HOCHSCHULE RUHR WEST
UNIVERSITY OF APPLIED SCIENCES

Der Einfluss ausgewählter ökonomischer Variablen auf die Leistung von LSTM-Modellen zur Aktienkursprognose

Bachelorarbeit
Studiengang BWL (IHL)
der Ruhr West University of Applied Sciences

Alexander Schmidt
Matrikelnummer: 10015737

Erstprüfer: Prof. Dr. Alexander Bönner
Zweitprüfer: Prof. Dr. Malte Weiß

Abgabedatum: 26.02.2024

Abstract

Die vorliegende Bachelorarbeit untersucht den Einfluss ökonomischer Variablen, darunter der risikolose Zinssatz, die Inflation, Rohstoffpreise und Währungskurse, auf die Leistung von Long Short-Term Memory (LSTM)-Modellen zur Aktienkursprognose. In effizienten Märkten, in denen alle verfügbaren Informationen in die Preisbildung einfließen, ist die Auswahl geeigneter Merkmale für Regressionsmodelle von höchster Bedeutung. Der Mangel an Studien, welche den kausalen Zusammenhang gepaart mit der Leistungseinwirkung der ökonomischen Variablen analysieren, bildet den Ausgangspunkt dieser Arbeit.

Der theoretischen Teil stellt die kausalen Zusammenhänge der Variablen mit dem intrinsischen Wert von Unternehmen dar. Die methodische Vorgehensweise umfasst die Erhebung von Daten zu technischen Preisdaten und ökonomischen Variablen, ihre Aggregation sowie die Optimierung eines Basismodells alleinig basierend auf den Preisdaten. Anschließend werden die ökonomischen Variablen einzeln und in ihrer Gesamtheit in das Basismodell integriert und unter konstanten Hyperparametern und konstanter Modellstruktur trainiert. Die Evaluation der Modellleistung erfolgt anhand klassischer Leistungsparameter und Handelsstrategien.

Die Ergebnisse zeigen, dass sich die Leistung der LSTM-Modelle bei allen ökonomischen Variablen nach Mean Squared Error (MSE) verschlechtert, insbesondere bei Berücksichtigung des risikolosen Zinssatzes. Keine der Modelle konnte im Durchschnitt eine bessere Rendite als eine klassische Buy-&-Hold-Strategie erzielen. Positiv wirkende Effekte einzelner ökonomischer Variablen auf die Handelsleistungen resultierten hauptsächlich aus einer konstanten Überbewertung dieser Modelle.

Keine der untersuchten ökonomischen Variablen konnten die Leistungen des LSTM-Modells verbessern. Dennoch zeigt sich auch die Prognosegenauigkeit des Basismodells nicht als ausreichend, um höhere Renditen als der Markt zu erzielen. Es bedarf weiterer Forschung zur Identifikation und erfolgreicher Integration von relevanten ökonomischen Variablen in LSTM-Modelle, um bessere Handelsleistungen erzielen zu können. Zusätzlich könnten eine erneute Optimierung der Versuchsmodelle oder langfristigere Handelsstrategien bessere Ergebnisse für die getesteten ökonomischen Variablen erbringen.

Eidesstattliche Erklärung

Hiermit erkläre ich, dass ich die vorliegende Bachelorarbeit selbständig angefertigt habe. Es wurden nur die in der Arbeit ausdrücklich benannten Quellen und Hilfsmittel benutzt. Wörtlich oder sinngemäß übernommenes Gedankengut habe ich als solches kenntlich gemacht. Die vorgelegte Arbeit hat weder in der gegenwärtigen noch in einer anderen Fassung schon einem anderen Fachbereich der Hochschule Ruhr West oder einer anderen wissenschaftlichen Hochschule vorgelegen.

Alexander Schmidt, Mülheim, den 26.02.2024

Inhaltsverzeichnis

Abstract I

Eidesstattliche Erklärung II

Inhaltsverzeichnis IV

Abbildungsverzeichnis V

Tabellenverzeichnis VI

Abkürzungsverzeichnis VII

1. Einleitung 1
1.1. Ausgangssituation und Problemstellung . . . 1
1.2. Formulierung der Forschungsfrage . . . 2
1.3. Ziel der Arbeit und Vorgehensweise . . . 2

2. Theoretische Grundlagen 4
2.1. Künstliche Intelligenz und Aktienkursprognose . . . 4
2.1.1. Einführung Künstliche Intelligenz . . . 4
2.1.2. Machine Learning: Relevanz und Ansätze . . . 5
2.1.3. Deep Learning und Neuronale Netze . . . 6
2.1.4. Long Short-Term Memory . . . 9
2.1.5. Zusammenfassung: Terminologie . . . 11
2.2. Einfluss der ökonomischen Variablen . . . 12
2.2.1. Aktienkursprognosen und effiziente Märkte . . . 13
2.2.2. Der intrinsische Unternehmenswert . . . 14
2.2.3. Einfluss des risikolosen Zinssatzes . . . 17
2.2.4. Einfluss der Inflation . . . 19
2.2.5. Einfluss von Wechselkursen . . . 21
2.2.6. Einfluss von Rohstoffpreisen . . . 22

3. Aktueller Forschungsstand 23

4. Methodik 25
4.1. Versuchsübersicht . . . 25
4.2. Datenerhebung und -vorbereitung . . . 27
4.2.1. Gewählter Basisindex und Zeitraum . . . 27

4.2.2. Repräsentation der ökonomischen Variablen 27
4.2.3. Datenvorbereitung 28
4.3. Erstellung des Basis-Modelles 29
4.3.1. Datentransformation 30
4.3.2. Modelloptimierung 30
4.3.3. Modell-Evaluation 32
4.4. Erstellung der Versuchsmodelle 34

5. Ergebnisse **36**
5.1. Klassische Leistungsparameter 36
5.1.1. Kategorische Leistung nach MSE 36
5.1.2. Interpretation und Bewertung 38
5.2. Handelsstrategien 40
5.2.1. Ergebnisse aller Versuche 40
5.2.2. Kategorische Ergebnisse 42
5.2.3. Interpretation und Bewertung 43
5.3. Kritische Reflexion 45

6. Schlussteil **47**
6.1. Fazit 47
6.2. Ausblick 49

Literaturverzeichnis **51**

A. Zusätzliche Abbildungen **56**

B. Zusätzliche Tabellen **68**

C. Dateianhang **74**

Abbildungsverzeichnis

2.1. Mehrschichtiges Perzeptron 8
2.2. RNN: Vanishing Gradiend Problem 10
2.3. LSTM-Zelle 11

4.1. Versuchsprozess 26

5.1. MSE nach Merkmal-Konfiguration 37
5.2. „ir“ Konfiguration Vergleich mit rollender Korrelation 39
5.3. Allgemeine Handelsleistung 41

A.1. Ansätze des Machine Learning 56
A.2. Einfaches Neuronales Netzwerk 57
A.3. Versteckes Neuron eines RNN´s 57
A.4. RNN´s im Verlauf von t 57
A.5. RNN-Zelle 58
A.6. LSTM Gates 58
A.7. Venn-Diagramm KI 59
A.8. CAPM: Security-Market-Line 59
A.9. Unternehmensklassen nach Flood und Lessard, 1986 60
A.10. Zeitreihen aller Merkmale 61
A.11. Korrelation der Leistungsparameter 62
A.12. Methodik Handelsstrategien 62
A.13. MSE Boxplot 63
A.14. Prognosen Model „ir“ 63
A.15. Model „ir“ Handelsleistung 64
A.16. Rendite nach Merkmal-Kombination 65
A.17. Korrelation Handelsleistung und Leistungsparameter 65
A.18. S&P 500 Total Index Autokorrelation 66
A.19. Abweichungsrichtung nach Merkmal-Kombination 66
A.20. Korrelation: ME und Handelsstrategien 67

Tabellenverzeichnis

4.1. Versuchsmerkmale 29
4.2. Optimierte Hyperparameter 31
4.3. Modellstrukturen 32
4.4. Optuna Feldstudie Resultate 32
4.5. Alle Merkmal-Kombinationen 35

5.1. Kategorische klassische Leistungsparameter 36
5.2. Kategorische Renditen der Handelsstrategien 42
5.3. Handelsleistung Deskriptive Statistik 43

B.1. Dokumentierte klassische Leistungsparameter 69
B.2. MSE Deskriptive Statistik 69
B.3. Handelsstrategien Deskriptive Statistik 69
B.4. Leistungsparameter aller trainierten Modelle 73

Abkürzungsverzeichnis

BPTT Backpropagation Through Time

CAPM Capital Asset Pricing Model

COGS Cost Of Goods Sold

CPI Consumer Price Index

DCF Discounted Cashflow Model

DL Deep Learning

FCF Free Cash Flow

FCFE Free Cash Flow to Equity

KI Künstliche Intelligenz

LLM Large Language Model

LSTM Long Short-Term Memory

MAE Mean Absolute Error

MAPE Mean Absolute Percentage Error

ME Mean Error

ML Machine Learning

MLP Mehrschichtige Perzeptren

MSE Mean Squared Error

NN Neuronale Netzwerke

PCA Principal Component Analysis

R2 Bestimmtheitsmaß

RMSE Root Mean Squared Error

RNN Rekurrente Neuronale Netze

TA Trading Accuracy

1. Einleitung

1.1. Ausgangssituation und Problemstellung

Künstliche Intelligenz (KI) hat in den letzten Jahren eine rasante Entwicklung erfahren und eine transformative Wirkung auf zahlreiche Industrien entwickelt. Unternehmen setzen vermehrt auf KI-Modelle, um komplexe Probleme zu lösen, Entscheidungen zu automatisieren und innovative Lösungen zu finden.

Besonders Neuronale Netzwerke (NN) zur Prognose von Aktienkursen haben in den letzten Jahren stark an Verwendung zugenommen (Kumbure et al., 2022). Aufgrund des enormen Transaktionsvolumens auf Aktienmärkten ist das Limit des möglichen Profits fast unendlich und Aktienmärkte ein wichtiger Treiber von Wirtschaftswachstum (Beck & Levine, 2004). Einzige Voraussetzung und zeitgleich größte Herausforderung ist die korrekte Prognose des zukünftigen Wertes einer Aktie. In der Aktienanalyse kann zwischen zwei Ansätzen unterschieden werden. Die fundamentale Analyse basiert auf dem intrinsischen Wert von Unternehmen, welcher sich durch Informationen wie Umsätze, Kosten und Cashflows berechnet (Damodaran, 2012). Abgesehen von den unternehmensbezogenen Daten, haben auch ökonomische Variablen wie der Zins, die Inflation oder Wechselkurse einen Einfluss auf den Aktienmarkt (Peiró, 2016). Die technische Analyse hingegen basiert rein auf den historischen Kursdaten einer Aktie. Durch die Berechnung verschiedener Kennzahlen werden Trends und Formationen im Kursverlauf identifiziert, welche die Basis von Kursprognosen in der technischen Analyse darstellen.(Arnold & Lewis, 2019)

NN werden genutzt, um auf Basis von technischen und fundamentalen Merkmalen Aktienkurse zu prognostizieren. Abgesehen von der Art und dem strukturellen Aufbau des Modells haben die Input-Variablen, auch Merkmale (eng. Features) genannt, einen essenziellen Einfluss auf die Leistung, also die Prognosegenauigkeit von KI-Modellen (Tsai & Hsiao, 2010). Obwohl bereits eine Vielzahl von Studien erfolgreich Modelle zur Aktienkursprognose auf Basis verschiedenster Modelltypen, Modellstrukturen, Hyperparameter und Merkmalen erstellt haben, fehlt es an Studien, welche den direkten Einfluss bestimmter Merkmale auf die Leistung von KI-Modellen untersuchen (Kumbure et al., 2022).

