkaufssignale aufzeigen, ergänzt durch das kombinierte Summenergebnis, so wie es zuvor beispielhaft dargestellt wurde. Strukturell lässt sich das Ergebniskapitel, wie folgt einteilen: Zunächst erfolgt eine oberkategoriale Differenzierung nach Kennzahlen, gefolgt von einer Unterteilung innerhalb dieser Subkapitel nach dem betrachteten Zieldatum von drei Tagen (3D), einer Woche (1W) oder zwei Wochen (2W). Für das jeweils betrachtete Zieldatum werden die Ergebnisse dann nach den Gruppengrößen S, M und L in einer Tabelle zusammengefasst.

Im Weiteren findet eine Darstellung der Signalgenauigkeit statt, wobei eine Unterscheidung nach den zugrunde liegenden Kennzahlen erfolgt, sodass drei Tabellen dargelegt werden. Für jede Kennzahl wird jede Gruppe unter Berücksichtigung sämtlicher Zieldaten, zusammenfassend von drei Tagen bis zu zwei Wochen, untersucht. Eine korrekte Zuordnung der Signale wird dann angenommen, wenn die Ergebnisse der Kaufsignale in den Mittel- oder Medianwerten positive Ausprägungen und die der Verkaufssignale entsprechend negative aufweisen. Zusätzlich wird eine Beurteilung auf die Summe durchgeführt, welche aus beiden Signalarten errechnet wird, die für eine korrekte Klassifizierung gleichfalls einen positiven Wert voraussetzt.

Nachstehend in der Tabelle 5.4, wird ein Ausschnitt aus der Darstellung der Signalgenauigkeit für Gruppe S präsentiert, unterteilt nach der Marktkapitalisierung. Die vollständige Ausführung der Daten findet sich im folgenden Kapitel 6. In der Tabelle wird deutlich, dass von insgesamt sechs berechneten Werten für die Kaufsignale (*Buy*), vier ein positives Vorzeichen (+) aufzeigen. Die Identifizierung der sechs möglichen korrekten Ausprägungen je Signal basiert auf der Zusammenfassung der Daten aus den drei Tabellen, die jeweils für die drei Zieldaten stehen, kombiniert mit den zwei Analysewerten – dem Median und dem Mittelwert, was rechnerisch in  $2 \times 3 = 6$  Werten dargestellt wird. Dieselbe Analyseverfahren wird ebenso auf die Verkaufssignale (*Sell*) angewandt sowie auf die kombinierten Summenergebnisse. Anhand dieser Werte wird anschließend für jede Gruppe ein prozentualer Genauigkeitswert berechnet.

	Buy-Signale	Sell-Signale	Summe	Score
Gruppe S	4/6	6/6	6/6	88,9%

Tabelle 5.4.: Beispielhafte Signalgenauigkeit

## 6. Ergebnisse

In der Phase der Ergebnispräsentation werden die Daten zunächst in ihrer numerischen Form vorgestellt. Eine subjektive Deutung und weiterführende Interpretation dieser Daten findet im darauffolgenden Kapitel 7 statt. Zu Beginn dieses Abschnitts wird auf die Metadaten geblickt, der weitere Teil des Kapitels gliedert sich in drei Teilbereiche, von denen jeder eine spezifische Kennzahl thematisiert. Nach einer Einleitung, die einen Überblick über die Resultate jeder Kennzahl gewährt, folgt eine detaillierte Analyse. Diese teilt sich auf in eine Segmentierung nach den Gruppen sowie eine Differenzierung zwischen Mittel- und Medianwerten. Abschließend wird ein zusammenfassender Blick auf zusammengeführte, aussagekräftige Ergebnisse geworfen.

### 6.1. Metadaten

Die Metadaten dienen dazu, die Daten strukturiert darzulegen, diese in den betrachteten Kontext zu stellen und so aufzubereiten, dass die Herleitung und das Verständnis der Ergebnisse erleichtert werden. Im Folgenden wird zunächst die Verteilung der Daten auf die verschiedenen Gruppen betrachtet. Anschließend werden Histogramme untersucht, die die Verteilung der Vorhersagen sowie der realen Kursänderungen darstellen. Schließlich wird die *Baseline* besprochen, die den Mittelwert der ursprünglichen Gruppen und die zugehörige Standardabweichung darstellt.

#### 6.1.1. Verteilung der Daten

Die Datenerhebung für diese Arbeit erstreckte sich über den Zeitraum von Januar 2021 bis Dezember 2022. Hierfür wurde der *NYSE Composite* Index herangezogen, der sämtliche Aktien der New Yorker Börse repräsentiert. Dies entspricht fast 1900 gelisteten Aktien. Es ist allerdings anzumerken, dass die Anzahl der analysierten Aktien geringfügig unter diesem Wert liegen werde, da die verwendete Leeway-API nicht für jede Aktie im Index, Daten für die ausgewählte Kennzahl, zur Verfügung stellen konnte. Über den genannten Zeitraum wurden zu jeder Aktie des Index Nachrichten gesammelt, was in insgesamt etwa 600.000 Nachrichten mündete. Nach dem Ausschluss von Daten, die Überschneidungen mit dem Testdatensatz aufwiesen, verblieben circa 558.000 relevante

Datensätze. Im Rahmen der Vorverarbeitung für das Sprachmodell wurden zu lange Nachrichtenartikel in mehrere Segmente unterteilt, um der maximalen Eingabelänge des BERT-Modells gerecht zu werden. Diese Aufbereitung resultierte in etwa 830.000 Datensätzen, die für die Analyse durch das Sprachmodell vorbereitet wurden. Die nachfolgende Tabelle 6.1 visualisiert die Verteilung der Aktien nach den Gruppen. Eine detaillierte Erläuterung der festgelegten Grenzwerte für die unterschiedlichen Kennzahlen ist im Kapitel zur Methodik 3 nachzulesen.

	Gruppe S	Gruppe M	Gruppe L	
Marktkapitalisierung	617	617	618	1.852
Nettogewinnmarge	405	669	742	1.816
Dividendenrendite	712	1.029	151	1.892

Tabelle 6.1.: Verteilung der Aktien nach Kennzahl und Gruppen

Die Verteilung der Nachrichten, dargestellt in der Tabelle 6.2, weist im Vergleich zur Verteilung der Aktien Unterschiede auf. Dies lässt sich darauf zurückführen, dass Aktien in höheren Gruppen tendenziell eine größere Anzahl an Nachrichten generieren.

	Gruppe S	Gruppe M	Gruppe L	
Marktkapitalisierung	99.804	210.421	518.396	828.621
Nettogewinnmarge	142.791	278.664	390.672	812.127
Dividendenrendite	250.041	534.492	45.666	830.199

Tabelle 6.2.: Verteilung der Nachrichten nach Kennzahl und Gruppen

Obwohl die Datengrundlage für den Untersuchungszeitraum von zwei Jahren für den *NYSE Composite* Index mehr als eine halbe Million Datensätze umfasst, beschränkte sich die Analyse aufgrund von Hardwarebegrenzungen auf nur 10.000 Datensätze je Gruppe. Bei der Auswahl und Reduktion der Datensätze wurde darauf geachtet, die ursprüngliche Verteilung der Nachrichten zu erhalten. Dies bedeutet, dass Nachrichten, die bei den gesamten Daten einen größeren Anteil einnahmen, auch in der reduzierten Datenauswahl höhere Beachtung fanden. Auf der Grundlage dieses verkleinerten Datensatzes werden anschließend die Vorhersagen erstellt. Die Anzahl der Datensätze pro Gruppe liegt leicht unter 10.000. Dies resultiert daraus, dass die Verteilung der Nachrichten identisch zur des Gesamtdatensets bleibt, wodurch es vorkommt, dass bestimmte Aktien ihren Platz nicht vollständig ausfüllen können, da nicht genügend Nachrichten vorhanden sind. Dies hat weiterführend zur Folge, dass bei der Vergabe der Signale diese Signalgruppen auch weniger Werte umfassen, als zu erwarten wäre.

### 6.1.2. Verteilung der Kursänderungen

In den nachstehenden Abbildungen 6.1, 6.2 und 6.3 werden jeweils zwei Histogramme präsentiert. Die y-Achse repräsentiert die Häufigkeit des Vorkommens, während die x-Achse die prognostizierte beziehungsweise tatsächliche Kursänderung in Prozent abbildet. Auf der linken Seite ist die Visualisierung der *predicted changes* zu sehen, welche die vom Modell erstellten Vorhersagen darstellen, mit rot gestrichelten Linien, welche die Schwellenwerte für die Zuweisung der Signale markieren. Auf der rechten Seite sind die tatsächlichen Kursänderungen, die sogenannten *actual changes*, abgebildet. Zusätzlich sind in beiden Darstellungen der Mittelwert sowie die Standardabweichung integriert. Eine detailliertere Betrachtung dieser Werte erfolgt im nachfolgenden Teil.

In Abbildung 6.1 wird die Verteilung der vorhergesagten und realen Kursänderungen für die Gruppe M, unterteilt nach der Marktkapitalisierung, auf das Zieldatum von drei Tagen (3D) dargestellt. Die prognostizierten Änderungen (*predicted changes*) weisen eine rechtsschiefe Verteilung auf. Dies wird ersichtlich durch die Konzentration der meisten Werte zu Beginn der Verteilung, was zu einem raschen Anstieg bis zu einem Maximum der Häufigkeit von über 700 führt, gefolgt von einem langsameren Abfall. Der größte Teil der Vorhersagen liegt im positiven Bereich. Dies wird durch die Festlegung der Signalgrenzen bei 0,02% für die untere und 0,14% für die obere Grenze verdeutlicht. Nach der Signalgrenzenverteilung befinden sich nur 10% der Gesamtvorhersagen unter dem unteren Schwellenwert. Im Gegensatz dazu zeigen die realen Kursänderungen (*actual changes*) eine Normalverteilung, mit einer Tendenz zu mehr positiven Ausreißern und allgemein deutlich höheren Werten.

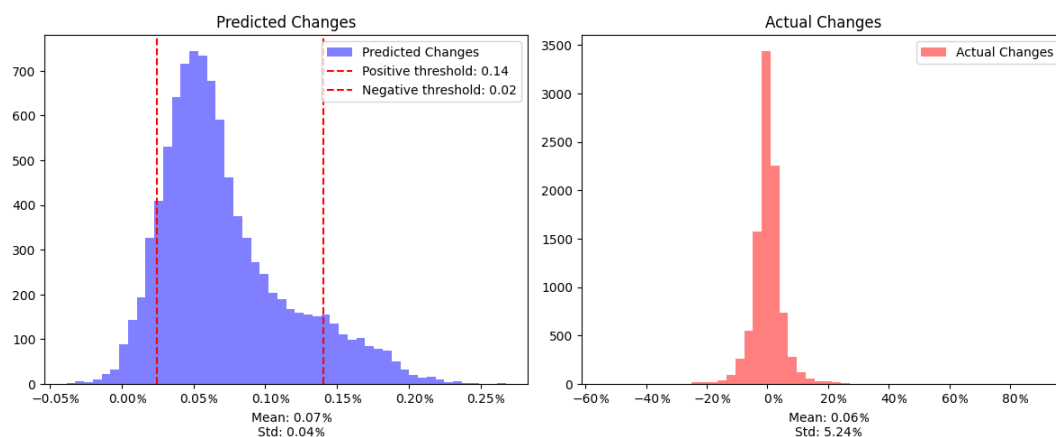


Abbildung 6.1.: Histogramm der vorhergesagten und realen Kursänderungen (3D)

Die nachfolgende Abbildung (vgl. 6.2) veranschaulicht die prognostizierten sowie die tatsächlichen Kursänderungen für die Gruppe M, unterteilt nach der Marktkapitali-



sierung, für ein Zieldatum von einer Woche (1W). Die Verteilung der Vorhersagen (*predicted changes*) ist deutlich ausgeprägter rechtsschief als zuvor. Der initiale steile Anstieg erreicht einen Höhepunkt bei etwa 1750 Vorkommnissen und fällt anschließend stark ab. Dabei jedoch mit einem langen Schweif, der sich zur rechten Seite erstreckt. Die Verteilung der Vorhersagen, liegt weiterhin überwiegend im positiven Bereich. Die festgelegten Signalgrenzen bei  $-0,01\%$  für den unteren und  $0,63\%$  für den oberen Grenzwert deuten darauf hin, dass lediglich eine geringe Anzahl von Vorhersagen negativ ausfallen. Die realen Kursänderungen (*actual changes*) sind ähnlich wie bei dem betrachteten Zeitraum von drei Tagen normalverteilt und weisen größere Werte auf, sowohl im Vergleich zu den Vorhersagen als auch zu dem vorherigen Zieldatum.

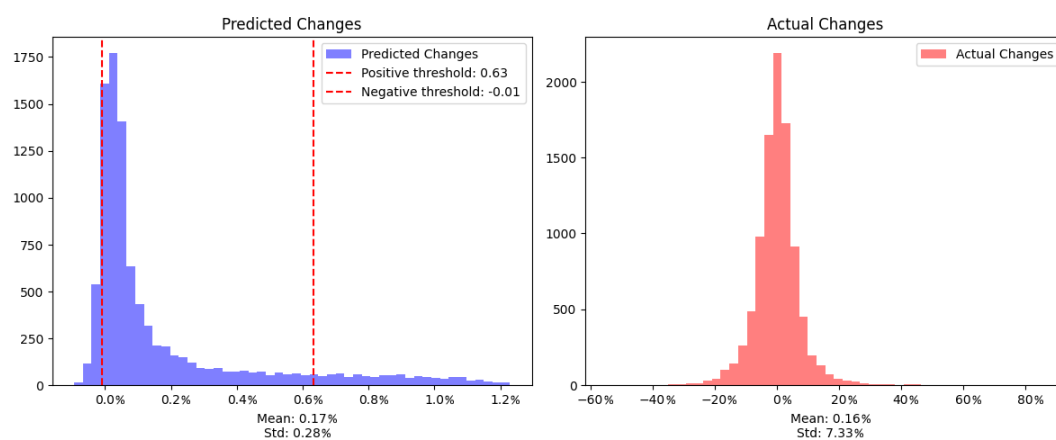


Abbildung 6.2.: Histogramm der vorhergesagten und realen Kursänderungen (1W)

Die abschließende Darstellung 6.3 betrachtet wiederum für die Gruppe M, basierend auf der Unterteilung nach der Marktkapitalisierung, die Verteilungen der Kursänderungen, für das dritte und letzte Zieldatum von zwei Wochen. Die Verteilung der prognostizierten Änderungen (*predicted changes*) weist weiterhin eine rechtsschiefe Charakteristik auf, allerdings in weniger ausgeprägter Form als im vorangehenden Zeitraum von einer Woche. Optisch ergibt sich eine größere Übereinstimmung mit der Verteilungsform der Prognosen die für das Zieldatum von drei Tagen erstellt wurden. Mit einem Maximum von knapp 600 Ereignissen fällt die Häufigkeit im Anschluss langsam ab. Obwohl die Vorhersagen weiterhin eine positive Richtung einschlagen, weisen sie nicht das Ausmaß der vorher gezeigten Verteilung auf, und der festgesetzte negative Grenzwert bei  $-0,56\%$  zeigt, dass ein größerer Anteil der Vorhersagen im negativen Bereich liegt. Der positive Grenzwert wurde mit  $1,70\%$  errechnet. Die realen Kursänderungen (*actual changes*) bleiben normalverteilt, zeigen jedoch eine kleine Tendenz zu positiven Ausreißern und weisen weiterhin größere Werte auf im Vergleich zu den vorhergesagten Kursänderungen und den vorausgehenden Zieldaten.