1.2. Formulierung der Forschungsfrage

Das Interesse sowie der wissenschaftliche Diskurs im Bereich der Aktienkursprognose mit KI ist groß. Dennoch gibt es nur wenige Studien, welche zum einen den kausalen Zusammenhang zwischen Merkmal und Zielmerkmal (also Unternehmen) betrachten und zum anderen den tatsächlichen Einfluss dieses Merkmals auf die Leistung eines Modells analysieren.

Ansätze, wie die der Feature-Selektion, filtern zwar repräsentative Faktoren aus einem Pool an unterschiedlichen Variablen, lassen jedoch den kausalen Zusammenhang mit dem Unternehmenswert unbeachtet. Während der direkte Einfluss einer bestimmten Variable auf die Endprognose eines NN nur schwer nachzuvollziehen ist, lässt sich durch fundamentale Theorie der kausale Einfluss gewisser Variablen auf den Kurs einer Aktie verstehen.

Diese Arbeit zielt darauf ab, den theoretischen Zusammenhang zwischen ausgewählten ökonomischen Merkmalen und dem Zielmerkmal (Unternehmen) darzustellen und zu evaluieren, ob dieser theoretische Zusammenhang tatsächlich Auswirkungen auf die Leistung von Long Short-Term Memory (LSTM)-Modellen hat. In Hinsicht auf die oben identifizierte Wissenslücke definiere ich die Forschungsfrage dieser Arbeit wie folgt:

> *Wie wirken sich ausgewählte ökonomische Variablen auf die Leistung von LSTM-Modellen zur Aktienkursprognose aus?*

Als ökonomische Variablen sollen in dieser Thesis der risikolose Zinssatz, die Inflation, Rohstoffpreise und Währungskurse analysiert werden. Aufbauend auf dem kausalen Zusammenhang der ökonomischen Variablen und dem Zielmerkmal (Unternehmen) formuliert sich somit folgende Hypothese:

> *Ein ökonomisches Merkmal mit einem kausalen Zusammenhang zu der Zielgröße des Modells wirkt sich positiv auf dessen Leistung aus.*

1.3. Ziel der Arbeit und Vorgehensweise

Das inhaltliche Ziel dieser Arbeit ist die Beantwortung der in Kapitel 1.2 formulierten Forschungsfrage durch die Überprüfung der formulierten Hypothese. Im theoretischen Teil (Kapitel 2) sollen die kausalen Zusammenhänge der untersuchten ökonomischen Variablen auf den intrinsischen Wert von Unternehmen dargestellt werden. Ziel ist es hier zu klären, ob und wie die betrachtete ökonomische Variable und der Unternehmenswert nach der fundamentalen Theorie zusammenhängen. Des Weiteren werden die Grundlagen von KI

dargestellt, um das hier verwendete LSTM-Modell einordnen zu können. Es folgt eine kurze Darstellung des aktuellen Forschungsstandes im Bereich der Merkmal-Selektion und Aktienkursprognose mit KI in Kapitel 3.

Im Analyseteil (Kapitel 4 & 5) soll geprüft werden, ob dieser kausale Zusammenhang sich in einer Verbesserung der Genauigkeit des Modells bei der Prognose von Aktienkursen auswirkt. Hierfür wird zuerst ein LSTM-Modell auf Basis des Aktienkurses trainiert. Es wird ein aussagekräftiger Leistungsparameter ausgewählt, um das verwendete Modell zu optimieren. In einem zweiten Schritt werden die zu betrachtenden Variablen einzeln zu den reinen Kursdaten hinzugefügt und die Leistung des Modells unter gleichbleibender Struktur und Hyperparametern (ceteris paribus) mit der Leistung des Basismodells verglichen. Ziel des Analyseteils ist es zu erkennen, ob und wie sich die betrachteten ökonomischen Variablen auf die Leistung des Modells auswirken. Zum Ende dieser Thesis in Kapitel 6 werden die relevantesten Erkenntnisse zusammengefasst und mit der Forschungsfrage und der aufgestellten Hypothese verglichen.

2. Theoretische Grundlagen

In diesem Kapitel werden die grundlegenden theoretischen Konzepte für diese Arbeit erarbeitet. In dem ersten Abschnitt 2.1 werden die Grundlagen von KI dargestellt. Ziel ist es, dem Leser ein ausreichendes Verständnis für die in dieser Thesis benutzen Modelle und allgemeinen Begrifflichkeiten zu verschaffen. In Kapitel 2.2 werden die Grundlagen für den intrinsischen Wert einer Aktie und die betrachteten ökonomischen Variablen dargestellt. Dem Leser wird ein Verständnis dafür vermittelt, wie der Aktienkurs mit den analysierten ökonomischen Variablen in Beziehung steht.

2.1. Künstliche Intelligenz und Aktienkursprognose

2.1.1. Einführung Künstliche Intelligenz

KI ist ein Begriff, der aktuell in vielen Fachbereichen und Medien auftaucht und besonders in den letzten Jahren beispielsweise durch die Einführung von ChatGPT stark an Relevanz zugenommen hat (Kumbure et al., 2022). Es bestehen eine Vielzahl von Definitionen für den Begriff KI in der Literatur:

> „[The automation of] activities that we associate with human thinking, activities such as decision-making, problem solving, learning . . .“ (Bellman, 1978, S. 28)

> „The study of the computations that make it possible to perceive, reason, and act.“ (Winston, 1993, S. 5)

Diese Definitionen verleihen KI eine komplexe, mit dem menschlichen Verhalten eng verbundene Natur, die sich auf Fähigkeiten wie rationales Denken, Lernen, Problemlösung und menschlichem Handeln bezieht (Russell & Norvig, 2016). Eine anschaulichere Perspektive auf KI bietet das Zitat von Rich und Knight, 1996:

> „The study of how to make computers do things at which, at the moment, people are better.“ (Rich & Knight, 1996, S. 3)

Somit bildet KI zusammenfassend einen Oberbegriff für eine Vielzahl von unterschiedlichen Modellen und Methoden, dessen Ziel es ist, die menschliche Intelligenz zu simulieren, um komplexe Probleme lösen zu können (Grunert, 2021).

Abgesehen von Large Language Models (LLMs) wie beispielsweise ChatGPT, werden KI-Modelle auch für Mustererkennung (Sprach- oder Bilderkennung), Empfehlungssysteme (beispielsweise einer Suchmaschine) oder auch Aktienkursprognosen eingesetzt (Grunert, 2021). Es wird deutlich, dass der Begriff KI äußerst vielschichtig ist. Im Verlauf dieses Kapitels werden die verschiedenen Bereiche bis hin zu dem hier verwendeten LSTM-Modell genauer beleuchtet.

2.1.2. Machine Learning: Relevanz und Ansätze

Ein Teilbereich, der KI der sich besonders mit dem Aspekt des menschlichen Lernens beschäftigt, ist Machine Learning (ML). Mit einer zunehmenden Digitalisierung steigt ebenfalls die Datenmenge, die durch heutige Systeme erfasst werden kann. Es benötigt neue Ansätze, um diese großen Datensätze zu klassifizieren, analysieren und auszuwerten. Methoden des ML ermöglichen es Muster in großen Datensätzen zu erkennen, welche dann genutzt werden, um Erkenntnisse über die Daten an sich und deren Entwicklung zu gewinnen. (Murphy, 2014)

„Je mehr Daten gesammelt werden, umso größer wird das Potenzial von Machine-Learning-Algorithmen.“ (Grunert, 2021, S. 8) Deshalb bildet der Aktienmarkt eine optimale Basis für die Anwendung von ML-Modellen, weil Preisdaten sowie fundamentale Kennzahlen der gelisteten Unternehmen jedem Teilnehmer des Aktienmarktes zugänglich sind.

Bei ML wird zwischen zwei Ansätzen unterschieden: Dem überwachten Lernen (eng: supervised learning) und dem unüberwachtem Lernen (eng: unsupervised learning). Bei dem Ansatz des **überwachten Lernen** bestehen ein oder mehrere Input-Variablen x (auch Merkmale genannt). Diese könnten beispielsweise Aktienkurse oder auch Textgefüge repräsentieren. Zu diesen Input-Faktoren besteht eine passende Zielgröße y. Paare aus x und y sind in einem Trainings-Datensatz D mit einer Menge von N aggregiert:

$$D = \{(x_i, y_i)\}_{i=1}^{N} \tag{2.1}$$

Basierend auf dem Skalenniveau von y_i wird das überwachte Lernen weiter unterschieden. Ist y_i eine nominale oder kategorische Variable mit C Merkmalen in $y_i \in \{1, ..., C\}$ handelt es sich um eine **Klassifikation**. Durch die dem Modell bereitgestellten Daten x_i soll

eine Klassifikation in vorgegebene Klassen vorgenommen werden. Beispiele wären hier die Krebserkennung $y_i \in \{\text{Ja}, \text{Nein}\}$ oder die Klassifizierung von Verkehrsteilnehmern $y_i \in \{\text{Auto}, \text{Fußgänger}, \text{Fahrrad}\}$. Ist y_i eine metrische Variable, handelt es sich um eine **Regression**. Durch Input-Faktoren x_i soll das Modell einen Wert prognostizieren. Dies könnte beispielsweise das Einkommen oder auch der zukünftige Wert einer Aktie sein. (Murphy, 2014)

Bei dem Ansatz des **unüberwachten Lernen** besteht keine Zielgröße y für die Merkmale x:

$$D = \{(x_i)\}_{i=1}^{N} \tag{2.2}$$

Es handelt sich um einen explorativen Ansatz, bei dem der Fokus auf der Erkundung von Strukturen und möglichen Klassifizierungen in den Daten liegt (Murphy, 2014). Zwei relevante Methoden sind hier die Clusteranalyse und die Faktorenanalyse. „Ziel von **Clusteranalysen** ist es, in sich homogene und verglichen miteinander möglichst heterogene Gruppen zu bilden.“ (Grunert, 2021, S. 15) Während es visuell nur möglich ist, den Zusammenhang zwischen maximal drei Variablen darzustellen, so können Methoden der Clusteranalyse eine Vielzahl von Variablen in Betracht ziehen, um innerhalb des Datensatzes Klassen zu bilden. Ziel der **Faktorenanalyse** ist es, aus einer Menge von Merkmalen relevante Faktoren zu identifizieren. Eine hier oft eingesetzte Methode ist die Principal Component Analysis (PCA). Aus einer Menge an Merkmalen, welche teilweise miteinander korrelieren, wird eine kleinere Menge an unkorrelierten Faktoren extrahiert. Es kommt zu einer Minderung der Merkmale und somit auch der Laufzeit des Trainingsprozesses. (Grunert, 2021)

Die Struktur von ML ist auch zusammenfassend in Abbildung A.1 dargestellt.

2.1.3. Deep Learning und Neuronale Netze

Deep Learning (DL) ordnet sich bei ML unter den Ansätzen des überwachten Lernens unter und kann demnach für Regressionen und Klassifikationen eingesetzt werden. NN sind stark dem menschlichen Gehirn nachempfunden und bilden die grundlegende Struktur eines DL-Modells. Vereinfacht besteht das menschliche Gehirn aus einer Vielzahl von Neuronen, welche untereinander mit Synapsen verbunden sind. Durch Botenstoffe kommt es im Gehirn zu Signalübertragungen zwischen Neuronen (Purves, 2004). NN im Bereich des ML bestehen aus mehreren Schichten solcher Neuronen, welche untereinander verbunden sind (Goodfellow et al., 2018).