Abbildung 6.3.: Histogramm der vorhergesagten und realen Kursänderungen (2W)

Im Anhang A sind alle Histogramme zu jeder Kennzahl, jedem Zieldatum und jeder Gruppe aufgeführt. Die aus den präsentierten Abbildungen gewonnenen Erkenntnisse lassen sich auf die im Anhang befindlichen Werte übertragen. Insbesondere auch die Resultate bezüglich des Zieldatums von einer Woche (1W).

### 6.1.3. Baseline der Gruppen

Im Folgenden wird die so genannte *Baseline* betrachtet, die den Mittelwert der realen Kursänderung einer Aktie in den jeweiligen Gruppen darstellt. Zusätzlich dazu wird nebenstehend zu der *Baseline*, auch die Standardabweichung der realen Kursänderungen innerhalb der Gruppen nach der jeweiligen Kennzahlen dargestellt. Diese initiale Visualisierung ermöglicht es, frühzeitig festzustellen, ob bestimmte Gruppen durchgängig besser oder schlechter abschneiden. Es ist dabei von Bedeutung zu betonen, dass die *Baseline*-Werte in die Bewertung und Auswertung der Ergebnisse des Modells einbezogen werden. Die tatsächliche Kursänderung, im Programm als *actual change* bezeichnet, die als zentrales Vergleichs- und Bewertungskriterium fungiert, ist unter Berücksichtigung der gruppenbezogenen *Baseline* bereits normalisiert. Dies wird Einführend in der Methodik erläutert, siehe Schritt 1.14 in dem Abschnitt 3.2.1. In den nachfolgenden Abbildungen werden sowohl der beschriebene Wert als auch die Standardabweichung graphisch dargestellt. Die y-Achse repräsentiert die entsprechenden Angaben in Prozent. Auf der x-Achse erfolgt eine Differenzierung nach den jeweiligen Gruppen. Innerhalb dieser Gruppen wird zudem nach den unterschiedlichen Zieldaten unterschieden, was durch die Verwendung farblicher Balken kenntlich gemacht wird.

## Marktkapitalisierung

In der nachstehenden Grafik, siehe Abbildung 6.4, wird der Mittelwert, bezeichnet als *Baseline*, für die vorgegebenen Gruppen und Zeiträume gemäß der Marktkapitalisierung aufgezeigt. Die Darstellung der Standardabweichung, die sich auf dieselbe Kategorisierung nach der Marktkapitalisierung bezieht, findet sich in der angrenzenden Abbildung 6.5.

Es ist zu erkennen, dass der Mittelwert der realen Kursänderungen für die Gruppe S über die verschiedenen Zieldaten hinweg durchweg negativ ist, wobei der Wert für einen Zeitraum von drei Tagen (3D) bei etwa -0,01%, für eine Woche (1W) bei -0,1% und für zwei Wochen (2W) bei fast -0,2% liegt. Im Gegensatz dazu sind die Werte der Gruppe M über alle betrachteten Zeiträume durchweg positiv, mit fast 0,5% für drei Tage, 0,15% für eine Woche und über 0,2% für zwei Wochen. Die Gruppe L hingegen zeigt einen Wert von knapp -0,05% für drei Tage, circa -0,1% für eine Woche, während der Wert für zwei Wochen mit über 0,1% im positiven Bereich liegt.

Die Standardabweichung zeigt für die Gruppe S einen stetigen Anstieg vom kleinsten Zieldatum mit circa 6,0% für drei Tage bis zu einem Zeitraum von zwei Wochen mit etwa 12,5%. Gruppe M zeigt ein ähnliches Muster, allerdings liegen die Werte im direkten Vergleich zu den entsprechenden Zeiträumen durchgängig leicht unter denen von Gruppe S. Die Gruppe L hingegen weist für die Zeiträume von drei Tagen und einer Woche mit circa 5,0% beziehungsweise 7,5% die geringste Standardabweichung auf. Der Wert für zwei Wochen weicht mit über 25,0% deutlich ab.

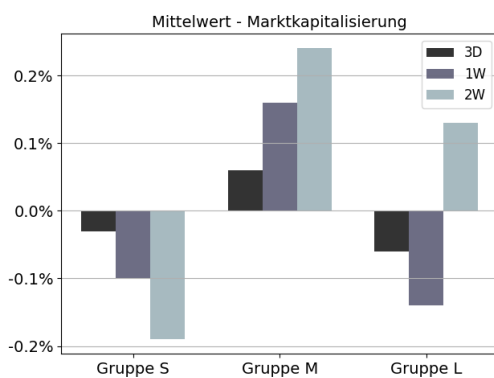


Abbildung 6.4.: Mittelwert für Marktkapitalisierung nach Gruppen und Zieldaten




Abbildung 6.5.: Std.Abw. für Marktkapitalisierung nach Gruppen und Zieldaten

## Nettogewinnmarge

In der untenstehenden Abbildung 6.6 wird der Mittelwert (*Baseline*) der Nettogewinnmarge nach den verschiedenen Gruppen und Zieldaten dargestellt. Ergänzend hierzu zeigt nebenstehend Abbildung 6.7 die Standardabweichung der Nettogewinnmarge unter denselben Kriterien, nach den Gruppen und Zieldaten.

Der Mittelwert der Nettogewinnmarge für die Gruppe S beträgt bei einem Zieldatum von drei Tagen (3D) etwa 0,3% und bleibt auch nach einer Woche (1W) unverändert. Nach zwei Wochen (2W) steigt dieser Wert auf über 0,5%. Die Mittelwerte für die Gruppen M und L sind über alle betrachteten Zeiträume hinweg niedrig. Für die Gruppe M zeigen die Werte sowohl nach drei Tagen als auch nach einer Woche geringfügig negative Tendenzen, nach zwei Wochen liegt der Mittelwert über 0,05%. Ein ähnliches Muster zeigt sich bei der Gruppe L, wobei die Werte für drei Tage und eine Woche geringfügig negativ sind und nach zwei Wochen bei knapp 0,01% liegen.

Die Standardabweichung zeigt einen abnehmenden Trend von Gruppe S bis Gruppe L, während die Standardabweichung mit zunehmendem Zieldatum steigt. Kürzere Zeiträume weisen dabei geringere Standardabweichungen auf, während längere Zeiträume höhere Standardabweichungen zeigen. Für die Gruppe S beträgt die Standardabweichung nach drei Tagen etwa 7,0%, nach einer Woche über 10,0% und nach zwei Wochen nahezu 16,0%. Die Vergleichswerte für die Gruppe M liegen bei etwa 5,0% für drei Tage, über 6,0% für eine Woche und über 8,0% für zwei Wochen. Gruppe L zeigt nahezu identische, jedoch geringfügig niedrigere Werte im Vergleich zur Gruppe M.

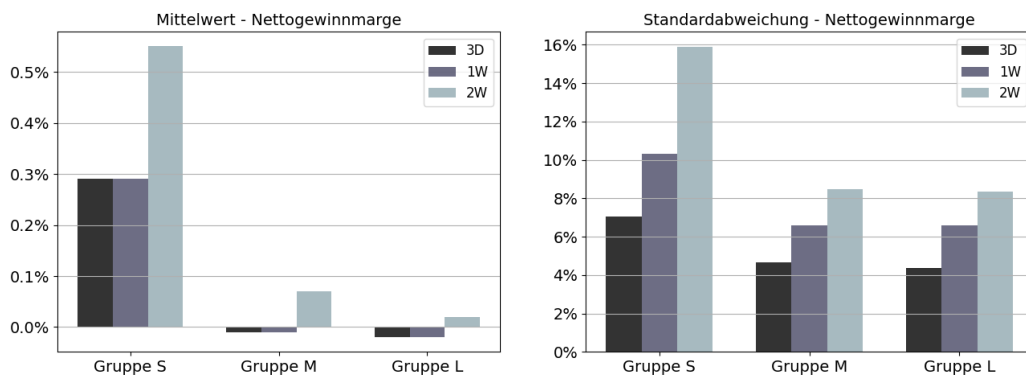


Abbildung 6.6.: Mittelwert für Nettogewinnmarge nach Gruppen und Zieldaten

Abbildung 6.7.: Std.Abw. für Nettogewinnmarge nach Gruppen und Zieldaten

## Dividendenrendite

Die folgende Abbildung 6.8 zeigt den Mittelwert (*Baseline*) der Dividendenrendite, gegliedert nach den verschiedenen Gruppen und Zeiträumen. Ergänzend dazu zeigt Abbildung 6.9 die Standardabweichung der Dividendenrendite, ebenfalls aufgeteilt nach den gleichen Kriterien.

Gruppe S ist unter Anbetracht der Dividendenrendite, die einzige Gruppe, die über alle betrachteten Zeiträume hinweg positive Mittelwerte aufweist. Knapp 0,1% für drei Tage (3D), etwas über 0,1% für eine Woche (1W) und mehr als 0,2% für zwei Wochen (2W). Für Gruppe M wird ein negativer Wert von etwa -0,05% für drei Tage, über -0,1% für eine Woche und mehr als -0,2% für zwei Wochen verzeichnet. Gruppe L zeigt, ähnlich wie Gruppe M, ausschließlich negative Werte, die sich über alle betrachteten Zieldaten von drei Tagen bis hin zu zwei Wochen hinweg auf etwa -0,06% belaufen.

Hinsichtlich der Standardabweichung ergibt sich ein ähnliches Bild wie zuvor, wobei die Werte mit zunehmendem Zeithorizont für jede Gruppe ansteigen. Gruppe S verzeichnet bei drei Tagen einen Wert von circa 7,5%, bei einer Woche über 10,0% und bei zwei Wochen nahezu 14,0%. Die Gruppe M zeigt durchweg niedrigere Werte als die vorausgehende Gruppe S. Diesbezüglich sind für einen Zeitraum von drei Tagen Werte unter 4,0%, für eine Woche Werte über 5,0% und für zwei Wochen Werte von circa 8,0% zu verzeichnen. Gruppe L weist fast identische Werte wie Gruppe M auf, die allerdings für jeden betrachteten Zeitraum minimal höher sind.




Abbildung 6.8.: Mittelwert für Dividendenrendite nach Gruppen und Zieldaten




Abbildung 6.9.: Std.Abw. für Dividendenrendite nach Gruppen und Zieldaten

## 6.2. Resultate Marktkapitalisierung

In den Ergebnismatrizen 6.10 und 6.11 zeigt sich, dass die Gruppe S bei einem Zieldatum von zwei Wochen (2W) in beiden Kategorien die höchsten Werte aufweist. Die Gruppe hat für dieses Zieldatum einen Mittelwert von 2,48% und einen Medianwert von 1,76%, womit sie die Vergleichswerte der anderen Gruppen übertrifft. Bemerkenswert sind zudem die übrigen Mittelwerte der Gruppe S, die im Vergleich zu den anderen Gruppen ebenfalls höhere Werte aufweisen. Auch für das Zieldatum von drei Tagen (3D) überschreiten die Werte der Gruppe S die Ein-Prozent-Marke, wobei die Medianwerte dies etwas relativieren. Die Definition der Gruppengrenzen für die Marktkapitalisierung ist in der Methodik unter Abschnitt 3.1.1 zu finden.

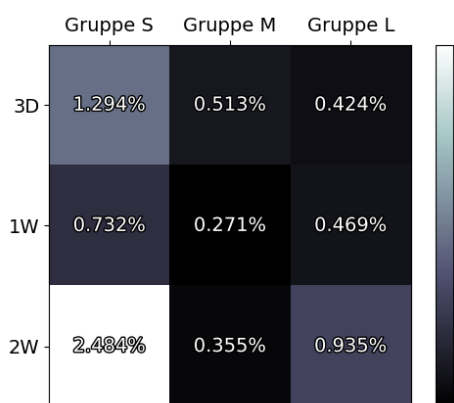


Abbildung 6.10.: Mittelwert der Summe für die Marktkapitalisierung




Abbildung 6.11.: Median der Summe für die Marktkapitalisierung

### Drei Tage (3D)

In Tabelle 6.3 sind die Ergebnisse für ein Zieldatum von drei Tagen (3D) dargestellt. Dabei zeigt sich eine Relativierung der Resultate unter Berücksichtigung des Medians. Trotz hoher Mittelwerte in der Summe, sowie für die einzelnen Signale, spiegeln sich diese nicht im Median wider, der eher Werte näher null aufweist.

Gruppe S zeigt mit den Ergebnissen auf, dass der Mittelwert in der Summe für das dreitägige Zieldatum der höchste unter den betrachteten Gruppen ist. Eine Diskrepanz zwischen Mittelwert und Median ist insbesondere bei den Kaufsignalen (*Buy*) der Gruppe S zu beobachten, wo die Differenz mehr als ein Prozent beträgt: Der Mittelwert

liegt bei 0,82%, der Median bei -0,20%. Die Verkaufssignale (*Sell*) dieser Gruppe zeigen sowohl im Mittelwert als auch im Median nur geringe Abweichungen

Gruppe M erzielt sowohl im Mittelwert als auch im Median positive Ergebnisse, mit 0,51% und 0,28% entsprechend. Der Median führt jedoch zu einer Anpassung der Ergebnisse in Richtung null, was besonders bei den Verkaufssignalen auffällt, die von -0,29% auf -0,06% sinken. Die Kaufsignale dieser Gruppe zeigen eine minimale Differenz von 0,01% und bleiben im Bereich von 0,22% bis 0,23%.

Gruppe L weist sowohl im Mittelwert als auch im Median positive Ergebnisse auf, liegt jedoch mit 0,42% und 0,15% an letzter Stelle der drei betrachteten Gruppen für dieses Zieldatum. Die Unterschiede zwischen Mittelwert und Median sind sowohl bei den Kaufsignalen, die von 0,16% auf 0,06% fallen, als auch bei den Verkaufssignalen zu erkennen, die von -0,26% auf -0,09% ansteigen.

Signal	Gruppe	Mittelwert	Median
Buy-Signale	S	0,8236%	-0,2000%
Sell-Signale	S	-0,4703%	-0,4020%
Summe	S	<b>1,2939%</b>	0,2021%
Buy-Signale	M	0,2239%	0,2192%
Sell-Signale	M	-0,2886%	-0,0574%
Summe	M	0,5125%	<b>0,2765%</b>
Buy-Signale	L	0,1633%	0,0636%
Sell-Signale	L	-0,2604%	-0,0884%
Summe	L	0,4238%	0,1521%

Tabelle 6.3.: Ergebnisse für Marktkapitalisierung nach Signal und Gruppe (3D)

### Eine Woche (1W)

In den Ergebnissen, die in Tabelle 6.4 für ein Zieldatum von einer Woche (1W) präsentiert werden, lässt sich ähnlich zu den Beobachtungen des Drei-Tage-Ziels eine Diskrepanz zwischen dem Mittelwert und dem Median feststellen, wobei der Median der Summenergebnisse stärker in Richtung null tendiert.

Gruppe S erzielt den höchsten mittleren Summenwert unter den untersuchten Gruppen für das Zieldatum von einer Woche, mit einem Wert von 0,73%. Auch der Medianwert erreicht mit 0,37% den höchsten Wert in dieser Kategorie. Diese Differenz zwischen

den beiden Werten lässt sich auf die zugehörigen Kaufsignale (*Buy*) zurückführen, bei denen der Mittelwert von 0,33% auf einen Medianwert von -0,15% fällt. Eine weitere Beobachtung liegt bei den Verkaufssignalen (*Sell*) vor, dessen Mittelwert von -0,40% sich auf einen Medianwert von -0,52% verschiebt, was eine Abweichung zu der allgemeinen Tendenzen des Medians darstellt.

Gruppe M verzeichnet sowohl im Mittel als auch im Median die niedrigste Summe mit 0,27% beziehungsweise -0,02%. Eine signifikante Differenz zeigt sich bei den Kaufsignalen, die einen Mittelwert von 0,45% und einen Median von 0,27% aufweisen, einem Unterschied von knapp 0,20%. Diese Gruppe weist damit die niedrigste Gesamtsumme auf, dass lässt sich darauf zurückführen, dass der Mittelwert der Verkaufssignale von 0,18% auf einen Median von 0,29% gestiegen ist.

Gruppe L positioniert sich mit einem Mittelwert von 0,47% und einem Median von 0,13% im mittleren Bereich der Ergebnisse für das einwöchige Zieldatum. Der Mittel- und der Medianwert der Kaufsignale zeigen geringfügige Unterschiede, mit Werten von 0,33% und 0,34%. Die Differenz in der Summe ist in diesem Fall insbesondere den Verkaufssignalen zuzuschreiben, bei denen der Mittelwert von -0,14% auf einen Medianwert von 0,22% ansteigt.

Signal	Gruppe	Mittelwert	Median
Buy-Signale	S	0,3289%	-0,1504%
Sell-Signale	S	-0,4031%	-0,5169%
Summe	S	<b>0,7320%</b>	<b>0,3665%</b>
Buy-Signale	M	0,4500%	0,2729%
Sell-Signale	M	0,1794%	0,2895%
Summe	M	0,2706%	-0,0166%
Buy-Signale	L	0,3273%	0,3419%
Sell-Signale	L	-0,1412%	0,2157%
Summe	L	0,4685%	0,1262%

Tabelle 6.4.: Ergebnisse für Marktkapitalisierung nach Signal und Gruppe (1W)

### Zwei Wochen (2W)

Die in Tabelle 6.5 dargestellten Ergebnisse zeigen weiterhin die gleiche fortlaufende Tendenz wie bei den vorherigen Zieldaten. Dabei passt der Median in den meisten



Fällen den Mittelwert in Richtung null an. Diese Relativierung ist insbesondere bei den höheren Mittelwerten stärker zu beobachten.

Gruppe S weist die höchsten Werte sowohl im Mittel als auch im Median auf, mit 2,48% beziehungsweise 1,76%. Diese Differenz resultiert hauptsächlich aus den Kaufsignalen (*Buy*), die von einem Mittelwert von 1,63% auf einen Median von 0,55% fallen, eine Differenz von mehr als einem Prozentpunkt. Im Gegensatz zu der fortlaufenden Tendenz, dass der Median den Mittelwert in Richtung null relativiert, fällt in diesem Fall der Mittelwert der Verkaufssignale (*Sell*) von -0,85% auf -1,21%.

Gruppe M weist für das zweiwöchige Zieldatum sowohl beim Durchschnitt als auch beim Median die geringsten Werte in beiden Kategorien auf, mit 0,36% beziehungsweise 0,37%. Trotz des nahezu identischen Summenergebnisses weisen die einzelnen Signale Unterschiede zwischen Mittel- und Medianwerten auf. So sinken die Kaufsignale im Durchschnitt von 0,72% auf einen Median von 0,56%, während die Verkaufssignale von einem Mittelwert von 0,36% auf einen Median von 0,19% reduziert werden.

Gruppe L positioniert sich hinsichtlich der Summenergebnisse im Mittelfeld der betrachteten Gruppen für dieses Zieldatum, mit einem Durchschnitt von 0,94% und einem Median von 0,69%. Die Kaufsignale zeigen eine minimale Diskrepanz zwischen Durchschnitt und Median mit 0,45% beziehungsweise 0,54%, was einem Unterschied von weniger als 0,10% entspricht. Die Verkaufssignale hingegen zeigen eine deutlich größere Differenz, von einem Durchschnitt von -0,48% zu einem Median von -0,15%, was eine Differenz von mehr als 0,30% darstellt.

Signal	Gruppe	Mittelwert	Median
Buy-Signale	S	1,6302%	0,5512%
Sell-Signale	S	-0,8536%	-1,2083%
Summe	S	<b>2,4838%</b>	<b>1,7594%</b>
Buy-Signale	M	0,7161%	0,5600%
Sell-Signale	M	0,3611%	0,1927%
Summe	M	0,3549%	0,3672%
Buy-Signale	L	0,4518%	0,5347%
Sell-Signale	L	-0,4837%	-0,1515%
Summe	L	0,9354%	0,6862%

Tabelle 6.5.: Ergebnisse für Marktkapitalisierung nach Signal und Gruppe (2W)

### 6.3. Resultate Nettogewinnmarge

Die in den Ergebnismatrizen 6.12 und 6.13 dargestellten Werte zeigen für Gruppe S zum Zieldatum von zwei Wochen (2W) verhältnismäßig hohe Werte, ähnlich wie bei der vorherigen Untersuchung der Marktkapitalisierung. Es wird ein durchschnittlicher Gewinn von etwa 1,60% verzeichnet, während der Medianwert bei etwa 0,74% liegt. Generell sind die Werte überwiegend positiv, und die Ergebnisse der verschiedenen Gruppen liegen tendenziell höher als die Ergebnisse der vorherigen Kennzahl. Auffällig ist zudem, dass bei Gruppen und Zieldaten mit höheren Durchschnittswerten der Median tendenziell geringer ist. Die Definition der Gruppengrenzen für die Nettogewinnmarge ist in der Methodik unter Abschnitt 3.1.2 zu finden.

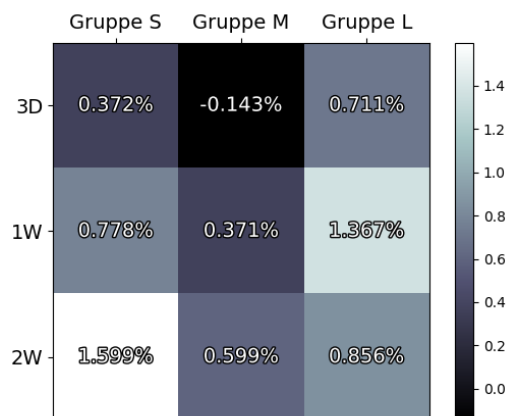


Abbildung 6.12.: Mittelwert der Summe für die Nettogewinnmarge




Abbildung 6.13.: Median der Summe für die Nettogewinnmarge

#### Drei Tage (3D)

In der nachstehenden Tabelle 6.6 sind die Ergebnisse bezüglich des Zieldatums von drei Tagen (3D) präsentiert. Es zeigt sich konstant, dass der Median im Vergleich zum Durchschnitt die Werte näher an den Nullpunkt rückt, ein Trend, der sich aus den vorherigen Ergebnissen fortsetzt.

Gruppe S positioniert sich mit den Summenergebnissen im mittleren Bereich des Spektrums für beide Ergebnistypen, mit einem Mittelwert von 0,37% und einem Median von 0,17%. Die Differenz zwischen dem Mittelwert der Kaufsignale (*Buy*) und dem Median dieser beträgt mehr als 0,50%, mit einem Abfall von 0,87% auf 0,35%. Die Resultate der Verkaufssignale (*Sell*) befinden sich im positiven Wertebereich, was

für diese als negativ zu bewerten ist. Sie nähern sich jedoch der Nulllinie an, indem der Durchschnitt von 0,49% auf einen Median von 0,18% abfällt.

Gruppe M zeichnet sich dadurch aus, dass sowohl der Mittelwert als auch der Median der Summe erstmalig im negativen Bereich angesiedelt sind, mit Werten von -0,14% für den Durchschnitt und -0,02% für den Median. Diese Beobachtung ist auf die negativen Resultate der Kaufsignale zurückzuführen, die eine Differenz von mehr als 0,20% zwischen dem Mittelwert (-0,26%) und dem Median (-0,03%) aufweisen. Die Verkaufssignale zeigen eine moderate Spanne zwischen -0,11% und -0,01%.

Gruppe L führt bezüglich beider Summen mit einem Mittelwert von 0,71% und einem Median von 0,22%. Die Differenz zwischen diesen beiden Werten lässt sich direkt auf die Kaufsignale zurückführen, welche eine Diskrepanz von mehr als 0,40% zwischen dem Mittelwert (0,42%) und dem Median (-0,03%) erkennen lassen. Die Ergebnisse der Verkaufssignale fallen von -0,29% auf -0,24% und weisen somit nur eine geringfügige Abweichung von 0,05% auf.

Signal	Gruppe	Mittelwert	Median
Buy-Signale	S	0,8652%	0,3472%
Sell-Signale	S	0,4937%	0,1811%
Summe	S	0,3715%	0,1661%
Buy-Signale	M	-0,2551%	-0,0285%
Sell-Signale	M	-0,1123%	-0,0078%
Summe	M	-0,1427%	-0,0207%
Buy-Signale	L	0,4240%	-0,0285%
Sell-Signale	L	-0,2862%	-0,2440%
Summe	L	<b>0,7102%</b>	<b>0,2154%</b>

Tabelle 6.6.: Ergebnisse für Nettogewinnmarge nach Signal und Gruppe (3D)

### Eine Woche (1W)

In Tabelle 6.7 werden die Ergebnisse für das Zieldatum von einer Woche (1W) dargestellt. Auffällig ist, dass der Median, insbesondere bei hohen Durchschnittswerten, die Ergebnisse in Richtung null anpasst, mit Ausnahme der Summen für Gruppe M.

Gruppe S weist den höchsten Medianwert der Summe für das Zieldatum von einer Woche auf, mit 0,61%. Der entsprechende Mittelwert liegt bei 0,78%. Die Differenz

zwischen diesen beiden Werten ist somit geringer im Vergleich zu anderen betrachteten Ergebnissen. Im Einzelnen betragen die Ergebnisse für Kaufsignale (*Buy*) im Durchschnitt 1,25% und im Median 0,91%. Die Werte der Verkaufssignale (*Sell*) zeigen durchschnittlich einen negativen Wert von 0,47% und eine Mediananpassung näher an null mit einem Wert von 0,30%.

Gruppe M weist den niedrigsten Summenwert für das betrachtete Zielfeld auf, wobei sich Durchschnitt und Median auf 0,37% und 0,44% belaufen. Die zugehörigen Resultate für Kauf- und Verkaufssignale zeigen, ähnlich wie die Summen, nur geringe Differenzen zwischen Durchschnitt und Median. Im Detail betragen die Mittelwerte für Kaufsignale 0,24% und für den Median 0,33%. Die Verkaufssignale weisen eine minimale Differenz auf, mit einem Mittel von -0,13% und einem Median von -0,10%.

Gruppe L präsentiert hingegen den höchsten Mittelwert unter den Summenergebnissen mit 1,37%, während sich der Medianwert mit 0,60% knapp hinter dem der Gruppe S einreihet. Besonders auffällig ist die vergleichsweise hohe Differenz zwischen Mittelwert und Median in dieser Gruppe, insbesondere bei den Kaufsignalen, wo der Durchschnitt 0,79% und der Median lediglich 0,27% beträgt. Die Resultate für Verkaufssignale innerhalb dieser Gruppe zeigen eine Abweichung von etwa 0,15%, mit einem Mittelwert von -0,58% und einem Medianwert von -0,33%.

Signal	Gruppe	Mittelwert	Median
Buy-Signale	S	1,2472%	0,9135%
Sell-Signale	S	0,4689%	0,2995%
Summe	S	0,7783%	<b>0,6139%</b>
Buy-Signale	M	0,2370%	0,3325%
Sell-Signale	M	-0,1343%	-0,1031%
Summe	M	0,3713%	0,4356%
Buy-Signale	L	0,7895%	0,2729%
Sell-Signale	L	-0,5770%	-0,3284%
Summe	L	<b>1,3666%</b>	0,6012%

Tabelle 6.7.: Ergebnisse für Nettogewinnmarge nach Signal und Gruppe (1W)

### Zwei Wochen (2W)

In Tabelle 6.8 sind die Ergebnisse für das Zielfeld von zwei Wochen (2W) aufgeführt. Der Median zeigt erneut eine relativierte Summe in Richtung null, wiederholend mit

Ausnahme der Gruppe M, wo der Medianwert leicht höher als der Mittelwert ist.

Gruppe S hat sowohl den höchsten durchschnittlichen Summenwert mit 1,60% als auch den höchsten Medianwert mit 0,74%. Besonders hervorzuheben ist die signifikante Differenz zwischen den Werten der Kaufsignale (*Buy*), mit einem Durchschnitt von 1,89% und einem Median von 0,52%, was eine Diskrepanz von über 1% ergibt. Auch bei den Verkaufssignalen (*Sell*) ist eine Differenz von annähernd 0,50% zu verzeichnen, mit einem Mittelwert von 0,29% und einem Median von -0,22%.

Gruppe M zeigt mit ihren Ergebnissen eine Abweichung von der allgemeinen Tendenz, wonach der Mittelwert höher als der Median ist. Der mittlere Summenwert liegt bei 0,60%, während der Median mit 0,72% höher ist. Anders als bei den bisherigen Beobachtungen, bei denen der Median in der Regel unter dem Mittelwert lag, ist hier das Gegenteil der Fall. Dieser Trend setzt sich sowohl bei den Kaufsignalen, mit einem Mittel von 0,51% und einem Median von 0,59%, als auch bei den Verkaufssignalen, mit einem Mittel von -0,08% und einem Median von -0,13%, fort.