In Abbildung A.2 ist ein simples NN mit zwei Schichten, D-Merkmalen und C-Zielgrößen

dargestellt. Die erste Schicht (auch input-layer) eines NN hält alle Neuronen, welche die Merkmale x_D repräsentieren. Die letzte Schicht eines solchen Modells (auch output-layer genannt) repräsentiert die Zielgröße y_C des Modells. Die Neuronen der beiden Schichten sind durch Gewichte miteinander verbunden, welche die Intensität der Signalübertragung von dem vorherigen Neuron zum nachfolgenden Neuron angeben.

Die Gewichte stellen also in diesem simplen Modell **direkt** die Zuordnung der Merkmale zu den Zielgrößen her, weshalb das Modell stark von diesen Merkmalen abhängig ist. Für die Lösung eines Problems mit ML ist es obligatorisch die Merkmale auszuwählen, die für das Problem relevant sind. Dies gilt besonders für das vereinfachte Modell aus Abbildung A.2, da das Modell strukturell keine Kapazität hat, die gegebenen Merkmale zu transformieren, bevor diese auf die Zielgrößen übergehen. Um diese Problematik zu verdeutlichen, nennt Goodfellow et al., 2018, S. 4 ein verständliches Beispiel: „Menschen können problemlos mit arabischen Ziffern rechnen, doch mit römischen Zahlenzeichen fällt es den meisten sehr viel schwerer.“ Die römischen Zahlen müssten in diesem Falle erst in arabische Ziffern umgerechnet werden, bevor Rechnen mit diesen möglich wäre. Es benötigt also einer weiteren Schicht an Berechnung. (Goodfellow et al., 2018)

Dies wird durch Deep Learning ermöglicht, indem viele weitere Schichten zu dem einfachen Modell in Abbildung A.2 hinzugefügt werden. Die ursprünglichen Merkmale x_D können durch die Schichten zwischen der Input- und der Output-Schicht transformiert werden, bevor sie als Signale im Output-Layer zur Bildung der Zielgröße dienen. DL erlaubt es, das Grundproblem in verschiedene kleinere Probleme zu zerlegen. **Mehrschichtige Perzeptren (MLP)** sind die bekanntesten DL-Modelle. Ein solches ist beispielsweise in Abbildung 2.1 dargestellt. Die Schichten an m Neuronen, die zwischen der Input- und der Output-Schicht liegen, werden versteckte Schichten (eng. hidden layers) genannt. Die Anzahl an versteckten Schichten L und den Neuronen dieser Schichten m sind nicht fix und sollten je nach Problem individuell gewählt werden. Da in jeder Schicht Daten abstrahiert werden können, steigt die Komplexität der Modelle mit zunehmenden Schichten und Neuronen, was auch die Fähigkeiten des Modells bei ausreichender Datenlage steigert. (Grunert, 2021)

Bei einem MLP-Modell handelt es sich um ein sogenanntes Feedforward-Netz, da Signale ausschließlich nach vorne, also Richtung Output-Schicht weitergeleitet werden können. Das Modell hat zum einen keine Rückkopplung zwischen den einzelnen Schichten, weder noch Kenntnisse über bevor ausgegebene Zielgrößen y_C. (Goodfellow et al., 2018)

Bestehen Rückkopplungen zwischen den Neuronen eines MLP-Modells handelt es sich um **Rekurrente Neuronale Netze (RNN)** (Rumelhart et al., 1986). Durch diese

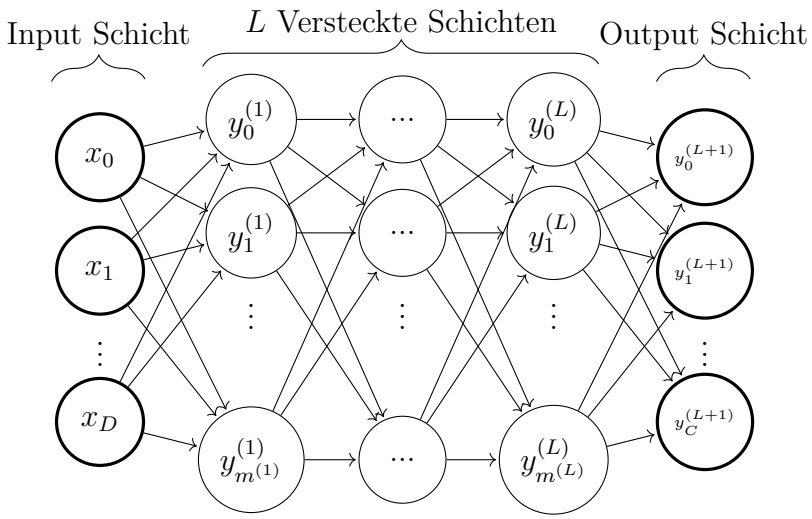

Abbildung 2.1.: Mehrschichtiges Perzeptron (Quelle: In Anlehnung an David Stutz, 2014)

Rückkopplung ist die Reihenfolge der Daten für das Modell relevant, weshalb es sich gerade für die Verarbeitung von Sequenzen von Werten $x_{(t)}, ..., x_{(t+N)}$ eignet. Beispiele hierfür sind die Verarbeitung von Text-, Audio- oder auch Aktienpreisdaten, für welche die Merkmale der vorherigen Perioden x_{t-1} relevant sind (Goodfellow et al., 2018). In Abbildung A.3 ist ein Neuron eines RNNs dargestellt. Als zusätzliche Variable wird der Index der Sequenz durch t definiert. Der Index stellt bei einer Sequenz von Aktienkursen über einen gewissen Zeitraum, den Zeitstempel des aktuell betrachteten Kurses dar.

Das Signal des RNN-Neurons beeinflusst durch die Rückkopplung W nicht nur die Zielgröße $y_{C,\mathbf{t}}^{(L+1)}$ sondern auch das Input Signal des Neurons in dem folgenden Durchlauf $y_{m^{(L)},\mathbf{t+1}}^{(L)}$. Das Output-Signal s von einem RNN-Neuron definiert sich fortan:

$$s_{(t)} = f\left(s_{(t-1)}, x_{(D,t)}\right) \tag{2.3}$$

In Abbildung A.4 ist ein solches RNN-Modell vereinfacht über den Verlauf der Zeit t aufgefaltet dargestellt. Das Signal der Neuronen $y_{m^{(L)}}^{(L)}$ wird in dem folgenden Durchlauf erneut mit dem aktuellen Merkmal $x_{(D)}$ verarbeitet. Dies ermöglicht dem Modell, zeitliche Abhängigkeiten und Kontextinformationen zu bewahren und fortzuführen. (Goodfellow et al., 2018)

Für diese Arbeit fungieren Aktienkurse und ökonomische Variablen als Schlüsselmerkmale für die Prognose. Die Vorhersage eines Aktienkurses allein auf Grundlage technischer und fundamentaler Analysen gestaltet sich bereits als anspruchsvoll und basiert darüber hinaus überwiegend auf historischen Daten. Daher wird in dieser Thesis ein RNN-Modell

herangezogen, um die Prognose unter Berücksichtigung vergangener Informationen zu ermöglichen.

2.1.4. Long Short-Term Memory

Das Problem instabiler Gradiente

Ein grundlegendes Problem neuronaler Netze mit einer Vielzahl an Schichten sind verschwindende und explodierende Gradienten. Der Ursprung dieses Problems liegt in dem Optimierungsprozess des Modells und soll hier vereinfacht dargestellt werden. Im Rahmen des Trainingsprozesses eines Modells werden die Gewichte aller Neuronen schrittweise angepasst, um die Abweichung des Modells (eng. Loss) von den tatsächlichen Zielwerten y_C zu minimieren. Die Richtung und Stärke, in welche die Gewichte angepasst werden müssen, ergibt sich durch individuelle Gradienten, welche durch den Backpropagation-Algorithmus berechnet werden. Ziel ist es, die Gewichte am stärksten anzupassen, welche die stärkste Auswirkung auf den berechneten Wert y_C haben, um die Abweichung maximal zu minimieren. Die Relevanz jedes Gewichts ergibt sich also durch dessen nachgelagerte Gewichte. Wenn beispielsweise das Gewicht eines Neurons in der ersten Schicht hoch ist, die Gewichtung des nachgelagerten Neurons aber sehr gering, so mindert dies die Auswirkung des ersten Gewichts auf y_C. (Grunert, 2021)

In DL-Modellen entstehen durch die Vielzahl an Schichten lange Ketten von Neuronen. Durch das Produkt vieler kleiner Gewichte kommt es in den hinteren Schichten (welche weiter von y_C entfernt sind) zu verschwindend kleinen Gradienten. Die Optimierung dieser Gewichte in jedem Durchlauf ist also ebenfalls verschwindend gering. Durch das Produkt vieler großer Gewichte in einer Neuronenkette kommt es in den hinteren Schichten wiederum zu explodierend großen Gradienten, welche zu einer Überanpassung der Gewichte (also einer Überoptimierung) führen können. Schlussendlich kommt es bei hinteren Neuronen zu schlechteren Lernleistungen durch den Backpropagation-Algorithmus. (Goodfellow et al., 2018)

Das Problem der verschwindenden Gradienten verstärkt sich bei RNN-Modellen. Hier werden die Gewichte der Neuronen durch die Rückkopplungen bei allen Schritten t in der Sequenz verwendet. Daher wird bei RNNs der Backpropagation Through Time (BPTT) Algorithmus angewandt. Die Berechnungen der Gradienten zur Optimierung der Gewichte basieren nicht nur auf dem aktuellen (Zeit-) Schritt t, sondern zusätzlich auf dem vorherigen $t - N$. Die Optimierung erfolgt somit entlang einer aufgerollten Kette an NN, wie sie auch in Abbildung A.4 dargestellt ist. Wo sich die Problematik bei MLP-Modellen durch die

Tiefe der Netzte (also Anzahl der Schichten) ergibt, ist bei RNN-Modellen zusätzlich die Länge der Sequenz problematisch. (Grunert, 2021)

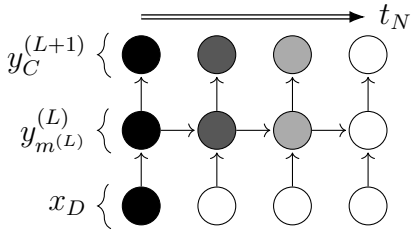

Abbildung 2.2.: Vanishing Gradient Problem bei RNN´s
(Quelle: Eigene Darstellung)

Das Problem verschwindender Gradienten erschwert es RNNs langfristige Abhängigkeiten in Sequenzen zu erlernen (Bengio et al., 1993, 1994). Dieses Phänomen ist in Abbildung 2.2 dargestellt. Signale durch x_D verblassen entlang der Sequenz t. Dies bedeutet nicht, dass es unmöglich ist langfristige Muster in Sequenzen zu erkennen, da jedoch die Gradienten von langfristigen Zeitschritten exponentiell kleiner sind als von kurzfristigen, dauert das Erlernen dieser sehr viel länger (Hochreiter, 1991).

LSTM als Lösungsansatz

Es gehen mehrere Lösungsansätze gegen das Problem der instabilen Gradienten für die Verarbeitung von Sequenzen aus der Literatur hervor (Cho et al., 2014; Hochreiter & Schmidhuber, 1997; Jaeger & Haas, 2004; Maass et al., 2002). Das **Long Short-Term Memory (LSTM)** Modell wurde von Hochreiter und Schmidhuber, 1997 erstmals veröffentlicht und findet in dieser Thesis Anwendung.

Neben der Rückkopplung h (eng. Hidden State), welche die Signale eines Neutrons zwischen Zeitschritten weiterreichen, verfügen LSTM-Zellen über einen sogenannten Zellenstatus c (eng. Internal State). Dieser Zellenstatus repräsentiert ein Signal, was parallel zu dem eigentlichen Zellengewicht zwischen den Zeitschritten weitergereicht wird und in jedem Zeitschritt von der Zelle angepasst werden kann. (Hochreiter & Schmidhuber, 1997)

Eine solche LSTM-Zelle ist in Abbildung 2.3 dargestellt. Die genaue Signalverarbeitung innerhalb der Zelle ist für diese Arbeit nicht relevant und wird daher nicht vertiefend dargestellt. Relevant ist jedoch die grobe Struktur des Zellenstatus. Auch eine klassische RNN-Zelle kann Signale über mehrere Zeitschritte speichern, da diese durch den versteckten Status h_t als Input mit x_t in die nächste RNN-Zelle eingehen. Zum Vergleich ist der Aufbau einer klassischen RNN-Zelle in der Abbildung A.5 dargestellt. Innerhalb der Zelle werden

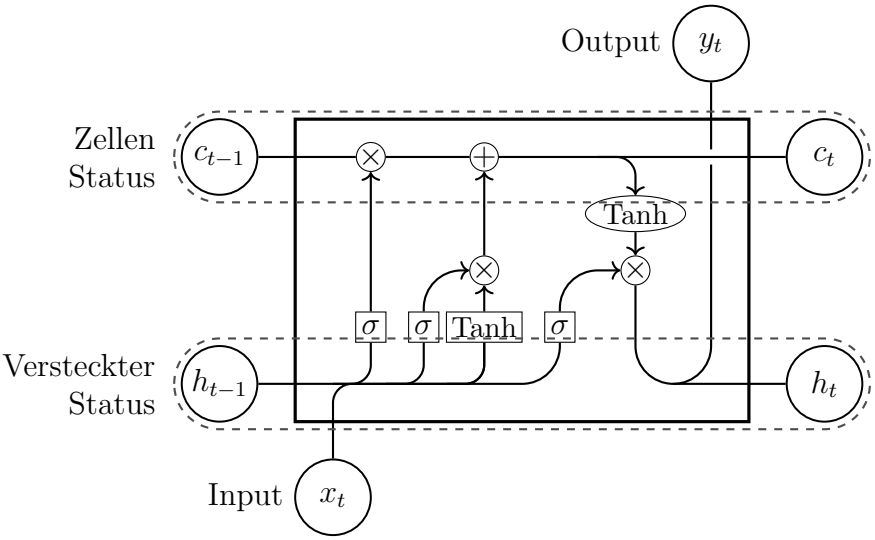

Abbildung 2.3.: LSTM-Zelle
(Quelle: In Anlehnung an Christopher Olah, 2015)

die Signale von x_t und h_{t-1} aggregiert und nicht gesondert verarbeitet. Demnach ist $y_t = h_t$. Da die Signale von h in jedem weiteren Zeitschritt teilweise durch x_t überschrieben werden, kommt es zu verschwindenden Gradienten (siehe Abbildung 2.2).

Der Zellenstatus c_t einer LSTM-Zelle wird nicht in jedem Zeitschritt mit x_t „verwässert“. Drei sogenannte Gates steuern die Zufuhr und Entfernung von Signalen aus dem Zellenstatus c (siehe Abbildung A.6). Ein Forget-Gate ermöglicht es der Zelle irrelevante Daten aus dem Zellenstatus zu entfernen und ein Input-Gate ermöglicht es neue Daten dem Zellenstatus zuzuführen. Ob also Signale weiter langfristig im Zellen Status gespeichert werden, obliegt der Zelle selbst. Somit können langfristige Abhängigkeiten in Sequenzen auch über lange Zeiträume in dem Zellenstatus der LSTM-Zellen gespeichert werden.

Ebenso der Signaleinfluss, den der Zellenstatus c_t auf den Output der Zelle h_t / y_t hat, ist in einer LSTM-Zelle durch ein Output-Gate gesteuert. Der Zellenstatus fließt also zu Ende gefiltert in den Zellen-Output h_t / y_t ein. Zu der nächsten Zelle wird c_t, h_t (und y_t) weitergegeben (wobei $y_t = h_t$).

2.1.5. Zusammenfassung: Terminologie

Künstliche Intelligenz umfasst eine Vielzahl von Begriffen, welche in den vergangenen Kapiteln definiert und erläutert wurden. Diese sollen in diesem Abschnitt nochmals kurz gemeinsam betrachtet werden. In Abbildung A.7 wurden ebenso alle Begriffe in einem Venn-Diagramm angeordnet.

Künstliche Intelligenz bildet den Oberbegriff aller betrachteter Modelle und beschreibt Methoden der Informatik aller Art, menschliches Verhalten und Denken nachzubilden. Kerngebiete sind hier das menschliche Lernen, rationelles Denken, Problemlösekompetenzen und Entscheidungskompetenzen. **Machine Learning** ist der Bereich der KI, welcher sich auf das Lernen durch verschiedenste Modelle fokussiert. Hier gibt es unterschiedliche Ansätze, um Daten gezielt oder ungezielt zu klassifizieren oder Prognosen durch Regressionen zu erstellen.

Modelle, die sich in ihrer Funktionsweise und ihrem Aufbau an dem menschlichen Gehirn orientieren, sind sogenannte **Neuronale Netzwerke**. Diese Modelle verarbeiten Daten anhand von Neuronen, welche auf Schichten angeordnet sind und untereinander verknüpft sind, um die Input-Daten mit den Zielgrößen zu verbinden. NN mit einer Vielzahl an Schichten sind Teil des **Deep Learning**. Durch besonders tiefe Netze können Probleme abstrahiert und durch einfachere Konzepte dargestellt werden. Diese Modelle können selbst mit sehr komplexen Daten arbeiten, benötigen jedoch einen großen Datensatz für Ihren Trainingsprozess.

Mehrschichtige Perzeptren sind die am häufigsten verwendeten Modelle des DL. Diese verarbeiten Signale immer in einseitiger Richtung zu der Zielgröße. Es findet somit keine Rückkopplung zwischen den Neuronen statt. Bestehen zwischen den Durchläufen eines Modells Rückkopplungen, handelt es sich um **Rekurrente Neuronale Netze**. Aufgrund dieser Rückkopplungen können RNN-Modelle Daten aus vergangenen Perioden verarbeiten, was sie besonders effektiv für die Verarbeitung von Sequenzen macht.

Während sich RNN-Modelle sehr effektiv darin erweisen, kurzfristige Abhängigkeiten in einer Sequenz zu erkennen und zu speichern, so erweist sich die Erkennung langfristiger Abhängigkeiten als schwierig. Dies liegt am Problem instabiler Gradienten (Kapitel 2.1.4). **Long Short-Term Memory** Modelle sind eine Weiterentwicklung der klassischen RNNs und ermöglichen es durch einen gesonderten Zellenspeicher auch langfristige Abhängigkeiten zu erfassen und über einen langen Zeitraum zu speichern.

2.2. Einfluss der ökonomischen Variablen

Um den Einfluss ökonomischer Variablen auf die Leistung des LSTM-Modells zu analysieren, werden in dieser Arbeit vier ökonomische Variablen getestet: der risikolose Zinssatz, die Inflation, Währungskurse und Rohstoffpreise. DL-Modelle wie das LSTM-Modell, welches in dieser Thesis angewandt wird, sind zu einem gewissen Maße eine „Black-Box“. Während sich die Leistung der Modelle feststellen lässt, so sind die Einflüsse einzelner Merkmale in

dem Modell und dessen Verarbeitungsstruktur kaum festzustellen.

Aus diesem Grund soll der kausale Zusammenhang der analysierten Merkmale mit dem Aktienkurs nach fundamentaler Theorie dargestellt werden. Zunächst wird in Kapitel 2.2.1 der grundlegende Marktmechanismus zur Preisbildung eingeführt und Ansätze zur Aktienkursprognose diskutiert. Ebenso wird hier die Hypothese der effizienten Märkte dargestellt, welche die Überleitung zum intrinsischen Unternehmenswert bildet (Kapitel 2.2.2). Anhand dessen wird die kausale Verbindung der vorher genannten Merkmale mit dem Aktienkurs hergestellt.

2.2.1. Aktienkursprognosen und effiziente Märkte

Methoden der Aktienkursprognose

In der Dynamik des Aktienmarktes, wo Preise durch das ständige Wechselspiel von Angebot und Nachfrage geformt werden, treten zwei grundlegende Ansätze hervor, um diese Preise zu verstehen, zu analysieren und zu prognostizieren.

Nach dem Ansatz der **adaptiven Erwartungen** basieren die Erwartungen der Investoren an den Preis eines Wertpapiers allein auf dem vergangenen Kursverlauf des Wertpapiers. Die technische Analyse verfolgt diesen Ansatz und geht davon aus, dass sich Strukturen innerhalb eines Kursverlaufs langfristig wiederholen. Durch die Analyse des Kursverlaufs werden Trends, Strukturen und Preisniveaus identifiziert, die Rückschlüsse auf die künftige Kursentwicklung einer Aktie ermöglichen. (Arnold & Lewis, 2019)

Ein Kritikpunkt der Theorie der adaptiven Erwartungen ist, dass es für einen Investor irrational wäre, sich bei seiner Erwartungsbildung auf die Kursdaten zu beschränken und nicht alle verfügbaren Informationen in seine Erwartung mit einfließen zu lassen. Nach dem Ansatz der **rationalen Erwartungen** beziehen Menschen bei ihren Erwartungen immer alle verfügbaren Informationen ein (Muth, 1961). Aus diesem Ansatz entspringt die fundamentale Analyse, die jeder Aktie zu jedem Zeitpunkt einen inneren Wert zurechnet, welcher sich durch alle öffentlich verfügbaren Informationen berechnet (Damodaran, 2012).

Die Hypothese effizienter Märkte

Angenommen ein Großteil aller Teilnehmer an dem Aktienmarkt handelt rational, so ist der Preis, der sich für ein Wertpapier bildet, die beste Prognose für dieses Wertpapier zu dem aktuellen Zeitpunkt auf Basis aller aktuell verfügbaren Informationen. Diese Prognose wird naturgemäß nicht korrekt sein, da sich im Verlauf der Zeit die Informationslage zu dem Wertpapier und damit auch dessen Preis ändern wird. Dieses grundlegende

Konzept der rationalen Erwartungen von Muth, 1961 bezieht sich generell auf alle von dem Menschen gemachten Prognosen und wurde durch Fama, 1995 in Form der „Efficient Market Hypothesis“ auf den Aktienmarkt übertragen.