Gruppe L verzeichnet bei der Summe ein Durchschnittsergebnis von 0,86% und einen Median von 0,60%. Der Hauptbeitrag zu diesem Ergebnis stammt von den Kaufsignalen, die einen Mittelwert von 0,63% und einen Median von 0,51% aufweisen, eine vergleichsweise geringe Differenz. Die Verkaufssignale tragen in geringerem Maße zur Summe bei, mit einem Mittelwert von -0,22% und einen Median von -0,08%, was einer Differenz von knapp 0,15% zwischen diesen beiden Werten ergibt.

Signal	Gruppe	Mittelwert	Median
Buy-Signale	S	1,8872%	0,5200%
Sell-Signale	S	0,2883%	-0,2242%
Summe	S	<b>1,5989%</b>	<b>0,7442%</b>
Buy-Signale	M	0,5163%	0,5891%
Sell-Signale	M	-0,0822%	-0,1269%
Summe	M	0,5985%	0,7160%
Buy-Signale	L	0,6316%	0,5052%
Sell-Signale	L	-0,2243%	-0,0871%
Summe	L	0,8560%	0,5923%

Tabelle 6.8.: Ergebnisse für Nettogewinnmarge nach Signal und Gruppe (2W)

## 6.4. Resultate Dividendenrendite

Wie in den Ergebnismatrizen, dargestellt in den Abbildungen 6.14 und 6.15, ersichtlich ist, erzielt die Gruppe S hohe Werte, insbesondere bei einem Zieldatum von zwei Wochen. Mit einem durchschnittlichen Anstieg von etwa 2,48% und einem Medianwert von circa 1,43% heben sich diese Ergebnisse deutlich von den übrigen Daten ab. Im Gegensatz dazu zeigt Gruppe L in den Zeitspannen von drei Tagen und einer Woche sowohl im Mittelwert als auch im Median negative Werte. Der Median liegt bei den höheren Ergebnissen signifikant niedriger als die Mittelwerte, bleibt jedoch bei moderaten Werten relativ konstant. Die Definition der Gruppengrenzen für die Dividendenrendite ist im Abschnitt 3.1.3 der Methodik zu finden.




Abbildung 6.14.: Mittelwert der Summe für die Dividendenrendite

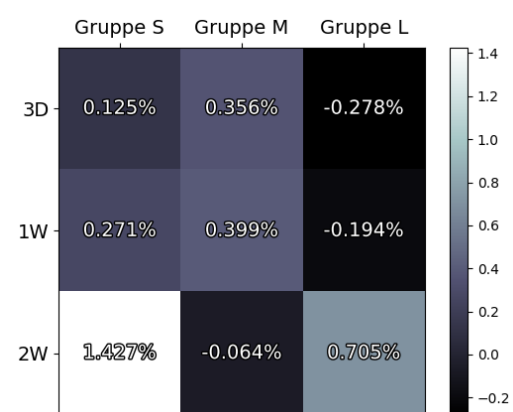


Abbildung 6.15.: Median der Summe für die Dividendenrendite

### Drei Tage (3D)

In der Tabelle 6.9 sind die Ergebnisse für das dreitägiges (3D) Zieldatum dargestellt. Mit Ausnahme der Summenergebnisse der Gruppe L, tendiert der Median der Ergebnisse weiterhin mehr in Richtung null, als im Vergleich zu den Mittelwerten der Ergebnisse.

Gruppe S sticht hervor, da der Mittelwert von 0,93% im Vergleich zum Medianwert auf 0,13% fällt. Diese große Abweichung von 0,80% ist hauptsächlich auf die Ergebnisse der Kaufsignale (*Buy*) zurückzuführen, bei denen der Mittelwert von 0,70% auf einen Medianwert von nur 0,16% sinkt. Hinsichtlich der Verkaufssignale (*Sell*) ist eine Verschiebung des Mittelwert von -0,23% auf einen Medianwert von 0,03%

zu verzeichnen, was einer Differenz von circa 0,25% entspricht. Innerhalb des hier betrachteten Zieldatums weist die Gruppe S den höchsten Mittelwert auf.

Gruppe M zeigt geringere Abweichungen zwischen Median und Mittelwert. Die Summe zeigt einen Mittelwert von 0,39% und einen nahezu äquivalenten Medianwert von 0,36%. Die Kaufsignale weisen eine geringe Differenz auf, dabei liegt das Durchschnittsergebnis bei 0,14%, während der Medianwert mit 0,18% leicht darüber liegt. Die Ergebnisse der Verkaufssignale befinden sich im Durchschnitt bei -0,26% und im Median bei -0,17%, was einer Differenz von weniger als 0,10% entspricht.

Gruppe L hingegen zeigt sowohl bei den Kauf- als auch bei den Verkaufssignalen durchgängig negative Werte, mit einer Summe im Durchschnitt von -0,20% und einem Median von -0,28%. Insbesondere die Kaufsignale weisen mit einem Mittelwert von -0,36% und einem Median von -0,34% negative Ergebnisse auf. Im Fall der Verkaufssignale liegt der Mittelwert bei -0,17% und der Median bei -0,06%, was einer Differenz von etwa 0,10% entspricht.

Signal	Gruppe	Mittelwert	Median
Buy-Signale	S	0,7003%	0,1608%
Sell-Signale	S	-0,2291%	0,0356%
Summe	S	<b>0,9294%</b>	0,1252%
Buy-Signale	M	0,1369%	0,1815%
Sell-Signale	M	-0,2551%	-0,1741%
Summe	M	0,3921%	<b>0,3556%</b>
Buy-Signale	L	-0,3634%	-0,3373%
Sell-Signale	L	-0,1675%	-0,0595%
Summe	L	-0,1959%	-0,2778%

Tabelle 6.9.: Ergebnisse für Dividendenrendite nach Signal und Gruppe (3D)

### Eine Woche (1W)

In der Tabelle 6.10, die die Ergebnisse für das einwöchige (1W) Zieldatum aufführt, wird weiterhin deutlich, dass der Median insbesondere bei höheren Mittelwerten stärker in Richtung null tendiert. Dabei stellt Gruppe L, wie zuvor beim dreitägigen Zieldatum, eine Ausnahme dar.

Gruppe S zeigt einen relativ großen Unterschied zwischen dem Durchschnittsergebnis von 1,08% und dem Median von 0,27% auf, was eine Differenz von über 0,80% darstellt. Der Mittelwert repräsentiert den höchsten Wert für das analysierte Zieldatum. Die zugehörigen Kaufsignale (*Buy*) weisen einen Mittelwert von 1,16% und einen Median von 0,64% auf, eine Differenz von mehr als 0,50%. Die Verkaufssignale (*Sell*) zeigen einen Mittelwert von 0,08% und einen Median von 0,37%, was einer Differenz von etwa 0,30% entspricht.

Gruppe M befindet sich mit dem zugehörigen Summenergebnis im Mittelfeld, mit einem Mittelwert von 0,45% und einem Median von 0,40%, was eine geringfügige Differenz von 0,05% entspricht. Bei den Kaufsignalen liegen sowohl der Mittelwert als auch der Median bei etwa 0,29%. Bei den Verkaufssignalen besteht eine kleine Differenz von 0,04%, mit einem Mittelwert von -0,15% und einem Median von -0,11%.

Gruppe L zeigt, ähnlich wie beim zuvor diskutierten dreitägigen Zieldatum, in beiden Kategorien negative Werte und verzeichnet somit die niedrigsten Ergebnisse für das betrachtete Zieldatum. Der Mittelwert beläuft sich auf -0,09% und der Median auf -0,19%. Die vorrangig negative Summe stammt hauptsächlich aus den negativen Kaufsignalen, mit einem Mittelwert von -0,25% und einem Median von -0,30%. Die Verkaufssignale ergeben einen Mittelwert von -0,16% und einen Median von -0,11%.

Signal	Gruppe	Mittelwert	Median
Buy-Signale	S	1,1618%	0,6370%
Sell-Signale	S	0,0834%	0,3664%
Summe	S	<b>1,0784%</b>	0,2706%
Buy-Signale	M	0,2958%	0,2873%
Sell-Signale	M	-0,1525%	-0,1113%
Summe	M	0,4482%	<b>0,3987%</b>
Buy-Signale	L	-0,2524%	-0,3018%
Sell-Signale	L	-0,1632%	-0,1077%
Summe	L	-0,0892%	-0,1941%

Tabelle 6.10.: Ergebnisse für Dividendenrendite nach Signal und Gruppe (1W)

### Zwei Wochen (2W)

In der Tabelle 6.11 werden die Resultate für das zweiwöchige (2W) Zieldatum präsentiert. Im Gegensatz zu den vorangegangenen Vergleichen ist die Tendenz, dass



sich der Median mehr gegen null bewegt, in diesem Kontext nicht mehr so konsistent festzustellen, weder bei der Summe noch bei den einzelnen Signalergebnissen.

Gruppe S erreicht mit einem durchschnittlichen Ergebnis von 2,49% den Höchstwert für das spezifisch betrachtete zweiwöchige Zieldatum und bestätigt diese Spitzenposition auch über sämtliche untersuchten Kennzahlen und Zieldaten hinweg. Der Median der Summe für Gruppe S liegt bei 1,43%, was ebenfalls diese führende Position unterstreicht. Ein wesentlicher Beitrag zu diesem Ergebnis kommt von den Kaufsignalen (*Buy*), die einen Mittelwert von 2,46% und einen Median von 1,14% aufweisen, was den überwiegenden Anteil der positiven Differenz in der Summe ausmacht. Im Gegensatz dazu liegen die Ergebnisse der Verkaufssignale (*Sell*) bei einem durchschnittlichen Wert von -0,02% und einem Median von -0,29%.

Gruppe M hingegen zeigt die niedrigsten Mittel- und Medianwerte für das betrachtete Zieldatum. Die durchschnittliche Summe beträgt hier 0,22%, während der Median bei -0,06% liegt. Diese Zahlen spiegeln sich vor allem in den Ergebnissen der Kaufsignale wider, die einen Mittelwert von -0,20% und einen Median von -0,48% aufweisen, was eine Differenz von 0,28% ergibt. Die Resultate der Verkaufssignale in dieser Gruppe sind mit einem Mittelwert und Median von -0,42% nahezu identisch.

Gruppe L zeigt, dass die durchschnittliche Summe mit 0,41% niedriger ausfällt als der Median von 0,71%, was eine Differenz von 0,30% ausmacht. Diese Differenz wird überwiegend durch die Ergebnisse der Kaufsignale verursacht, die einen Durchschnitt von -0,01% gegenüber einem Median von 0,38% aufweisen. Die Verkaufssignale dieser Gruppe zeigen lediglich eine geringe Diskrepanz von knapp 0,10%, mit einem Durchschnittswert von -0,42% und einem Median von -0,32%.

Signal	Gruppe	Mittelwert	Median
Buy-Signale	S	2,4591%	1,1372%
Sell-Signale	S	-0,0280%	-0,2899%
Summe	S	<b>2,4870%</b>	<b>1,4271%</b>
Buy-Signale	M	-0,2014%	-0,4802%
Sell-Signale	M	-0,4233%	-0,4160%
Summe	M	0,2219%	-0,0642%
Buy-Signale	L	-0,0050%	0,3825%
Sell-Signale	L	-0,4169%	-0,3227%
Summe	L	0,4119%	0,7052%

Tabelle 6.11.: Ergebnisse für Dividendenrendite nach Signal und Gruppe (2W)

## 6.5. Signalgenauigkeit

In diesem Abschnitt erfolgt die Darstellung der Präzision der Signale, unterteilt nach Gruppe und nach den Signalen Kauf und Verkauf, sowie der Summe. Hierbei wird eine differenzierte Betrachtung zwischen den drei Kennzahlen vorgenommen.

In Tabelle 6.12 wird die Signalgenauigkeit, unter Berücksichtigung der Marktkapitalisierung, dargestellt. Es ist erkennbar, dass Gruppe S und Gruppe L mit lediglich einem Treffer Unterschied, vor der Gruppe M positioniert sind, beide mit einer Trefferquote von knappen 90%. Gruppe M weist mit fünf absoluten Fehlern eine etwas niedrigere Trefferquote auf, die umgerechnet 72,2% beträgt. Die Genauigkeit der Kaufsignale liegt bei 88,9%, während die der Verkaufssignale bei 72,2% verzeichnet wird. Die Summe, mit nur einem absoluten Fehler, beläuft sich dahingegen auf 94,4%.

	Buy-Signale	Sell-Signale	Summe	Score
Gruppe S	4/6	6/6	6/6	88,9%
Gruppe M	6/6	2/6	5/6	72,2%
Gruppe L	6/6	5/6	6/6	<b>94,4%</b>
Score	88,9%	72,2%	94,4%	

Tabelle 6.12.: Signalgenauigkeit für Marktkapitalisierung nach Signal und Gruppe

Aufgeführt in Tabelle 6.13 wird die Genauigkeit der Signale für die Nettogewinnmarge. Dabei zeigt Gruppe S die geringste Genauigkeit mit 72,2%, was fünf absoluten Fehlern entspricht. Dabei resultieren alle diese Fehler aus den Verkaufssignalen. Gruppe M verzeichnet mit vier absoluten Fehlern eine leicht höhere Genauigkeit, die 77,8% beträgt. An der Spitze steht Gruppe L mit einer Trefferquote von 94,4%, basierend auf einem Fehler bei den Kaufsignalen. Die Beobachtung, dass alle Fehler der Gruppe S den Verkaufssignalen zuzuordnen sind, findet in deren kombinierten Trefferquote eine Entsprechung, die ebenfalls 72,2% ausmacht. Die Trefferquote der Kaufsignale liegt bei 83,3%, während die Summe mit zwei Fehlern eine Trefferquote von 88,9% hat.

	Buy-Signale	Sell-Signale	Summe	Score
Gruppe S	6/6	1/6	6/6	72,2%
Gruppe M	4/6	6/6	4/6	77,8%
Gruppe L	5/6	6/6	6/6	<b>94,4%</b>
Score	83,3%	72,2%	88,9%	

Tabelle 6.13.: Signalgenauigkeit für Nettogewinnmarge nach Signal und Gruppe

Abschließend wird in der Tabelle 6.14 die Signalgenauigkeit für die Dividendenrendite dargestellt. Gruppe S und Gruppe M erreichen mit jeweils 83,3% Genauigkeit, was drei absoluten Fehler entspricht, die höchste Trefferquote. Im Gegensatz dazu weist Gruppe L mit lediglich 50,0% Genauigkeit, acht absolute Fehlern, den niedrigsten Wert sowohl in dieser Kategorie als auch übergreifend über alle Kennzahlen auf. Dieses Ergebnis lässt sich aus fünf fehlerhaften Ergebnissen der Kaufsignale und vier Fehlern bei den Ergebnissen der Summe ableiten. Die Trefferquote der Kaufsignale liegt bei 61,1%, was aus sechs absoluten Fehlern stammt, während die Summe eine Genauigkeit von 72,2% aufzeigen. Die Verkaufssignale stehen bei einer Genauigkeit von 83,3%.