In der schwachen Form des effizienten Marktes sind alle Informationen in Form des Kursverlaufs bereits eingepreist und es ist nicht möglich allein durch historische Kursdaten Kursprognosen abzuleiten. Diese Theorie stützt sich auch auf die Annahme, dass Aktienkurse als „Random Walks“ zu klassifizieren sind, es also keine Autokorrelationen oder andere statistischen Zusammenhänge innerhalb des Kursverlaufes gibt, welche informationstragend für eine Prognose wären (Kendall & Hill, 1953). In der semi-starken Form des effizienten Marktes spiegeln die aktuellen Gleichgewichtspreise eines Wertpapiers alle vergangenen Kursdaten und alle öffentlich verfügbaren Informationen wider. In der starken Form des effizienten Marktes stellen diese zudem noch inoffizielle Informationen wie beispielsweise eine geplante Übernahme dar. (Fama, 1970)

Seit der Veröffentlichung der Hypothese effizienter Märkte konnte der Großteil der Studien in dem Bereich die Hypothese nicht widerlegen (Fama, 1970). Dies hat Auswirkungen auf die genannten Ansätze zur Prognose der Aktien, besonders für die technische Analyse:

> „If the random walk model is a valid description of reality, the work of the chartist [de: technischer Analyst], like that of the astrologer, is of no real value in stock market analysis“ (Fama, 1995, S. 80)

Wenn Märkte semi-effizient sind, dann repräsentieren die Preise einer Aktie zu jeder Zeit im Durchschnitt nach allen öffentlichen Informationen den fundamentalen Wert der Aktie. Bis neue Informationen in den Kurs einer Aktie eingepreist werden, benötigt es Analysten, welche diese neuen Informationen erkennen, einordnen und einen neuen fundamentalen Wert für die Aktie feststellen. Liegt dieser höher als der aktuelle Preis der Aktie, treiben Sie durch Ihre Nachfrage den Kurs wiederum zu seinem fundamentalen Wert. Das Handeln eines fundamentalen Analysten ermöglicht also nur überdurchschnittliche Renditen, wenn er neue Informationen früher als der Markt erkennt. (Fama, 1995)

2.2.2. Der intrinsische Unternehmenswert

Das Discounted Cashflow Modell

Nach der fundamentalen Theorie entspricht der Gleichgewichtspreis einer Aktie zu jeder Zeit im Durchschnitt dem intrinsischen Wert des Unternehmens. Der intrinsische Wert w einer Anlage entspricht den Barwerten sämtlicher zukünftiger Zahlungen z, die durch den Besitz

dieser Anlage generiert werden. Die Barwerte berechnen sich durch den Abzinsungsfaktor k, welcher die Mindestrendite für die Anlage angibt. (Damodaran, 2012)

$$w = \sum_{t=1}^{\infty} \frac{z_t}{(1+k)^t} \tag{2.4}$$

Im Kontext einer Aktie, die ein Unternehmen repräsentiert, profitiert der Investor infolge des Aktienbesitzes an Zahlungsströmen durch zwei Mechanismen. Einerseits erfolgen Zahlungen durch Aktienrückkäufe, die den Aktienkurs erhöhen und den Veräußerungswert steigern, und andererseits durch die Ausschüttung von Dividenden. Beide dieser Zahlungen erfolgen bei Unternehmen auf Basis des Free Cash Flow (FCF). Dieser repräsentiert, wie viel Cash (also liquide Mittel) innerhalb des Unternehmens für die Zahlung von Dividenden, Aktienrückkäufen sowie auch Aufnahme und Rückzahlung von Darlehen verfügbar ist. Der FCF abzüglich des Fremdkapital-Effekts ergibt den Free Cash Flow to Equity (FCFE) (Damodaran, 2012). Diese liquiden Mittel stehen dann ausschließlich den Eigenkapitalgebern zur Verfügung. Es sei hier jedoch angemerkt, dass diese Gelder nicht zwangsweise ausgeschüttet werden müssen.

$$\begin{aligned} FCFE = &\text{ Net Income} \\ &- (\text{Capital expenditures} - \text{Depreciation}) \\ &- (\text{Change in noncash working capital}) \\ &+ (\text{New debt issued} - \text{Debt repayments}) \end{aligned} \tag{2.5}$$

Da sich der zukünftige FCFE nur über eine gewisse Periode mit annähender Genauigkeit prognostizieren lässt, wird ein Phasenmodell eingesetzt. Über eine Planungsphase von n Perioden (z.B. Jahre) werden die zukünftigen FCFE prognostiziert. Bei einer Bewertung von Unternehmen wird jedoch grundsätzlich ein unendliches Fortführen angenommen. Deshalb wird zu der Planungsphase der Terminalwert addiert, welcher den Wert des Unternehmens ab der Planungsphase in die Unendlichkeit approximiert. Dieser wird durch das Gordon-Growth-Modell berechnet (Gordon, 1959). Hierbei wird angenommen, dass die FCFE mit einer konstanten Wachstumsrate g bis in die Unendlichkeit wachsen.

$$w = \frac{FCFE_{n+1}}{k - g_n} \tag{2.6}$$

Fasst man nun die Planungsphase mit dem Terminalwert zusammen, erhält man die Formel des Discounted Cashflow Model (DCF). Der resultierende Wert gibt den Wert

des Eigenkapitals des bewerteten Unternehmens an und muss durch die Anzahl der ausstehenden Aktien geteilt werden, um den inneren Wert einer Aktie des Unternehmens zu erhalten. Optional kann der FCFE direkt auf „pro-Aktien Basis“ berechnet werden.

$$w = \sum_{t=1}^{t=n} \frac{FCFE_t}{(1+k)^t} + \frac{FCFE_{n+1}}{(k-g)^n} \tag{2.7}$$

Capital Asset Pricing Model

Der Abzinsfaktor k entspricht den Eigenkapitalkosten des Unternehmens. Die Eigenkapitalkosten entsprechen der Rendite, die ein Investor fordert, um Kapital in das Bewertungsobjekt zu investieren. Das Capital Asset Pricing Model (CAPM) von Sharpe, 1964 und Lintner, 1965 basiert auf der modernen Portfoliotheorie von Markowitz, 1952 und wird auch heute noch primär zur Approximation der Eigenkapitalkosten eines Unternehmens verwendet. Um kausale Einflüsse der untersuchten Merkmale auf den intrinsischen Unternehmenswert zu verstehen, soll dieses Modell hier kurz dargestellt werden. Für eine genauere Betrachtung der Theorie und empirisch neuen Ansätzen wird auf das Paper von Fama und French, 2004 verwiesen.

Die Basis der Renditeerwartung eines Investors an ein Investment mit Eigenkapital ist der risikolose Zinssatz r_f. Als risikoloser Zinssatz wird zumeist die Verzinsung von langfristigen Anleihen von Staaten höchster Kreditwürdigkeit herangezogen. Die Zinsen, die auf Anleihen gezahlt werden, sind fix und nicht volatil wie beispielsweise die Rendite einer Aktie. Zudem ist das Ausfallrisiko von Staaten höchster Kreditwürdigkeit minimal. Zusätzlich zu dem risikolosen Zinssatz r_f verlangt der Investor eine Marktrisikoprämie, die das zusätzliche Risiko widerspiegelt, welches der Investor eingeht, indem er in das Marktportfolio r_m und nicht in r_f investiert. Diese Marktrisikoprämie ist demnach die Differenz zwischen der Rendite eines Marktportfolios r_m wie beispielsweise dem S&P 500 und dem risikolosen Zinssatz r_f.

Jeder Investor hält aufgrund homogener Informationslage und Erwartungen an den Markt das Marktportfolio r_m. Es wird zwischen dem systematischen Risiko (Marktrisiko) und dem unsystematischen Risiko (unternehmensspezifisches Risiko) unterschieden. Durch die Diversifikation des Marktportfolios r_m kann der Investor das unsystematische Risiko vollständig vermeiden. Das systematische Risiko ergibt sich durch Faktoren, welche sich auf die ganze Wirtschaft auswirken und daher nicht weg-diversifiziert werden können. Da jeder Investor das Marktportfolio r_m hält, definiert sich das zusätzliche Risiko in eine Anlage zu investieren durch die Korrelation dessen zum systematischen Risiko. Das Marktportfolio

r_m enthält nur noch das systematische Risiko. Berechnet man nun die Regression des Marktportfolios r_m mit der zu bewertenden Anlage, so ergibt sich Beta β. Ist Beta β größer als 1, weist die Anlage eine stärkere Anfälligkeit auf das systematische Risiko auf und fügt dem Marktportfolio r_m des Investors weiteres Risiko hinzu. Errechnet sich ein Beta β geringer als 1, so ist die Anlage weniger anfällig für das systematische Risiko und lindert das Risiko des Marktportfolios r_m des Investors. Es ergibt sich eine gewichtete Marktrisikoprämie von $\beta(r_m - r_f)$.

Zusammenfassend ergeben sich die Eigenkapitalkosten r des CAPM durch Summe aus risikolosem Zinssatz und der durch Beta gewichteten Marktrisikoprämie:

$$r = r_f + \beta(r_m - r_f) \tag{2.8}$$

Einige Annahmen des CAPM entsprechen nicht exakt der Marktrealität wodurch es lediglich als eine Annäherung der Eigenkapitalkosten eines Unternehmens betrachtet werden kann. Obwohl im Laufe der Zeit weitere Modelle entwickelt wurden, um die Eigenkapitalkosten präziser zu schätzen, bleibt das CAPM aufgrund seiner Anwendungseinfachheit weiterhin relevant. (Arnold & Lewis, 2019)

2.2.3. Einfluss des risikolosen Zinssatzes

Der risikolose Zinssatz bildet die Basis des CAPM, welches innerhalb des Bewertungsmodells als Eigenkapitalkosten den Abzinsungsfaktor repräsentiert. Erhöhen sich die Eigenkapitalkosten, mindert dies den intrinsischen Unternehmenswert. Der risikolose Zinssatz stellt innerhalb des CAPM zum einen den Basiszinssatz (also den ersten Summanden) dar und wird des Weiteren zur Berechnung der Marktrisikoprämie verwendet. Durch eine Umstellung der CAPM Formel lässt sich der Einfluss des risikolosen Zinssatzes gesondert betrachten:

$$\begin{aligned} r &= r_f + \beta(r_m - r_f) \\ r &= r_f + \beta r_m - \beta r_f \\ r &= \beta r_m + r_f(1 - \beta) \end{aligned} \tag{2.9}$$

Wie sich eine Veränderung des risikolosen Zinssatzes auf die Eigenkapitalkosten auswirkt, ist abhängig von Beta. Das ist durch die Theorie hinter dem CAPM begründet. Jeder Investor kann durch eine Mischung von risikofreiem Kapital (durch beispielsweise langfristige Staatsanleihen) und durch das Marktportfolio für jedes Risiko (gemessen in Beta) ein Portfolio kreieren.

Durch eine geteilte Anlage in risikolose Anlagen und in das Marktportfolio lassen sich Gesamtportfolios mit geringerer Varianz als dem Marktportfolio erstellen. Strebt der Investor eine höhere Rendite als die des Marktportfolios mit einer entsprechend höheren Varianz an, kann er Kapital zu dem risikofreien Zinssatz aufnehmen und dieses neben seinem eigenen Kapital in das Marktportfolio investieren. Dieser Zusammenhang lässt sich auch gut in Abbildung A.8 erkennen.

Weist die Aktie also ein geringeres systematisches Risiko (Volatilität) als das Marktportfolio auf, ist $\beta < 1$ und der Investor würde durch teilweise Anlage in risikolose Anlagen die Volatilität seines Portfolios senken. Daher wirkt sich in diesem Falle ein geringerer risikoloser Zinssatz negativ auf die Gesamtportfoliorendite und somit auf die Eigenkapitalkosten aus. Ist $\beta > 1$ würde der Investor Kapital zum risikolosen Zinssatz aufnehmen, um das Marktportfolio mit Fremdkapital zu hebeln und höhere Rendite mit höherer Volatilität zu erreichen. Würde in diesem Fall der risikolose Zinssatz steigen, so würde dies die von dem Investor durch sein Gesamtportfolio erzielbare Rendite lindern. Da der Investor zu gegebenem Beta nun eine geringere Rendite erzielen kann, lindert dies auch seine Erwartungen und somit die Eigenkapitalkosten des Unternehmens. Sei $\beta = 1$, so hat der risikolose Zinssatz kein Einwirken auf die Eigenkapitalkosten da $r = r_m$. Der Investor müsste hier, um zu gleicher Volatilität des Marktportfolios zu gelangen, all sein Kapital in gleich diesem anlegen, weshalb der risikolose Zinssatz in diesem Falle irrelevant ist.

Das CAPM ist in seiner grundlegenden Form wie bisher in dieser Thesis dargestellt ein Risiko-Rendite-Modell. Es ordnet einem bestehenden Risiko, welches durch Beta ausgedrückt wird, eine zu erwartende Rendite zu. Seit der Entwicklung des CAPMs haben sich jedoch fortwährend neue Ansätze und Veränderungen in der Anwendung des Modells ergeben. Obwohl sich das Modell heute in der Praxis überwiegend zu anderen Risiko-Rendite-Modellen durchsetzt, wird die Formel heute meist leicht angepasst berechnet. Die Marktrisikoprämie wird zumeist nicht mehr variabel durch $r_m - r_f$ berechnet, sondern vielmehr als zeitlich konstante Variable betrachtet (Damodaran, 2012). Die Marktrisikoprämie gibt die durchschnittliche zusätzliche Rendite an, die ein Investor fordert, anstatt von risikolosen Anlagen in Wertpapiere zu investieren. Praktisch ausgedrückt, stellt die Marktrisikoprämie die Renditedifferenz über einen längeren Zeitraum (meist von 10 bis 50 Jahren) zwischen risikolosen Anlagen und dem Marktportfolio dar. Es zeigt sich, dass unter neuer Betrachtung eine Erhöhung des risikolosen Zinssatzes immer die Eigenkapitalkosten eines Unternehmens erhöht. Steigen die Eigenkapitalkosten und somit der Abzinsfaktor der zukünftigen FCFE sinkt der intrinsische Unternehmenswert.

2.2.4. Einfluss der Inflation

Inflation und Deflation bilden ein Maß zur Bewertung der Kaufkraft einer Währung über die Zeit. Nimmt die Kaufkraft einer Währung ab, handelt es sich um Inflation (Mishkin, 2016). Die Kaufkraft einer Währung wird durch den Verbraucherpreisindex (eng. Consumer Price Index) gemessen. Durch einen über die Zeit gleichbleibenden Warenkorb an Waren und Dienstleistungen wird die Kaufkraft einer Währung festgestellt. Die Veränderung dieser Kaufkraft ist die Inflation (Abnahme der Kaufkraft) oder Deflation (Zunahme der Kaufkraft).

Eine Schwächung der Kaufkraft einer Währung kann erhebliche Auswirkungen auf die Gesamtwirtschaft haben, und die direkten Wechselwirkungen zwischen Inflation und Wirtschaft sind komplex. Dieses Kapitel fokussiert sich darauf, einige der unmittelbaren Auswirkungen der Inflation auf den inneren Unternehmenswert darzustellen, es wird jedoch nicht auf alle Wechselbeziehungen eingehen. Ziel ist es zu erkennen, dass eine Wechselbeziehung zwischen Inflation und Unternehmenswert besteht und somit die Inflation einem Modell bei der Prognose von Aktienkursen hilfreich wäre.

Wirkung durch den Abzinsungsfaktor

Bei zunehmenden Inflationserwartungen sinken die Erwartungen, die Investoren an die Rendite von Anleihen haben. Bei gleichbleibender nominaler Rendite sinken bei steigender Inflation die realen Renditen. Die Nachfrage nach Anleihen nimmt ab. Da durch Inflation die realen Kosten Kapital aufzunehmen sinken, steigt das Angebot an Anleihen. Durch eine Verschiebung der Angebots- und Nachfragekurve für Anleihen entsteht ein neues Gleichgewicht auf einem niedrigeren Preisniveau. In Anbetracht des inversen Verlaufs zwischen dem Preis von Anleihen und den Zinssätzen resultiert diese Preisanpassung in einer Erhöhung der Zinssätze. Zusätzlich erhöhen Zentralbanken in Zeiten von Inflation die Leitzinsen, um die Geldmenge innerhalb der Wirtschaft und somit die Inflation zu lindern. Während sich die Verzinsung zwischen Anleihen unterschiedlicher Emittenten und Laufzeiten unterscheiden, so entwickeln sie sich langfristig in die gleiche Richtung. Die Verzinsung (Yield to Maturity) langfristiger Staatsanleihen, die als risikolose Rendite verwendet wird, bildet gemäß der Erwartungstheorie den erwarteten Durchschnitt der zukünftigen kurzfristigen Zinssätze (Hicks, 1939). Demnach steigt langfristig der risikolose Zinssatz mit dem generellen Zinsniveau. Eine Erhöhung des CAPM lindert den intrinsischen Unternehmenswert. (Mishkin, 2016)

Zusätzlich zu dem risikolosen Zinssatz kann die Inflation ebenso Einfluss auf die Mark-

trisikoprämie haben. Es wird, wie in Kapitel 2.2.3, eine konstante Marktrisikoprämie unterstellt, welche das zusätzliche Risiko der Investoren in Wertpapiere mit Risikokomponente zu investieren bemisst. Durch erwartete Inflation entsteht eine Unsicherheit für die Zukunft und die Marktrisikoprämie kann ansteigen (Damodaran, 2012). Hier gilt zudem, dass Unternehmen mit einem hohen Beta stärker auf Veränderungen der Marktrisikoprämie reagieren.

In Zusammenfassung lässt sich feststellen, dass steigende Inflationserwartungen zu einer Erhöhung des Abzinsungsfaktors führen, was den intrinsischen Unternehmenswert mindert.

Wirkung durch die Cashflows

Während sich die überwiegenden Effekte der Inflation durch den Abzinsungsfaktor auf alle Unternehmen ausschlägt, sind nicht alle Unternehmen im gleichen Maße anfällig gegenüber Inflationseinflüssen. Aufseiten der Kosten gibt es zwei entscheidende Faktoren. Je geringer die Marge eines Unternehmens, desto stärker lindert die Inflation dessen Cashflow. Zudem sind gerade Rohstoffe stärker der Inflation ausgesetzt. Unternehmen, welche für ihre Produkte auf diese Rohstoffe angewiesen sind, verbuchen höhere Cost Of Goods Sold (COGS). Ob Unternehmen die durch die Inflation gestiegenen Kosten an ihre Kunden weitergeben können, hängt von dessen Preismacht ab. Unternehmen mit geringen Margen und schlechter Preismacht, können ihre erhöhten Kosten nicht an den Kunden weitergeben und das Ergebnis dieser Unternehmen sinkt. Ebenso ist es möglich, dass die Kosten mancher Unternehmen im Vergleich weniger steigen, als diese durch das Argument Inflation ihre Preise erhöhen können. Außerdem erschwert es der erhöhte CAPM allen Unternehmen in Zeiten starker Inflation große Investitionen zu rechtfertigen. Der langfristige Wachstumsfaktor kann somit verringert werden. (Damodaran, 2012)

Zusammenfassung

Ob Inflation einen negativen Effekt auf den intrinsischen Wert eines Unternehmens hat, hängt nun davon ab, ob der negative Effekt durch den Abzinsungsfaktor den womöglich positiven Effekt durch die Cashflows übertrifft. Meist jedoch ist auch der Effekt der Cashflows negativ, da die Mehrkosten durch die Inflation die möglichen Preiserhöhungen überschreiten. Es zeigt sich empirisch, dass zwischen der Inflation und der Aktienrendite eine negative Relation besteht und sich unter Annahme der effektiven Märkte die Inflation also negativ auf den intrinsischen Unternehmenswert auswirkt (Bodie, 1976; Fama & Schwert, 1977).

2.2.5. Einfluss von Wechselkursen

Der Wechselkurs einer Währung gibt den Wert dieser notiert in einer weiteren Währung an. Eine Wertsteigerung oder Wertminderung einer Währung A relativ zu einer Währung B ändert die Kaufkraft, welche die Währung A bei einer Anlage notiert in Währung B hat. Da Unternehmen unterschiedlich stark internationalen Transaktionen und in ausländischer Währung notierten Anlagen ausgesetzt sind, unterscheidet sich auch die Sensibilität verschiedener Unternehmen auf die Wechselkurse. (Mishkin, 2016)

Ein Konzept zur Bewertung der Sensibilität von Unternehmen auf Wechselkurse wurde von Flood und Lessard, 1986 entwickelt: Grundlegend lässt sich zwischen dem Vertragsrisiko (eng. contractural exposure) und dem operativen Risiko (eng. operating exposure) unterscheiden. Unternehmen haben ein **Vertragsrisiko** bei Cashflows, welche bereits in ihrem nominalen Wert festgesetzt wurden. Dies sind beispielsweise Forderungen oder Verbindlichkeiten notiert in Fremdwährungen, dessen realer Wert mit den Wechselkursen schwankt. Das **operative Risiko** bezieht sich auf die Auswirkungen von Wechselkursänderungen auf den künftigen operativen Cashflow eines Unternehmens. Hier sind wesentlich zwei Märkte zu betrachten. Zum einen der Absatzmarkt und darüber hinaus der Beschaffungsmarkt des Unternehmens. Es ergeben sich vier Klassen von Unternehmen (siehe Abbildung A.9). Unternehmen, welche aus einem lokalen Beschaffungsmarkt (notiert in der Lokalwährung) in internationale Märkte mit Fremdwährungen vertreiben, werden als Export-Unternehmen klassifiziert. Unternehmen mit Fremdwährung-notierten internationalen Beschaffungsmärkten und lokalen Absatzmärkten sind folglich als Import-Unternehmen klassifiziert. Unternehmen mit lokalen Absatz- wie Beschaffungsmärkten sind Lokal-Unternehmen. Unternehmen mit internationalen Absatz- sowie Beschaffungsmärkten sind internationale Unternehmen. Es wird angenommen, dass alle Unternehmen ihre Ergebnisse in der lokalen Währung notieren. Bei einer Wertsteigerung der lokalen Währung relativ zu der Fremdwährung reagieren die vier Unternehmensklassen unterschiedlich. Da die Fremdwährung gegen die Lokalwährung eine Wertminderung erfährt, sinkt der Wert der Umsätze des Export-Unternehmens. Da die Kosten lokal notiert sind, bleiben diese konstant und das Ergebnis des Unternehmens verschlechtert sich. Ebenso das Ergebnis des internationalen Unternehmens, dessen Ergebnis aber in der lokalen Währung notiert ist, verschlechtert sich. Im Gegensatz profitiert ein Importunternehmen von einer Wertsteigerung der lokalen Währung. Das lokale Unternehmen ist nicht von der Wertsteigerung betroffen, da keine Transaktionen mit Fremdwährungen bestehen. Das Ergebnis des lokalen Unternehmens bleibt unverändert. Wie stark sich das Ergebnis der Unternehmen in Abhängigkeit der

Wechselkurse verändert, ist bedingt durch die Marge des Unternehmens. Je größer die Marge der Unternehmen, desto signifikanter ist der Währungseffekt. (Flood & Lessard, 1986)

Grundsätzlich sind also gerade Export- und Import-Unternehmen dem Risiko von Wechselkursen ausgesetzt. Während sich das Vertragsrisiko der Unternehmen beispielsweise durch Hedging minimieren lässt, so haben Unternehmen auf das operative Risiko keinen Einfluss. Eine Veränderung des Ergebnisses der Unternehmen in Form des Jahresüberschusses fließt durch den operativen Cashflow in die FCFE ein und senkt oder steigert den Unternehmenswert. Es lässt sich also nicht allgemein für jedes Unternehmen betiteln, welche Auswirkung eine Veränderung des Wechselkurses auf den intrinsischen Unternehmenswert hat. Dennoch stellt der Wechselkurs einen elementaren Faktor für alle Unternehmen und Wirtschaften dar, welche durch Import oder Export von Wechselkursen abhängig sind.