	Buy-Signale	Sell-Signale	Summe	Score
Gruppe S	6/6	3/6	6/6	<b>83,3%</b>
Gruppe M	4/6	6/6	5/6	<b>83,3%</b>
Gruppe L	1/6	6/6	2/6	50,0%
Score	61,1%	83,3%	72,2%	

Tabelle 6.14.: Signalgenauigkeit für Dividendenrendite nach Signal und Gruppe

## 7. Diskussion

In diesem Kapitel werden die Ergebnisse aus Kapitel 6 aufgegriffen und interpretiert. Zudem wird versucht, Erklärungen für diese Resultate zu finden. Anschließend werden die Einschränkungen sowie die bekannten Risiken und Probleme des Projekts diskutiert, die für die Einordnung und Relativierung der Ergebnisse relevant sind.

### 7.1. Interpretation

Bei der Darstellung der Verteilung der vorhergesagten sowie der realen Kursänderungen ist besonders die Differenzierung der Vorhersagen des einwöchigen Zieldatums von den anderen beiden Zieldaten, drei Tage und zwei Wochen, visuell stark erkennbar. Während die Verteilungen der beiden letzteren rechtsschief ist, mit einem Maximum bei etwa 600 bis 700 Vorkommnissen, weist die Verteilung des einwöchigen Zieldatums ein anderes Muster auf. Diese kann auch als rechtsschief angesehen werden, jedoch mit einem deutlich steileren Anstieg und einem Höhepunkt bei circa 1.750 Vorkommnissen, gefolgt von einem raschen Abfall, mit einem anschließenden langem Schweif. Diese Daten wurden aus den exemplarischen Grafiken 6.1, 6.2 und 6.3 genommen, zu finden im Kapitel 6.1.2. Diese Ergebnisse sind repräsentativ für alle weiteren Histogramme im Anhang A und über alle Gruppen, Kennzahlen und Zieldaten gültig. Die genaue Ursache dieser Differenzierung und des visuellen Unterschiedes des einwöchigen Zieldatum kann nicht auf ein einzelnes Kriterium reduziert werden, zur Bestimmung sind detaillierte Analysen erforderlich. Der technische Aspekt dieses Ergebnisses wurde validiert, sodass die auffällige Darstellung auf die Natur der Domäne zurückzuführen ist. Für weitere Untersuchungen ist die Expertise einer Person erforderlich, die mit der Domäne vertraut ist. Festzuhalten ist jedoch, dass dies vermutlich auf Faktoren wie Marktreaktionszeit, Volatilität und die Dynamik der Nachrichten zurückzuführen ist.

Bei der Analyse der *Baseline*-Bewegung, der durchschnittlichen realen Kursänderung einer Aktie je Gruppe, zeigt sich, dass die Abweichung von Null umso größer ist, je weiter das Zieldatum in der Zukunft liegt. Diese Erkenntnis lässt sich darauf zurückführen, dass die Streuung und die nebenstehende Standardabweichung umso größer wird, je größer der zeitliche Abstand zwischen den betrachteten Zeitpunkten ist. Neben der Differenzierung zwischen verschiedenen Zieldaten ist weiterführend erkennbar, dass die Standardabweichung in den Gruppen M und L geringer ist als in

den Gruppen S. Dabei liegt zwischen den Gruppen M und L keine erhebliche Differenz vor. Dies deutet darauf hin, dass größere Unternehmen, die den Kennzahlen nach in die Gruppen M und L eingeordnet sind, weniger Schwankungen und somit eine größere Stabilität aufweisen als die kleineren Unternehmen der Gruppen S.

In den Ergebnismatrizen, die die kombinierte Summe in Form von Mittel- und Medianwerten je nach Gruppe und Zieldatum darstellen, ist erkennbar, dass der Median im Vergleich zum zugehörigen Mittelwert tendenziell weiter gegen Null geht. Dies deutet auf das vermehrte Vorhandensein von Ausreißern hin. Dies bedeutet, dass bestimmte Aktienkurse nach der Veröffentlichung einer Nachricht erheblich stärker gestiegen oder gefallen sind als die anderen in der Gruppe. Besonders deutlich fällt dies für die Werte auf, die einen besonderen hohen Mittelwert vorweisen, in den meisten Fällen sind das die Werte die unter Anbetracht der größeren Zieldaten erfasst wurden. Diese ausgeprägten durchschnittlichen Kursbewegungen werden durch den Median gemildert, da dieser den Wert in der Mitte der Verteilung darstellt und somit weniger anfällig für Ausreißer ist. Ein anschauliches Beispiel hierfür kann in Kapitel 6.4 anhand der Abbildung 6.14 und 6.15 erkannt werden. Es ist zu sehen, dass für Gruppe S der Mittelwert bei einem Zieldatum von zwei Wochen von 2,49% auf einen Median von 1,43% fällt, was einer Differenz von mehr als einem Prozentpunkt entspricht. Weniger stark ausgeprägt, zeigt sich dies auch für das Zieldatum von einer Woche. Hier sinkt der Mittelwert für Gruppe S von 1,08% auf einen Median von 0,27%. Unabhängig von diesem Beispiel ist diese Erkenntnis auf die meisten weiteren Ergebnisse anwendbar.

Im Vergleich der verschiedenen Gruppen ist zu erkennen, dass für jede betrachtete Kennzahl, sowohl im Mittelwert als auch im Median, die Gruppen S stets die besten Werte bei einem Zieldatum von zwei Wochen erzielen. Diese Tendenz zeigt sich für alle durchgeführten Analysen. Dies deutet darauf hin, dass die Kursänderungen der Unternehmen in den Gruppen S im Vergleich zu den anderen Gruppen am besten vom Modell auf Basis der Nachrichten vorhergesagt werden können. Zur Erinnerung: Gruppe S umfasst entweder Unternehmen mit einer geringen Marktkapitalisierung, einer niedrigen Nettogewinnmarge oder Unternehmen, die keine Dividenden ausschütten. Dass das Zieldatum von zwei Wochen die höchsten Werte aufweist, lässt sich unter anderem durch die zuvor festgestellte größere Streuung für längere Zeitintervalle erklären. Diese größere Streuung führt dazu, dass die berechneten Mittel- beziehungsweise Medianwerte einer Aktie in der Gruppe, bei korrekter Signalerkennung, höher ausfallen können. Nichtsdestotrotz könnten diese Schwankungen natürlich auch ins Negative gehen. Das Modell schafft es jedoch, diese Kursänderungen zuverlässig zu erkennen, was seine Fähigkeit zur Erfassung solcher Schwankungen unterstreicht. Die zuvor getroffene Feststellung, dass der Median im Gegensatz zum Mittelwert stärker gegen null tendiert, wird durch diese Ergebnisse erneut bestätigt. Die große Differenz zwischen besonders hohen Mittelwerten und dem Median ist, wie zuvor, auch auf Ausreißer in den Daten zurückzuführen. Trotz dieser Ausreißer bleibt der Medianwert dauerhaft positiv und

robust, auch wenn er nicht an die hohen Werte des Mittelwertes heranreicht. Dies lässt sich passend in den Ergebnismatrizen zur Kennzahl der Marktkapitalisierung erkennen, siehe Kapitel 6.2 mit den Abbildungen 6.10 und 6.11. Hier zeigt sich, dass für alle Zieldaten der Gruppe S die höheren Mittelwerte von 1,29%, 0,73% und 2,48% auf die geringeren, aber dennoch positiven, Medianwerte von 0,20%, 0,37% und 1,76% fallen. Zudem ist Gruppe S über alle Kennzahlen und Zieldaten hinweg die einzige Gruppe, die kein einziges Mal negative Summenergebnisse aufweist. Dies unterstreicht die vorherigen führende Position der Gruppe S über mehrere Experimente hinweg. Dies lässt sich damit erklären, dass kleinere Unternehmen tendenziell anfälliger für negative Presse sind als größere Unternehmen. Aufgrund dieser Tatsache, dass der Kurs eines kleineren Unternehmens stärker mit negativen Nachrichten korreliert, ist das Sprachmodell in der Lage, solche Kursschwankungen zuverlässiger zu erkennen.

Anknüpfend an die vorherige Auswertung der Gruppe S lässt sich feststellen, dass die Gruppen M und L im Gegensatz zu den Gruppen S zwar ebenfalls meist positive Median- und Mittelwerte aufweisen, jedoch nicht an die starken Ergebnisse der Gruppe S heranreichen. Die Gruppen M und L unterscheiden sich darin, dass die Gruppe L eine höhere Volatilität aufweist als die Gruppe M. Dies scheint widersprüchlich zu sein, da auch die Gruppen S hohe Schwankungen zeigen und dies die Interpretation nahelegt, dass dies mit zunehmender Unternehmensgröße abnehmen sollte. Diese Tendenz trifft auch auf die Gruppen M zu, jedoch wandelt sich dieses Bild bei den Gruppen L wieder. Die Gruppen L sind zwar weniger beständig als die Gruppen M, jedoch immer noch stabiler als die Gruppen S. Diese Erkenntnis lässt sich darauf zurückführen, dass in den Gruppen L, bedingt durch die hohen Kennzahlenwerte, eher *Global Player*<sup>1</sup> enthalten sind, die größeren äußeren Einflüssen und Marktbedingungen unterliegen. Diese großen Marktakteure können aufgrund ihrer Größe mehr Schwankungen aufweisen. Gleichzeitig sorgt ihre Marktdominanz auch für eine gewisse Beständigkeit, da sie in der Lage sind, Verluste in einem Segment durch Gewinne in anderen Bereichen zu kompensieren. Insgesamt führt dies zu höherer Volatilität im Vergleich zu den Gruppen M, jedoch weniger als bei den Gruppen S. Zwar weisen die Gruppen M dann insgesamt die geringsten Mittelwerte auf, jedoch sind diese hinsichtlich der Differenz zum Median deutlich stabiler und konstanter. Dies ist vorteilhaft, da der mittlere Gewinn je Aktie in der Gruppe nicht unverhältnismäßig stark durch Ausreißer beeinflusst wird, wie es teilweise bei den Gruppen S und teilweise auch bei den Gruppen L der Fall ist. Stattdessen setzt sich der Mittelwert bei den Gruppen M aus einer größeren Anzahl moderater, aber konsistent positiven Werte zusammen. Allgemein ist die Differenz, hinsichtlich Schwankungen und Stabilität, von Gruppe S zu den Gruppen M und L größer als die Differenz zwischen den Gruppen M und L. Diese beiden größeren Gruppen liegen in diesem Aspekt näher beieinander, wie anhand der in den Metadaten dargestellten Standardabweichung (siehe Abschnitt 6.1.3) zu erkennen ist.

---

<sup>1</sup>Global Player [Link], Abgerufen am 23.07.2024

Aus den Daten geht ebenfalls hervor, dass die Gruppen S deutlich stärker schwanken, während die Gruppen M und L nah beieinander liegen beziehungsweise fast identische Schwankungen aufweisen. Für weiterführende Schlussfolgerungen zur Unterscheidung der Gruppen und deren Auswirkungen auf die Präzision empfiehlt sich eine vertiefende Analyse mittels Signifikanztests. Detailliertere Informationen hierzu sind im Abschnitt zur Anregung zukünftiger Arbeiten im anschließenden Fazit 8 zu finden.

In der Darstellung der Signalgenauigkeit zeigt sich, dass alle Gruppen insgesamt zufriedenstellende Ergebnisse erzielen. Dies bedeutet, dass das Modell in der Lage ist, für jede Gruppierung eine Tendenz zu erkennen und diese in positiver als auch in negativer Richtung relativ akkurat vorherzusagen. Beim Vergleich der Signalgenauigkeiten der verschiedenen Gruppen ist jedoch keine direkte Überlegenheit einer Gruppe festzustellen. In jeder der drei Kategorien gab es Ausreißer, die das Gesamtbild beeinflussen haben. Da sich die Gruppen S hier nicht durch eine besondere Genauigkeit in der Verteilung der richtigen Signale auszeichnen, kann daraus geschlussfolgert werden, dass die höhere Rendite der Gruppen S nicht auf eine größere Anzahl richtiger Vorhersagen zurückzuführen ist, sondern auf die Richtigkeit der Vorhersagen mit einer größeren Schwankung. Diese Schlussfolgerung wird durch die zuvor festgestellten Ausreißer gestützt, die sich in den höheren Differenzen zwischen Mittelwert und Median zeigen.

## 7.2. Limitierungen und Risiken

Es wird zwischen zwei Kategorien unterschieden. Zunächst werden die aus dem vorausgehenden Praxisprojekt stammenden Limitierungen und Risiken erneut erwähnt, da diese auf die Ergebnisse dieser Arbeit Einfluss haben könnten. Anschließend werden die spezifischen Limitierungen und Risiken dieser Arbeit dargestellt.

### Praxisprojekt

Im Praxisprojekt wurde aufgrund von Hardware- und Zeitbeschränkungen das BERT-Modell nur über eine relativ geringe Anzahl an Epochen trainiert. Dies könnte zu einer schlechteren Performance führen, als potenziell mit dem Modell möglich wäre. Zusätzlich wurde die Auswahl der Lernrate, des Gewichtungsverlusts und der Batchgröße nicht intensiv verglichen und ausgewertet, was dazu führen könnte, dass optimalere Werte für dieses Anwendungsfeld nicht identifiziert wurden. Das Modell wurde ausschließlich mit Daten aus dem Zeitraum von Januar 2021 bis Dezember 2022 trainiert und getestet. Dies bedeutet, dass das Modell möglicherweise nicht mit der gleichen Genauigkeit auf andere Zeiträume angewendet werden kann. Weiterhin wurde im Praxisprojekt das DistilBERT-Modell verwendet, eine ressourcenschonendere Version

von BERT, die zwar deutlich schneller arbeitet, dafür aber etwas an Genauigkeit im Gegenzug abgibt. Es ist möglich, dass modernere Sprachmodelle wie die verschiedenen Versionen von Large Language Model Meta AI (LLaMA)<sup>2</sup> und GPT<sup>3</sup> oder spezielle Finanzmodelle wie FinBERT<sup>4</sup> eine höhere Genauigkeit erreichen könnten.