2.2.6. Einfluss von Rohstoffpreisen

Der Einfluss von Rohstoffpreisen auf den intrinsischen Unternehmenswert ist hochgradig unternehmensspezifisch. Unternehmen, deren Geschäftstätigkeiten stark von Rohstoffen abhängen, sind besonders anfällig für Preisschwankungen von Rohstoffen. Diese Unternehmen können in unterschiedlichem Maße von steigenden oder fallenden Rohstoffpreisen beeinflusst werden, abhängig von ihrer Positionierung in der Wertschöpfungskette, ihrer Fähigkeit zur Preisanpassung, und ihrer Risikomanagementstrategien (beispielsweise Hedging-Strategien). Generell sind Unternehmen, die Rohstoffe als Hauptproduktionsfaktoren verwenden, direkteren Preisschwankungen ausgesetzt. Steigende Rohstoffpreise können die operativen Kosten erhöhen und somit die Margen des Unternehmens beeinträchtigen. Umgekehrt könnten fallende Rohstoffpreise die Margen dieser Unternehmen verbessern. Besitzt ein Unternehmen die nötige Preismacht, die Schwankungen in den Rohstoffpreisen an den Kunden weiterzugeben, kann dies die Rentabilität ebenso stabil halten. Abhängig von der Betroffenheit der Unternehmen, können Preisänderungen der verwendeten Rohstoffe also positive, negative oder auch keine Auswirkungen auf Cashflows und somit den intrinsischen Unternehmenswert haben. Empirisch zeigt sich ein jedoch eher geringerer Einfluss von Rohstoffpreisen auf Unternehmen verglichen mit dem Einfluss von beispielsweise dem Zinssatz oder Währungskursschwankungen. Grund hierfür könnte sein, dass die Unternehmen, welche stark von Rohstoffpreisen betroffen sind, sich ihrem Risiko zumeist bewusst sind und Risikomanagement in Form von Hedging betreiben. (Bartram, 2005)

3. Aktueller Forschungsstand

Das Bestreben, Aktienkurse verlässlich prognostizieren zu können, ist fundamental gesetzt durch die hiermit zu erreichenden Renditen. Jedoch sind die Finanzmärkte höchst komplex und die Zusammenhänge zwischen den unterschiedlichen Treibern der Aktienpreise schwer zu verstehen. Einige hiervon wurden bereits in Kapitel 2 vorgestellt. Ebenso ist es nach der „Efficient Market Hypothesis“ in seiner stärksten Form, selbst mit Insider-Informationen nicht möglich, den Markt langfristig durch Handeln zu übertreffen (Fama, 1970). Heute wird oft angezweifelt, dass Märkte in der stärksten Form effizient sind und es finden sich empirische Hinweise von irrationalem Handeln am Markt oder Hinweise von Mustern innerhalb von Aktienkursen (Lo & MacKinlay, 1988; Schwert, 2013).

Mit dem Aufschwung von KI stieg ebenso das Interesse Aktienkurse anhand verschiedenster ML-Modelle zu prognostizieren. Kumbure et al., 2022 identifiziert drei aktuelle Trends in dem Bereich der Aktienkursprognose mit ML: Zuerst besteht ein starker Trend zu der Nutzung von DL-Modellen, wie auch beispielsweise dem LSTM-Modell. Zweitens werden zunehmend Prognosen von mehreren Modellen kombiniert. Drittens ist die Auswahl und Transformation der Merkmale, welche für die Modelle genutzt werden, relevanter geworden. Durch diesen vorgelagerten Schritt sollen die Modelle effizienter, simpler und genauer werden. (Kumbure et al., 2022)

Fischer und Krauss, 2018 zeigten als erste das Potenzial von LSTM-Modellen zur Aktienkursprognose. Sie verglichen die Leistung von LSTM-Modellen anhand eines Datensatzes des S&P 500 Indexes von 1992 bis 2015 mit anderen Modellen, ohne einen versteckten Status, wie beispielsweise klassische NN oder DL-Modelle. In dem gegebenem Versuch übertraf die Leistung des LSTM-Modells die der anderen Modelle. In dem Zeitraum von 1992 bis 2009 konnte das Modell Renditen über dem Markt erreichen. Ab dem Jahr 2010 sind die Überrenditen primär durch Arbitrage ausgeglichen worden und das Modell konnte nach Transaktionskosten keinen wirtschaftlichen Gewinn mehr erzielen.

Heutige Studien verwenden oft eine Vielzahl von Merkmalen zur Prognose (Kumbure et al., 2022). Beispielsweise Zhong und Enke, 2019 nutzen einen Datensatz von 60 ökonomischen und fundamentalen Merkmalen zur Prognose der täglichen Bewegungsrichtung des

S&P 500. Sie verwendeten eine Kombination mehrerer Modelle zur Prognose, welche sie auf zwei Merkmal-Datensätzen trainierten. Erstens dem kompletten Merkmal-Datensatz und zweitens einem durch die PCA transformiertem Datensatz. Die Modelle trainiert auf dem transformierten Merkmal-Datensatz wiesen eine signifikant höhere Genauigkeit auf.

Tsai und Hsiao, 2010 verwendeten eine Mehrzahl von Modellen zur Merkmal-Selektion durch Faktorenanalyse (unter anderem auch die PCA). Von einem Datensatz von ursprünglich 85 Merkmalen konnten 80% statistisch irrelevante Faktoren herausgefiltert werden.

Nti et al., 2019 prognostizierte Aktienkurse der Ghana Stock Exchange über mehrere Branchen durch Anwendung zweier Prozessschritte, um die Relevanz einzelner ökonomischer Variablen festzustellen. Durch einen Random Forest Algorithmus wurden für jede Branche aus einem Pool von 42 ökonomischen Variablen die relevantesten ausgewählt. In einem zweiten Schritt wurden Prognosen anhand eines LSTM-Modells generiert und evaluiert. Durch die selektierten ökonomischen Variablen konnte die Leistung gegenüber klassischen Vorgehen verbessert werden.

Niaki und Hoseinzade, 2013 prognostizierten die täglichen Kursbewegungen des S&P 500 Indexes anhand eines künstlichen NN. Zusätzlich zu den Kursdaten nutzten Sie eine Reihe an Experimenten, um aus 27 potenziellen ökonomischen Merkmalen, die Relevanten auszuwählen. In einem ersten Schritt wurden die Korrelationen aller Paare an Merkmalen berechnet und bei einer starken Korrelation eines der beiden Merkmale aus dem Datensatz entfernt. In einem zweiten Schritt wurden die überbleibenden Merkmale zu sechs Gruppen aggregiert. Durch ein NN-Modell wurden dann auf Basis der Kursdaten und der selektierten Merkmale Prognosen generiert. Anhand dieser Prognose wurde eine Handelsstrategie entwickelt, welche über den Handelszeitraum die Rendite einer Buy-&-Hold-Strategie signifikant übertraf.

Wie auch von Kumbure et al., 2022 als Trend identifiziert, zeigt sich auch in den hier vorgestellten Arbeiten ein zunehmender Fokus auf die Auswahl der Merkmale. Zumeist werden durch einen zusätzlichen Schritt relevante Merkmale für die Zielgröße durch ein weiteres Modell festgestellt. Diese Arbeit soll im Gegensatz den direkten Einfluss einzelner ausgewählter ökonomischen Variablen auf die Leistung des Modells testen, welches auch für die Prognose der Aktienkurse verwendet wird. Von einem Fokus auf Selektionsmodelle soll hier der Fokus auf den kausalen Zusammenhang der Merkmale und dem Aktienkurs gewendet werden. Dieser bleibt bei den dargestellten Studien zumeist unbeachtet. Das LSTM-Modell stellt sich in der Literatur als geeignetes Modell für die Aktienkursprognose dar und soll auch in diesem Versuch verwendet werden.

4. Methodik

4.1. Versuchsübersicht

In Kapitel 1.3 wurde folgende Forschungsfrage für diese Thesis formuliert: „Ziel dieser Arbeit ist es Erkenntnisse über die Wirkung von ausgewählten ökoomischen Variablen auf die Leistung von LSTM-Modellen zur Aktienkursprognose zu gewinnen“. Die Methodik zur Beantwortung der Forschungsfrage wird in diesem Abschnitt strukturell vorgestellt und in den Folgenden in seinen einzelnen Schritten gesondert beschrieben.

Bevor die LSTM-Modelle mit den entsprechenden Variablen (fortan Merkmale genannt) trainiert werden können, werden die benötigten Daten erhoben. Die technischen Preisdaten des Wertpapiers und die betrachteten ökonomischen Variablen werden über den Betrachtungszeitraum gesondert gesammelt. Anschließend werden die Merkmale aggregiert und in einem Datensatz für den nächsten Schritt vorbereitet. Es liegen nun alle benötigten Merkmale für den Modellierungsprozess vor.

Da der Einfluss einzelner zusätzlicher ökonomischer Merkmale auf die Leistung von LSTM-Modellen untersucht werden soll, benötigt es ein Vergleichsmodell. Die Leistung dieses sogenannten Basismodells wird dann als Benchmark für die Leistung der mit ökonomischen Merkmalen angehängten Modelle verwendet. Das Basismodell wird alleinig auf Basis der Preisdaten als Merkmale trainiert. Bevor die gesammelten und vorbereiteten Kurspreisdaten in einem Modell verwendet werden können, werden diese für den Trainingsprozess transformiert. Es folgt der Optimierungsprozess. Es werden drei Modell-Strukturen und eine Auswahl an Hyperparametern definiert. Unter diesen wird dann in dem Optimierungsprozess das Modell mit der besten Leistung ausgewählt. Das Modell wird durch mehrere Leistungsindikatoren bewertet, zum einen klassische Bewertungskennzahlen für Zeitreihen-Regressionen und zum anderen die Rendite von simulierten Handelsstrategien. Die Handelssimulation dient der Evaluation der Modellleistung mit ökonomischen Intentionen und wird mit einer klassischen Buy-&Hold-Strategie verglichen.

Nach der Definition, Optimierung und Auswertung des Basis-Modells, werden die Modelle mit angefügten ökonomischen Merkmalen getestet (genannt Versuchsmodelle). Den

Merkmalen des Basis-Modells wird jeweils eine der ökonomischen Variablen angehangen. Ebenso werden einem Modell alle betrachteten ökonomischen Variablen angehangen. Die neuen Merkmal-Konfigurationen werden wiederum für den Trainingsprozess transformiert. Da bei jedem Versuch nur die Merkmale als Variable des Versuchs verändert werden sollen, bleiben die Modellstruktur und die Hyperparameter des Basismodells auch für die neuen Modelle bestehen. Die Leistung jedes neuen Modells (mit den neuen Merkmal-Konfigurationen) wird durch die oben genannten Leistungsindikatoren bewertet.

Die Leistungen der Versuchsmodelle und des Basismodells werden verglichen und geben Aufschluss über den Einfluss der einzelnen ökonomischen Variablen. Diese Ergebnisse werden in Kapitel 5 dargestellt und eingeordnet.