## Bachelorarbeit

Bei der Darstellung der Metadaten und der Verteilung der Aktien sowie Nachrichten über die Gruppen fällt eine ungleichmäßige Verteilung insbesondere bei der Dividendenrendite auf. Diese Ungleichmäßigkeit ist unproblematisch, da der Testdatensatz nur 10.000 Daten umfasst und ausschließlich für Testzwecke genutzt wurde. Wäre dieser Datensatz hingegen für das Training verwendet worden, könnte die ungleiche Gewichtung zu Problemen führen. Weiterführend wirft die Auswertungsmethodik hinsichtlich der potenziellen Rendite bei genauer Befolgung des Modells die Frage auf, ob andere statistische oder theoretische Werte besser geeignet wären als marktorientierte und praxisbezogene Kennzahlen. Zudem sollte berücksichtigt werden, dass die potenzielle Mittel- und Medianrendite pro Aktie der Gruppe in der dargestellten Form nicht vollständig erreicht werden kann, da zusätzliche Kosten und Gebühren diesen Wert reduzieren können. Zu beachten ist außerdem, dass die Ergebnisse fundamental auf der Signalvergabe (*Buy, Hold, Sell*) basieren, wobei in dieser Durchführung besten 10% und die schlechtesten 10% den Kauf- beziehungsweise den Verkaufssignalen zugeordnet wurden. Eine andere Wahl der Signalgrenzen, sei es statisch, prozentual oder durch einen anderen Ansatz, hätte möglicherweise zu besseren Renditen geführt. Die Grenzen zwischen den Gruppen der Kennzahlen wurden teils dynamisch, für eine Gleichverteilung bei der Marktkapitalisierung, und teils statisch für die Nettogewinnmarge und Dividendenrendite, basierend auf Fachliteratur zur Unternehmensbewertung, definiert. Dieses Vorgehen könnte die Performance der einzelnen Gruppen beeinträchtigen, da andere Grenzwerte möglicherweise zu besseren Ergebnissen führen könnten. In der Testphase wurde mit 10.000 Datensätzen je Gruppe gearbeitet, was das Risiko birgt, dass die Genauigkeit aufgrund des relativ kleinen Datensatzes leidet, anstatt die gesamten 800.000 Datensätze oder zumindest einen größeren Teil davon zu verwenden. Es sei noch erwähnt, dass die verwendeten Werte und Visualisierungen suboptimal sind, da nur Mittelwert, Median und Standardabweichung dargestellt werden. Es sollte überdacht werden, ob es nicht bessere Darstellungsmethoden oder Werte gibt, die mehr Informationen über die Resultate liefern. Aufgrund der späten Entscheidung, dies zu überdenken, hätten alle Berechnungen neu durchgeführt werden müssen, was aufgrund zeitlicher und hardwarebedingter Einschränkungen nicht mehr möglich war.

---

<sup>2</sup>Meta LLaMA [Link], Abgerufen am 21.07.2024

<sup>3</sup>OpenAI GPT [Link], Abgerufen am 21.07.2024

<sup>4</sup>ProsusAI FinBERT [Link], Abgerufen am 12.07.2024



## 8. Fazit und Ausblick

Das Ziel dieser Arbeit war es, eine differenzierte Analyse des Einflusses bestimmter Kennzahlen auf die Vorhersagbarkeit von Aktienkursbewegungen auf Basis von Nachrichten durchzuführen. Der Erfolg dieser Untersuchung wird daran gemessen, inwieweit Divergenzen innerhalb der Korrelation zwischen den Kennzahlenwertebereichen und der Genauigkeit der Vorhersage tatsächlicher Aktienkursänderungen ermittelt werden können. Insbesondere wird dieser Erfolg anhand der Analyse von jeweils drei Gruppen, die mittels spezifischer Unternehmenskennzahlen separiert wurden, bewertet. Ein exemplarisches Resultat könnte dabei die Feststellung sein, dass eine Erhöhung des Wertes  $x$  zu einer Verringerung der Korrelation mit präzisen Prognosen tatsächlicher Kursschwankungen führt. Die vollständige Definition der Zielsetzung, sowie die der Erfolgsbewertung ist in der Einleitung 1 zu finden.

Die durchgeführte Analyse hat ergeben, dass die mittlere Rendite sowie die mediane Rendite pro Aktie in den Gruppen S, welche durch die kleinsten Wertebereiche der untersuchten Kennzahlen (Nettogewinnmarge, Marktkapitalisierung und Dividendenrendite) gekennzeichnet sind, signifikant höher sind als in den Gruppen M und L, welche höhere Werte dieser Kennzahlen aufweisen. Im Kontext der Gruppen S lässt sich somit eine Korrelation zwischen niedrigeren Kennzahlenwerten und einer präziseren Prognose von Kursänderungen ableiten. Daraus lässt sich schließen, dass der Aktienkurs von Unternehmen, die aufgrund der in dieser Arbeit betrachteten Kennzahlen als tendenziell kleiner einzustufen sind, empfindlicher auf positive wie negative Nachrichten reagiert. Diese Kursschwankungen können durch das trainierte und in dieser Arbeit angewendete Sprachmodell für diese Gruppen besser erkannt werden als für die Unternehmen, die anhand der Kennzahlen als größer eingestuft werden. Es ist jedoch zu beachten, dass in diesen kleineren Gruppen einzelne starke Ausreißer auftreten, was zu einer größeren Differenz zwischen Mittelwert und Medianwert führt. Entgegen der Erwartung setzt sich der Trend der zunehmenden Stabilität mit steigenden Kennzahlenwerten in den Gruppen M und L nicht so linear fort. Die Gruppen L zeigt höhere Schwankungen auf, als die Gruppen M, welche konstantere Werte aufzeigen. Dies liegt daran, dass in den Gruppen L eher *Global Player* enthalten sind, die größeren Einflüssen unterliegen. Diese Marktakteure können aufgrund ihrer Größe mehr Schwankungen aufweisen, besitzen aber gleichzeitig die Fähigkeit, Verluste in einem Segment durch Gewinne in anderen Bereichen zu kompensieren, was zu einer gewissen Beständigkeit führt. In der abschließenden Betrachtung lässt sich festhalten,

dass die Gruppen S durch die besten Mittel- und Medianwerte hervorstechen. Dennoch sollte die Relevanz der Gruppen M und L nicht unterschätzt werden. Die Gruppen M weisen zwar geringere Werte auf, zeichnen sich jedoch durch höhere Stabilität aufgrund weniger Ausreißer aus. Die Gruppen L vereinen Vorteile beider Gruppen.

In der folgenden Abbildung 8.1 sind zwei Entscheidungsmatrizen dargestellt, die auf der Basis des Mittelwertes (links) und des Medians (rechts) der Summenergebnisse erstellt wurden. Die x-Achse repräsentiert die Risikoaffinität beziehungsweise die Affinität bezüglich der Volatilität, dem Ausmaß an Kursschwankungen, während die y-Achse die Handelsfrequenz darstellt. Die dargestellten prozentualen Werte je Feld, folgen der im Ergebniskapitel angewandten Reihenfolge. Der obere Wert repräsentiert die Marktkapitalisierung, der mittlere die Nettogewinnmarge und der untere die Dividendenrendite. Die Farbgebung der Heatmap basiert auf dem Mittelwert der drei Werte, desto heller das Feld, desto positiver ist der Mittelwert des Feldes. Diese Matrix dient als Entscheidungsgrundlage für Akteure, die auf Basis der Erkenntnisse dieser Arbeit Handlungen auf dem Aktienmarkt ausführen möchten. Ein beispielhaftes Szenario ist die Entscheidung bei hoher Risikofreude und geringer Handelsfrequenz. In diesem Fall können sich Akteure auf die Vorhersagen der Gruppen S mit einem Zieldatum von zwei Wochen konzentrieren. Diese Gruppen weisen eine höhere Volatilität und ein höheres Risiko auf, da sie, wie bereits erwähnt, mehr Ausreißer enthalten und daher weniger stabil sind, können aber auch potenziell höhere Renditen erzielen. Bei einer geringeren Risikobereitschaft empfiehlt sich die Fokussierung auf die Gruppen M, welche vergleichsweise konstanter sind. Ist eine höhere Handelsfrequenz gewünscht, kann ein kürzeres Zieldatum gewählt werden.




Abbildung 8.1.: Entscheidungsmatrizen nach Risiko und Handelsfrequenz

Abschließend lassen sich Empfehlungen für zukünftige Arbeiten aussprechen, die größtenteils auf den im Kapitel 7.2 diskutierten Limitationen und Risiken basieren. Die folgenden Vorschläge zielen darauf ab, die Arbeit zu erweitern und zu verbessern sowie die zuvor identifizierten Limitationen zu adressieren und zu relativieren. Dabei wird zunächst auf mögliche Verbesserungsvorschläge bezüglich des Praxisprojekts eingegangen und anschließend auf die Bachelorarbeit.

Zur Anregung künftiger Arbeiten zur Erweiterung und Verbesserung des Praxisprojektes sind folgende Aspekte zu berücksichtigen: Ein wichtiger Punkt besteht darin, das Modell über eine größere Anzahl von Epochen zu trainieren, um die Genauigkeit zu erhöhen und den Fehler zu verringern. Dies ermöglicht dem Modell, optimale während des Trainings berechnete Parameter zu finden. Darüber hinaus sollten intensive Vergleiche der Hyperparameter des Sprachmodells durchgeführt werden, wobei der Fokus auf der Lernrate, dem Gewichtungsverlust und der Batchgröße liegt. Ziel ist es, herauszufinden, ob das Modell durch die Anpassung dieser Hyperparameter besser optimiert werden kann. Eine weiterführende Analyse, die zwar außerhalb des betrachteten Scopes liegt, jedoch interessante Einblicke bieten könnte, betrifft die Untersuchung der Modellgenauigkeit über verschiedene Zeiträume hinweg. Das Modell wurde von Anfang 2021 bis Ende 2022 trainiert und getestet. Bei Anwendung dieses Modells auf andere Zeiträume, beispielsweise 2023 bis 2024, stellt sich die Frage, ob und wie sich die Ergebnisse verändern würden. Ein Vergleich dieser Zeiträume könnte wertvolle Erkenntnisse über das Vertrauen von Personen in Nachrichtenartikel sowie die potenziell veränderte Auswirkung dieser Artikel auf den Aktienmarkt liefern. Als Basismodell wurde DistilBERT verwendet. Es wäre interessant zu erfahren, inwieweit andere Sprachmodelle, insbesondere komplexere Modelle wie die verschiedenen LLaMA Versionen, unter höheren Rechenkapazitäten eine bessere Performance erzielen könnten. Eine solche Untersuchung könnte aufzeigen, ob und in welchem Maße diese Modelle in ihrer Genauigkeit variieren und ob die höhere geforderte Rechenleistung, durch eine äquivalent gestiegenen Präzision gerechtfertigt wird. Ein geeigneter Ausgangspunkt für die Auswahl alternativer Sprachmodelle ist die Website von *Artificial Analysis*<sup>1</sup>. Diese bietet eine übersichtliche und nachvollziehbare Darstellung diverser Benchmarks von Sprachmodellen. Basierend auf diesen Benchmark-Ergebnissen können fundierte Entscheidungen darüber getroffen werden, welche Modelle für diese Arbeit verwendet werden könnten. Dieses Vorgehen ist effizienter, als die Modelle selbst hinsichtlich dieser Kriterien zu testen.

Für die Weiterentwicklung der Bachelorarbeit wird empfohlen, folgende Punkte zu berücksichtigen: Zur Auswertung der Ergebnisse wurden der Mittelwert, der Median und die Standardabweichung betrachtet. Ein detaillierterer Drilldown der Daten wäre jedoch von Interesse. Für eine tiefere Analyse und eine bessere Darstellung könnte

---

<sup>1</sup>Artificial Analysis [Link], Abgerufen am 24.07.2024

dieser Teil beispielsweise mithilfe von Boxplots visualisiert werden. Boxplots bieten einen besseren Überblick über die Strukturierung der Daten, einschließlich Streuung, Maximal- und Minimalwerte. Aufgrund von Hardware-Limitierungen wurde nur mit einem Testdatensatz von 10.000 Zeilen je Gruppe gearbeitet. Es wäre aufschlussreich zu untersuchen, ob sich die Genauigkeit des Modells und die erzielte Rendite verbessern, wenn die Testdatengröße erhöht wird. Ein weitergehender Vergleich von abgeänderten Signalgrenzen wäre ebenfalls interessant. In der Arbeit wurden die besten 10% den Kaufsignalen und die schlechtesten 10% den Verkaufssignalen zugeordnet. Es sollten verschiedene Grenzen sowie eventuell alternative Verfahren zur Bestimmung dieser Grenzen untersucht werden, um den Wert herauszufinden, der die besten Renditen liefert. Ein geeigneter Ansatz zur Lösung dieses Problems wäre eine Sensitivitätsanalyse. Dabei werden die beiden Signalgruppen (*Buy*, *Sell*) nach Perzentilen aufgeteilt. Die durchschnittliche Performance der besten 10% der Kaufsignale könnte mit den nächsten 10 - 20% bis hin zu den schlechtesten 10% verglichen werden. Diese Analyse liefert wertvolle Hinweise auf die Angemessenheit der Grenzwerte. Durch den Vergleich dieser verschiedenen Perzentile lässt sich der optimale Grenzwert möglicherweise bestimmen. Dieser Konzept der Sensitivitätsanalyse könnte zudem auch Aufschluss darüber geben, wie stark Ausreißer, sowohl positive als auch negative, die finalen Mittel- oder Medianwerte der Rendite in jeder Gruppe beeinflussen. Diese Aktien könnten dann identifiziert und gegebenenfalls gesondert behandelt werden. Die Erkenntnis, dass die Gruppen L eine höhere Volatilität aufweisen als die Gruppen M, stellt eine unerwartete Beobachtung dar. Es wäre von Interesse zu untersuchen, ob dieses Phänomen historisch konsistent ist. Hierzu könnte eine Zeitreihenanalyse durchgeführt werden, um diese Hypothese zu überprüfen und zu ermitteln, ob Unternehmen, die nach Kennzahlen als groß klassifiziert werden, in den vergangenen Jahren volatiler geworden sind. Um abschließend zu ermitteln, ob dieses Modell in der realen Welt tatsächlich Rendite erzielen kann, sollte dies mithilfe von Probanden untersucht werden. Verschiedene Gruppen könnten nach Risikoaffinität und Handelsfrequenz aufgeteilt werden, um auf Basis der Modellvorhersagen Kauf- und Verkaufsentscheidungen zu treffen. Dadurch könnten die Ergebnisse der Arbeit in Bezug auf das echte Leben validiert oder auch widerlegt werden. Dies könnte auch weitere Einblicke darüber liefern, ob zusätzliche Schritte zur Optimierung notwendig sind. Dafür müsste die Arbeit noch um den Schritt der Verarbeitung von Streaming-Daten erweitert werden, sodass schnelle Vorhersagen auf aktuelle Nachrichten getroffen werden können.

## Literatur

- [1] D. Araci, *FinBERT: Financial Sentiment Analysis with Pre-trained Language Models*, 2019. arXiv: 1908.10063 [cs.CL].
- [2] A. Vaswani, N. Shazeer, N. Parmar u. a., *Attention Is All You Need*, 2023. arXiv: 1706.03762 [cs.CL].
- [3] J. Devlin, M.-W. Chang, K. Lee und K. Toutanova, „BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding,“ in *Proceedings of the 2019 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, Volume 1 (Long and Short Papers)*, J. Burstein, C. Doran und T. Solorio, Hrsg., Minneapolis, Minnesota: Association for Computational Linguistics, 2019, S. 4171–4186. DOI: 10.18653/v1/N19-1423. Adresse: <https://aclanthology.org/N19-1423>.
- [4] V. Heese, „Wichtige Bewertungskennzahlen in der Aktienanalyse,“ in *Aktienbewertung mit Kennzahlen: Kurschancen und -risiken fundiert beurteilen*. Wiesbaden: Gabler, 2011, S. 29, ISBN: 978-3-8349-6446-5. DOI: 10.1007/978-3-8349-6446-5\_3. Adresse: [https://doi.org/10.1007/978-3-8349-6446-5\\_3](https://doi.org/10.1007/978-3-8349-6446-5_3).
- [5] K. Mishev, A. Gjorgjevikj, I. Vodenska, L. T. Chitkushev und D. Trajanov, „Evaluation of Sentiment Analysis in Finance: From Lexicons to Transformers,“ *IEEE Access*, Jg. 8, S. 131 662–131 682, 2020. DOI: 10.1109/ACCESS.2020.3009 626.
- [6] G. Gidófalvi, „Using News Articles to Predict Stock Price Movements,“ 2001. Adresse: <https://api.semanticscholar.org/CorpusID:17308076>.
- [7] L. Nemes und A. Kiss, „Prediction of stock values changes using sentiment analysis of stock news headlines,“ *Journal of Information and Telecommunication*, Jg. 5, Nr. 3, S. 375–394, 2021. DOI: 10.1080/24751839.2021.1874252. eprint: <https://doi.org/10.1080/24751839.2021.1874252>. Adresse: <https://doi.org/10.1080/24751839.2021.1874252>.
- [8] S. Mohan, S. Mullapudi, S. Sammeta, P. Vijayvergia und D. C. Anastasiu, „Stock Price Prediction Using News Sentiment Analysis,“ in *2019 IEEE Fifth International Conference on Big Data Computing Service and Applications (BigDataService)*, 2019, S. 205–208. DOI: 10.1109/BigDataService.2019.0003 5.

- 
- [9] A. Jain, A. Ruohe, S.-A. Grönroos und M. Kurimo, *Finnish Language Modeling with Deep Transformer Models*, 2020. arXiv: 2003.11562 [cs.CL].
- [10] J. Devlin, M.-W. Chang, K. Lee und K. Toutanova, *BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding*, 2019. arXiv: 1810.04805 [cs.CL].
- [11] J. Fernando, *Market Capitalization: What It Means for Investors*, <https://www.investopedia.com/terms/m/marketcapitalization.asp>, (Zugriff am: 14.05.2024).
- [12] C. B. Murphy, *What Is Net Profit Margin? Formula for Calculation and Examples*, [https://www.investopedia.com/terms/n/net\\_margin.asp](https://www.investopedia.com/terms/n/net_margin.asp), (Zugriff am: 14.05.2024).
- [13] J. Fernando, *Dividend Yield: Meaning, Formula, Example, and Pros and Cons*, <https://www.investopedia.com/terms/d/dividendyield.asp>, (Zugriff am: 14.05.2024).
- [14] A. Damodaran, *Margins by Sector (US)*, [https://pages.stern.nyu.edu/~adamodar/New\\_Home\\_Page/datafile/margin.html](https://pages.stern.nyu.edu/~adamodar/New_Home_Page/datafile/margin.html), (Zugriff am: 16.05.2024).
- [15] J. Berk und P. DeMarzo, „Market Value Versus Book Value,“ in *Corporate Finance, Global Edition*. 2023, S. 65. Adresse: <https://ebookcentral.proquest.com/lib/koln/detail.action?docID=7261465&ppg=65>.
- [16] J. Berk und P. DeMarzo, „Profitability Ratios,“ in *Corporate Finance, Global Edition*. 2023, S. 74. Adresse: <https://ebookcentral.proquest.com/lib/koln/detail.action?docID=7261465&ppg=74>.
- [17] J. Berk und P. DeMarzo, „Dividend Yields, Capital Gains, and Total Returns,“ in *Corporate Finance, Global Edition*. 2023, S. 315. Adresse: <https://ebookcentral.proquest.com/lib/koln/detail.action?docID=7261465&ppg=315>.
- [18] J. Berk und P. DeMarzo, „Key Financial Ratios for Large U.S. Firms,“ in *Corporate Finance, Global Edition*. 2023, S. 83. Adresse: <https://ebookcentral.proquest.com/lib/koln/detail.action?docID=7261465&ppg=83>.

## Linkverzeichnis

In der folgenden Liste sind die Links der Fußnotenverweise aufgeführt, um auch über die Printversion der Arbeit Zugriff auf die entsprechenden Webseiten zu ermöglichen. Die erste Zahl in der Auflistung steht für das Kapitel, während die zweite Zahl die spezifische Fußnote innerhalb des Kapitels angibt.

- 1.1 Peter Lynch Zitat, Abgerufen am 01.06.2024  
Link: <https://www.theguardian.com/money/2000/mar/27/1>
- 1.2 GitHub Repository Praxisprojekt, Abgerufen am 01.06.2024  
Link: <https://github.com/LennardFe/Stock-News-Analysis-with-BERT>
- 1.3 PWP Leeway UG Website, Abgerufen am 01.06.2024  
Link: <https://leeway.tech/>
  
- 2.1 OpenAI ChatGPT, Abgerufen am 21.07.2024  
Link: <https://chatopenai.de/>
- 2.2 Magnificent Seven, Abgerufen am 21.07.2024  
Link: <https://www.boerse.de/boersenlexikon/Magnificent-7>
- 2.3 Statistisches Bundesamt, Abgerufen am 01.06.2024  
Link: <https://www.destatis.de/DE/Themen/Branchen-Unternehmen/Unternehmen/Kleine-Unternehmen-Mittlere-Unternehmen/Glossar/kmu.html>
  
- 4.1 GitHub Repository Praxisprojekt, Abgerufen am 01.06.2024  
Link: <https://github.com/LennardFe/Stock-News-Analysis-with-BERT>
- 4.2 MongoDB: Bloated Documents, Abgerufen am 01.07.2024  
Link: <https://www.mongodb.com/developer/products/mongodb/schema-des-ign-anti-pattern-bloated-documents/>
- 4.3 ISO 8601: Date and time format, Abgerufen am 14.06.2024  
Link: <https://www.iso.org/iso-8601-date-and-time-format.html>
- 4.4 Pandas-Market-Calendar 4.4.0, Abgerufen am 04.06.2024  
Link: <https://pypi.org/project/pandas-market-calendars/>

- 4.5 Matplotlib, Abgerufen am 04.06.2024  
Link: <https://matplotlib.org/>
- 4.6 NLTK Stopwords, Abgerufen am 14.06.2024  
Link: <https://www.nltk.org/search.html?q=stopwords>
- 4.7 HuggingFace, Abgerufen am 14.06.2024  
Link: <https://huggingface.co/>
  
- 5.1 NYSE Composite, Abgerufen am 01.07.2024  
Link: <https://de.investing.com/indices/nyse-composite-components>
- 5.2 GitHub: executor.py Skript, Abgerufen am 01.07.2024  
Link: <https://github.com/LennardFe/Stock-News-Analysis-with-BERT/blob/main/executor.py>
  
- 7.1 Global Player, Abgerufen am 23.07.2024  
Link: <https://www.bpb.de/kurz-knapp/lexika/das-junge-politik-lexikon/320427/global-player/>
- 7.2 Meta LLaMA, Abgerufen am 21.07.2024  
Link: <https://llama.meta.com/>
- 7.3 OpenAI GPT, Abgerufen am 21.07.2024  
Link: <https://platform.openai.com/docs/models>
- 7.4 ProsusAI FinBERT, Abgerufen am 21.07.2024  
Link: <https://huggingface.co/ProsusAI/finbert>
  
- 8.1 Artificial Analysis, Abgerufen am 24.07.2024  
Link: <https://artificialanalysis.ai/>



## A. Anhang

Im Anhang erfolgt eine Visualisierung der Verteilungen sowohl der prognostizierten Veränderungen (*predicted changes*) als auch der beobachteten Kursänderungen (*actual changes*). Die y-Achse gibt die Auftrittshäufigkeit wieder, während die x-Achse die prognostizierte bzw. tatsächliche Kursänderung in Prozent darstellt. Vertikale, gestrichelte Linien markieren die definierten Signalgrenzen.

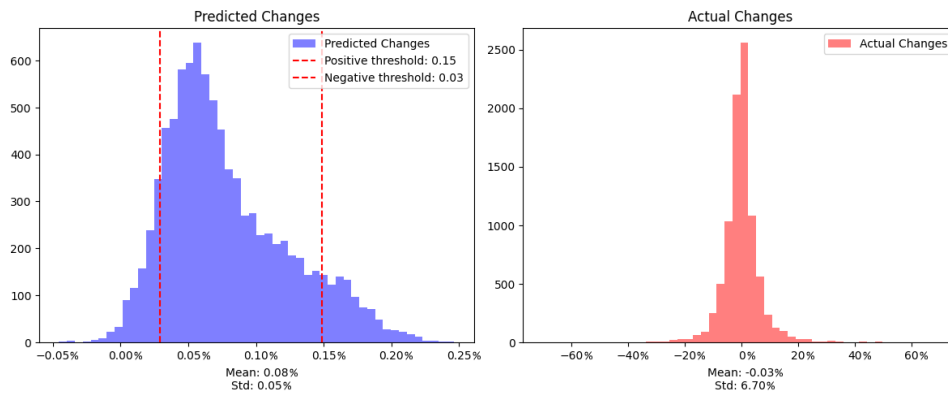


Abbildung A.1.: Histogramm für Marktkapitalisierung (3D - Gruppe S)

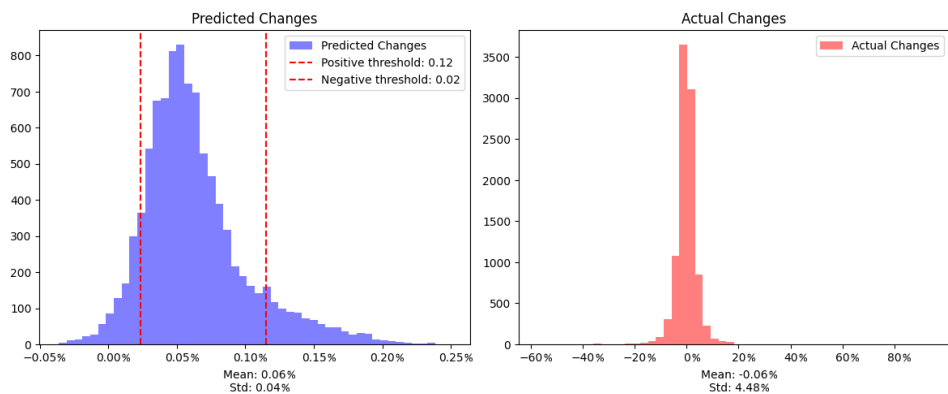


Abbildung A.2.: Histogramm für Marktkapitalisierung (3D - Gruppe L)

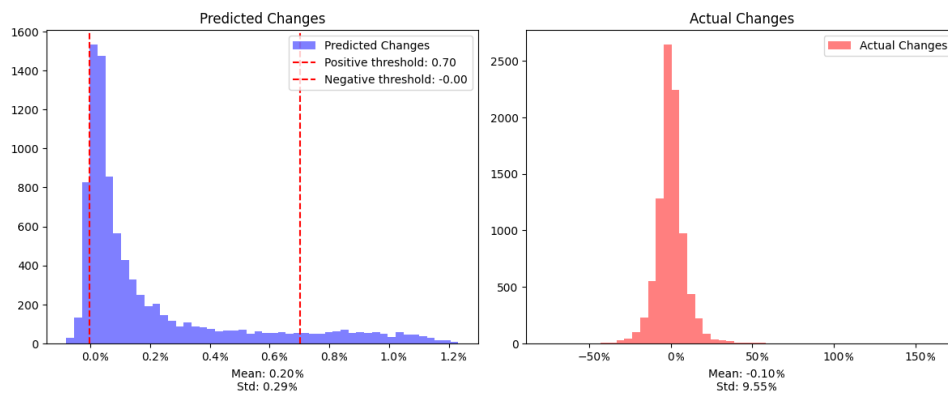


Abbildung A.3.: Histogramm für Marktkapitalisierung (1W - Gruppe S)




Abbildung A.4.: Histogramm für Marktkapitalisierung (1W - Gruppe L)




Abbildung A.5.: Histogramm für Marktkapitalisierung (2W - Gruppe S)

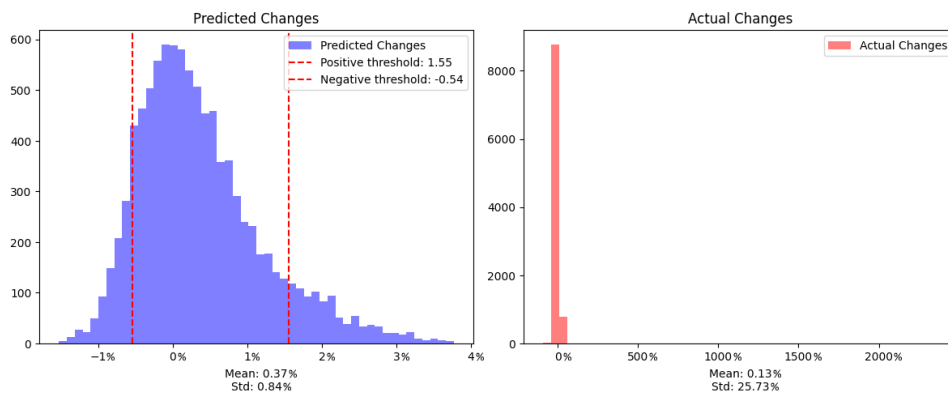


Abbildung A.6.: Histogramm für Marktkapitalisierung (2W - Gruppe L)

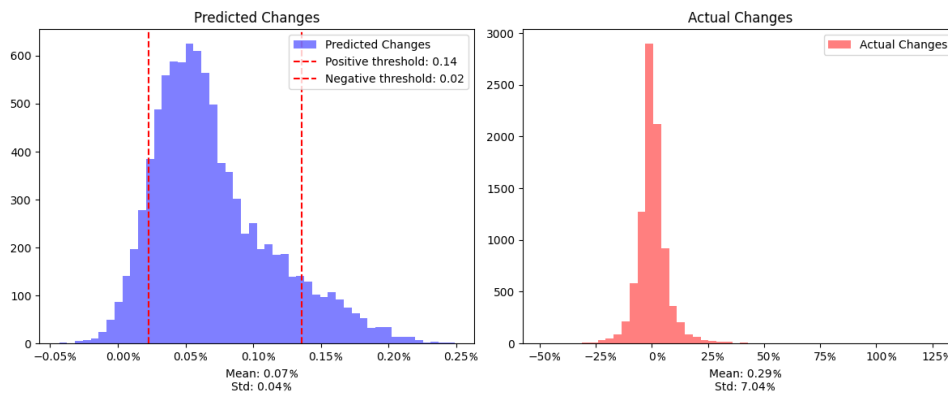


Abbildung A.7.: Histogramm für Nettogewinnmarge (3D - Gruppe S)

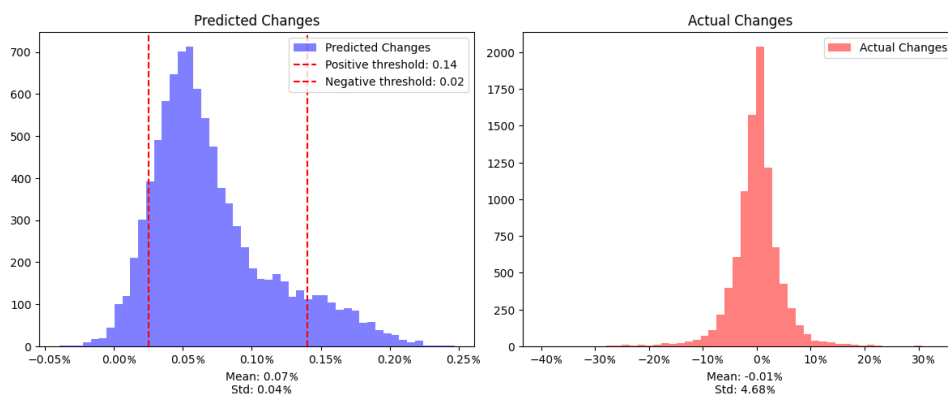


Abbildung A.8.: Histogramm für Nettogewinnmarge (3D - Gruppe M)




Abbildung A.9.: Histogramm für Nettogewinnmarge (3D - Gruppe L)




Abbildung A.10.: Histogramm für Nettogewinnmarge (1W - Gruppe S)

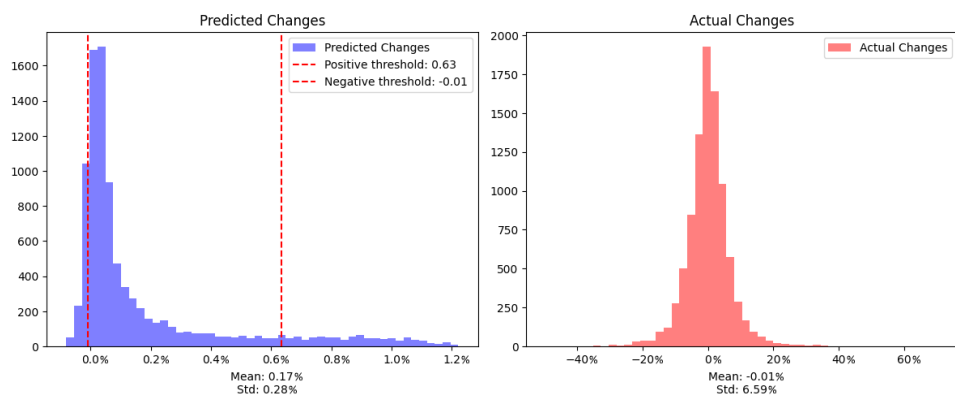


Abbildung A.11.: Histogramm für Nettogewinnmarge (1W - Gruppe M)




Abbildung A.12.: Histogramm für Nettogewinnmarge (1W - Gruppe L)




Abbildung A.13.: Histogramm für Nettogewinnmarge (2W - Gruppe S)

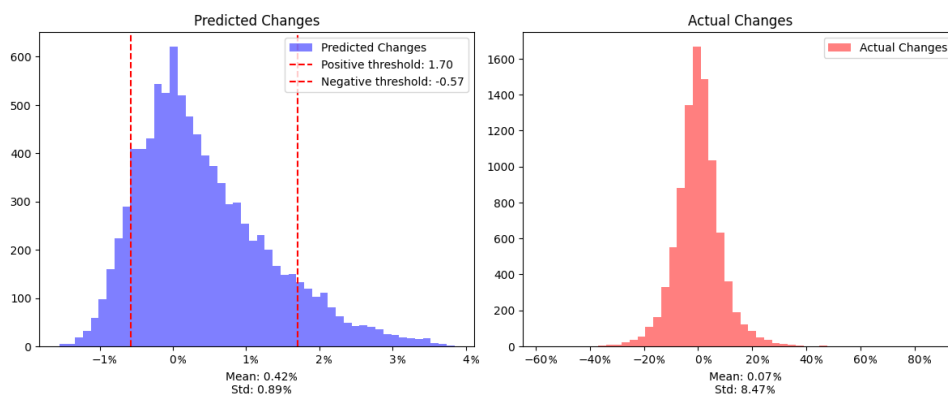


Abbildung A.14.: Histogramm für Nettogewinnmarge (2W - Gruppe M)

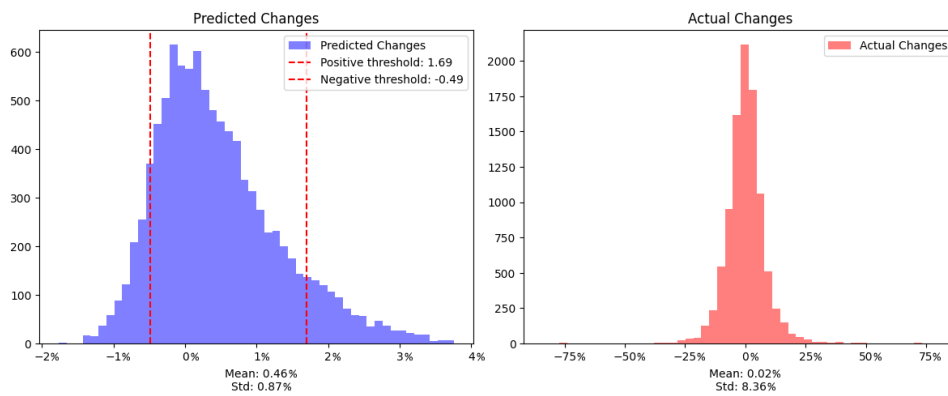


Abbildung A.15.: Histogramm für Nettogewinnmarge (2W - Gruppe L)

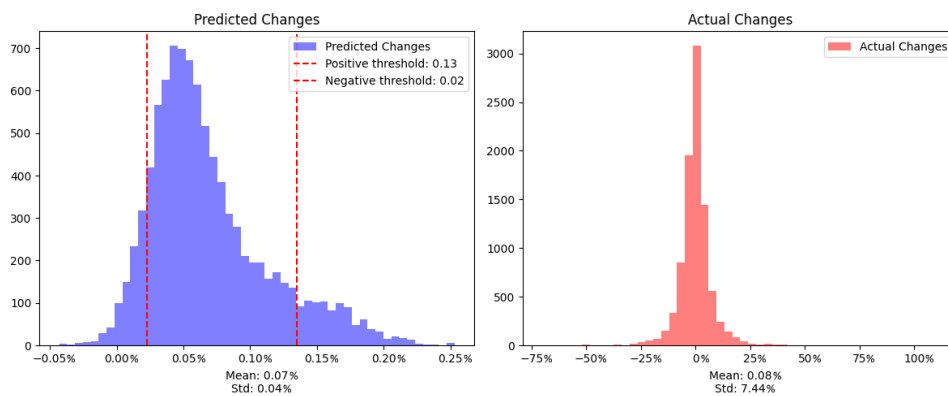


Abbildung A.16.: Histogramm für Dividendenrendite (3D - Gruppe S)

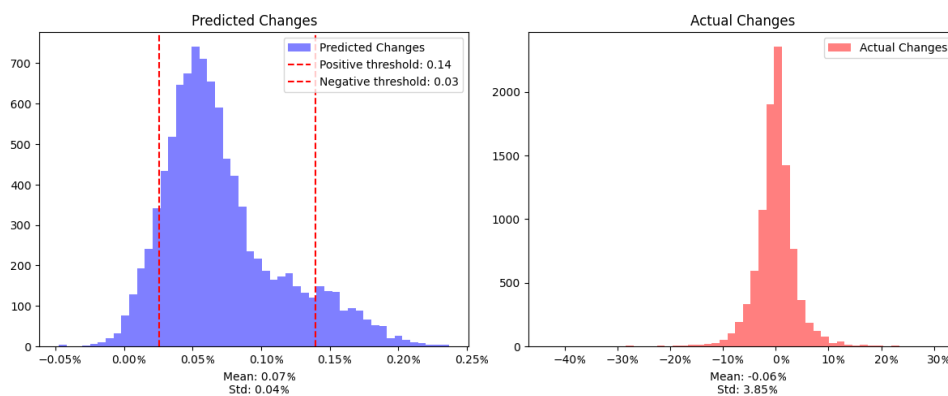


Abbildung A.17.: Histogramm für Dividendenrendite (3D - Gruppe M)

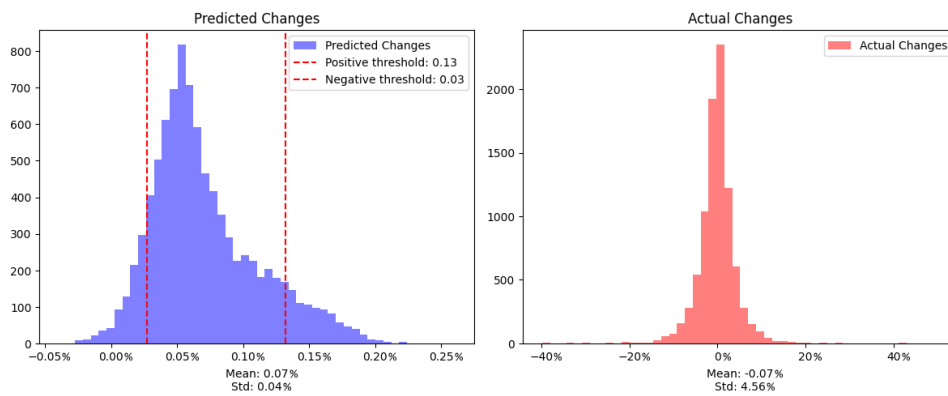


Abbildung A.18.: Histogramm für Dividendenrendite (3D - Gruppe L)




Abbildung A.19.: Histogramm für Dividendenrendite (1W - Gruppe S)

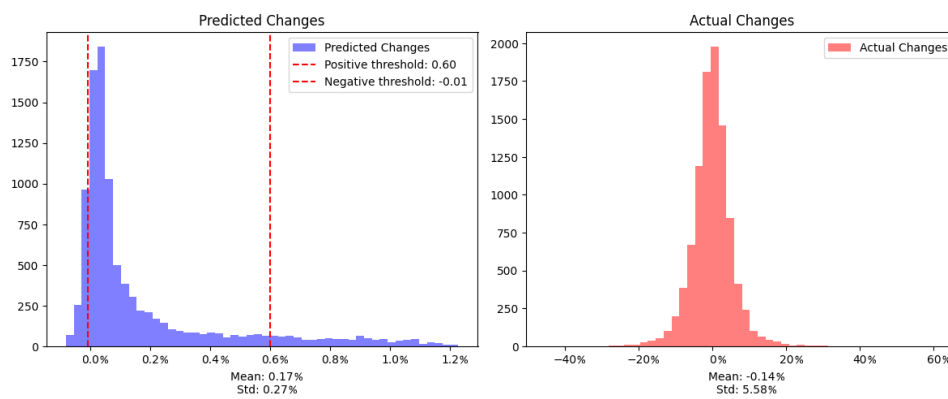


Abbildung A.20.: Histogramm für Dividendenrendite (1W - Gruppe M)




Abbildung A.21.: Histogramm für Dividendenrendite (1W - Gruppe L)

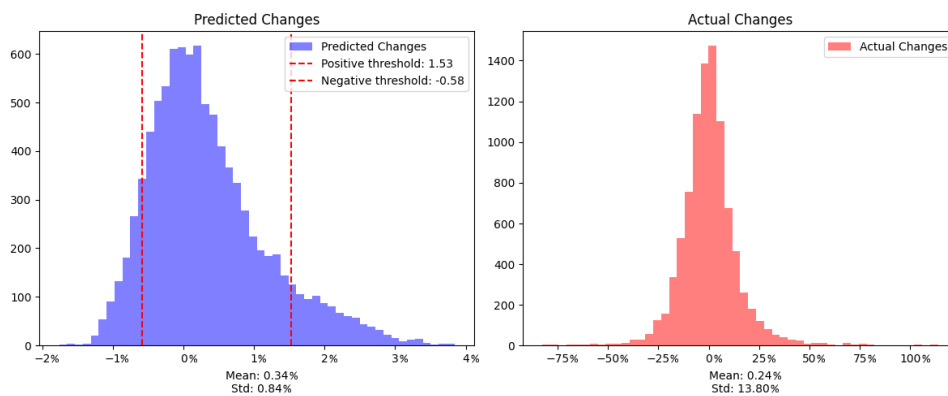


Abbildung A.22.: Histogramm für Dividendenrendite (2W - Gruppe S)

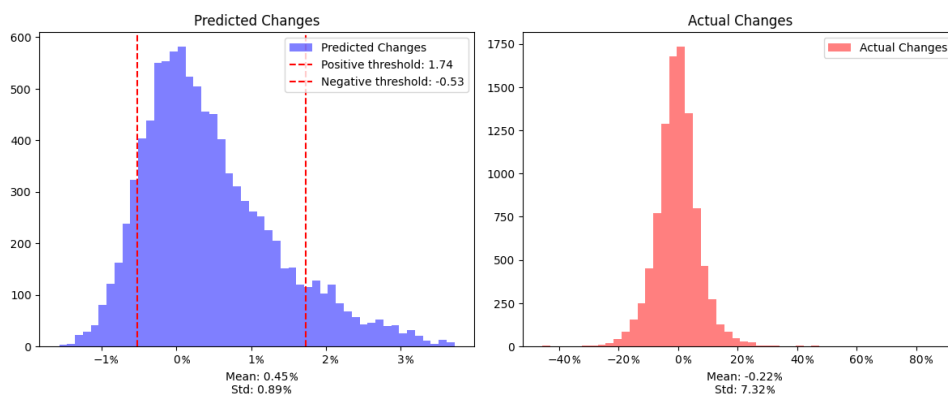


Abbildung A.23.: Histogramm für Dividendenrendite (2W - Gruppe M)






Abbildung A.24.: Histogramm für Dividendenrendite (2W - Gruppe L)