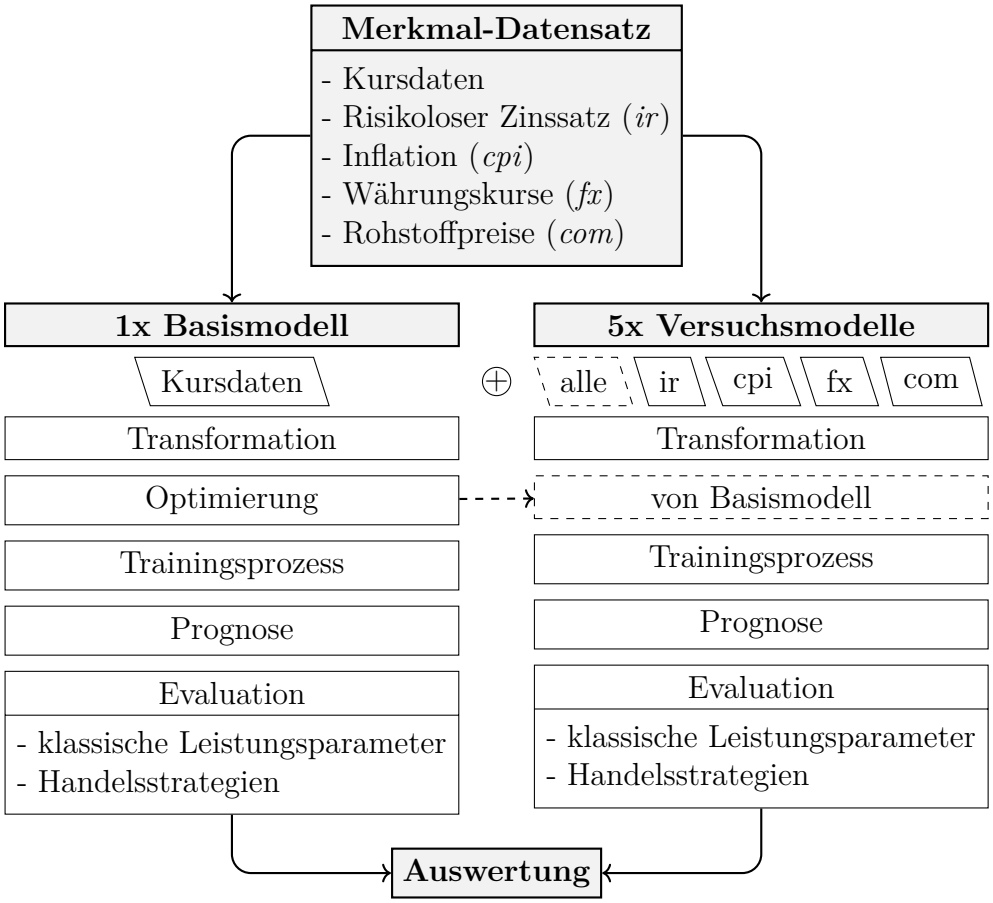

Abbildung 4.1.: Versuchsprozess (Quelle: Eigene Darstellung)

4.2. Datenerhebung und -vorbereitung

4.2.1. Gewählter Basisindex und Zeitraum

Da der kausale Einfluss von ökonomischen Variablen auf Unternehmen sehr individuell ist, wird in diesem Versuch ein Marktindex als Basis-Merkmal verwendet. Dieser repräsentiert die durchschnittlichen Reaktionen am Markt vieler Unternehmen auf Veränderungen der ökonomischen Variablen.

Es ist zwischen zwei Arten von Markt-Indexen zu unterscheiden. Ein Preis-Index repräsentiert alleinig die Kursveränderungen aller inkludierten Unternehmen. Zusätzlich zu dem Einkommen, das Investoren durch Kursgewinne erzielen, stellen Dividenden die zweite Quelle von Einkommen dar. Dividenden sind in einem Preis-Index nicht berücksichtigt. Ein Total-Return Index berücksichtigt neben den Kursgewinnen ebenso Dividendenzahlungen der Unternehmen. Da sich der innere Wert eines Unternehmens nach beider dieser Zahlungsströme richtet, wird in dieser Thesis ein Total-Return Index verwendet.

Der US-Aktienmarkt ist basierend auf der Marktkapitalisierung der weltweit Größte und ist demnach ebenso äußerst liquide wie gut dokumentiert. Folglich wird als Wertpapier für das Basis-Modell der **S&P 500 Total Return Index** gewählt. Der S&P 500 Index ist ein bekannter Aktienindex in den Vereinigten Staaten und umfasst 500 der größten börsennotierten Unternehmen, mit welchen 80% der US-Marktkapitalisierung abgedeckt werden (S&P Global, 2024). Er dient als repräsentative Messgröße für die Performance des US-Aktienmarktes. Da DL-Modelle besonders große Datensätze für einen erfolgreichen Lernprozess benötigen, wurden in diesem Versuch fünf Jahre an Daten auf täglicher Basis verwendet. Dies bildet einen Kompromiss zwischen der Datenmenge und der Rechenleistung, welche später für den Trainingsprozess benötigt wird. Der Zeitraum erstreckt sich von dem 01.12.2018 bis zum 01.12.2023. Die über den gegebenen Zeitraum exportierten Merkmale sind der Open-, Low-, High- und Close-Preis von jedem Handelstag innerhalb des Zeitintervalls. Alle Daten wurden von einem Bloomberg Terminal exportiert (Bloomberg, 2023e). Eine Darstellung des Kursverlaufes des S&P 500 Total Index findet sich in Abbildung A.10.

4.2.2. Repräsentation der ökonomischen Variablen

Zusätzlich zu den reinen Preis-Merkmalen benötigt es die Daten der zu analysierenden ökonomischen Variablen. Diese wurden für den gleichen Zeitraum wie die Kursdaten auf täglicher Basis erhoben. Alle folgenden Merkmale wurden von einem Bloomberg Terminal

exportiert. Die ökonomischen Variablen, welche in diesem Versuch analysiert werden, sind der risikolose Zinssatz, die Inflation, Währungskurse und Rohstoffpreise.

Der risikolose Zinssatz repräsentiert eine langfristige Staatsanleihe in der Bewertungswährung. Da in dem S&P 500 Index ausschließlich US-Unternehmen enthalten sind, ist die Bewertungswährung USD und der risikolose Zinssatz wird durch eine langfristige US-Staatsanleihe dargestellt. Die Verzinsung des **US 30Y Generic T-Bond** stellt in diesem Versuch das Merkmal des risikolosen Zinssatzes dar (Bloomberg, 2023f). Die Inflation der Vereinigten Staaten wird zumeist durch den Consumer Price Index (CPI) gemessen, welcher monatlich von dem U.S. Bureau of Labor Statistics veröffentlicht wird. Die monatlichen Daten des **CPI All Urban Consumers (Current Series)** wurden für den gesetzten Zeitraum von der Website des U.S. Bureau of Labor Statistics exportiert und spiegeln in diesem Versuch die Inflation des USD wider (US Bureau of Labor Statistics, 2023). Für den Währungskurs soll die Stärke des USD repräsentiert werden, da dies die Buchwährung aller in dem S&P 500 Index enthaltenen Unternehmen ist. Wie in Kapitel 2.2.5 erläutert, wird die Stärke einer Währung durch Währungskurse immer relativ zu einer anderen Währung angegeben. Die in dem S&P 500 Index enthaltenen Unternehmen sind globale Unternehmen, welche Transaktionen mit einer Vielzahl von Fremdwährungen tätigen. Um die Stärke des USD nicht nur gegenüber einer weiteren Währung, sondern gegenüber allen relevanten Währungen zu repräsentieren, wurde der **Bloomberg Dollar Spot Index** als Merkmal gewählt (Bloomberg, 2023b). Dieser Index dient als Maßstab für die Stärke des USD gegen die zehn maßgebenden Fremdwährungen. Die Gewichtungen der einzelnen Fremdwährungen basiert auf deren Anteil am internationalen Handel (Bloomberg, 2023a). Die letzte in diesem Versuch betrachtete ökonomische Variable sind die Rohstoffpreise. Da es hier ebenfalls eine große Anzahl unterschiedlicher relevanter Rohstoffe gibt, auf welche die verschiedensten Unternehmen zugreifen, wird hier der **Bloomberg Commodity Index** als Merkmal herangezogen (Bloomberg, 2023d). Dieser Index bildet die Preisentwicklung einer weiten Palette an Rohstoffen ab und ist eine gute Repräsentation der Gesamtleistung des Rohstoffmarktes (Bloomberg, 2023c).

4.2.3. Datenvorbereitung

Da die erhobenen Merkmale (siehe Tabelle 4.1) unterschiedliche Frequenzen und Datenbeständigkeit ausweisen, müssen diese erst aggregiert werden. Das CPI-Merkmal wird nur monatlich aktualisiert, während alle anderen Merkmale in täglicher Frequenz vorliegen. Hier wird ein quadratischer Verlauf angenommen und die Daten mit der Python Bibliothek

Variable	Repräsentatives Merkmal	Quelle
Basis-Kurs	S&P 500 Total Return Index (Open-, High-, Low- & Close-Preis	Bloomberg, 2023e
Risikoloser Zinssatz	US 30Y Generic Treasury Bond Yield	Bloomberg, 2023f
Inflation	Consumer Price Index for all urban consumers (CPI)	US Bureau of Labor Statistics, 2023
Wechselkurse	Bloomberg Dollar Spot Index	Bloomberg, 2023b
Rohstoffpreise	Bloomberg Commodity Index (BCOM)	Bloomberg, 2023d

Tabelle 4.1.: Versuchsmerkmale

„Pandas“ für die fehlenden Tage interpoliert (McKinney, 2010).

Anschließend wurden alle Merkmale in einem Datensatz aggregiert. Dieser beinhaltet alle Merkmale in täglicher Frequenz in dem Zeitraum von dem 01.12.2018 bis zum 01.12.2023. Es bestehen weiterhin einige Nullwerte, welche behandelt werden müssen, bevor der Datensatz für den Versuch verwendet werden kann. Ein Großteil dieser fehlenden Werte lässt sich auf Nicht-Handelstage wie Wochenenden oder Feiertage an der Börse zurückführen. Einige weitere Nullwerte entstehen durch zusätzliche Nicht-Handelstage auf dem Anleihen-Markt. Alle Tage mit Nullwerten wurden entfernt.

Es bleiben 1.249 Tage bestehen, an denen Daten für alle Merkmale vorliegen. Der Datensatz deckt einen Zeitraum von dem 03.12.2018 bis zum 01.12.2023 ab. Die Zeitreihen aller Merkmale sind in Abbildung A.10 dargestellt.

4.3. Erstellung des Basis-Modelles

Nachdem die Merkmale für die Modelle erhoben und vorbereitet wurden, kann der eigentliche Versuchsprozess starten. Der erste Schritt ist die Erstellung, Optimierung und Evaluation des Basis-Modells, welches alleinig auf den Kurs-Merkmalen trainiert wird. Die Erstellung der Modelle und alle vorgeschalteten Datenverarbeitungsprozesse wurden in der Programmiersprache Python in Form von Jupyter Notebooks erstellt.

Die relevanten Kursdaten wurden mit allen benötigten Bibliotheken in ein Jupyer Notebook importiert. Bevor jedoch der eigentliche Modellierungsprozess starten kann, müssen die Daten transformiert werden, um für ein LSTM-Modell als Merkmale genutzt werden zu können.

4.3.1. Datentransformation

Der Datensatz der Kursmerkmale beinhaltet den Open-, High-, Low- & Close Preis zu jedem Handelstag innerhalb des zuvor gewählten Zeitintervalls. In diesem Versuch handelt es sich um überwachtes Lernen, weshalb ein oder mehrere x_D und y_C Variablen definiert werden müssen. Der Open-, High-, Low- sowie Close-Preis stellen die x_{1-4} Merkmale dar, während nur der Close-Preis des nächsten Tages die Zielgröße y des Modells bildet. Um den Modell-Trainingsprozess effizienter zu gestalten, werden zudem alle Merkmale sowie die Zielgröße auf einen Bereich von 0 bis 1 normalisiert (Fabian Pedregosa et al., 2011). Dieser Prozess wird nach dem Prognoseprozess wieder rückgängig gemacht, um zu dem ursprünglichen Skalenbereich zurückzukehren. Als nächster Schritt der Datentransformation wird der Datensatz in einen Trainings- und Test-Datensatz in einem Verhältnis 80 zu 20 Prozent geteilt. Der Test Datensatz ermöglicht es, die Leistung der Modellprognosen an einem bisher „ungesehenen“ Datensatz zu testen. Da es sich bei dem LSTM-Modell um ein RNN-Modell handelt, werden die Gewichte der einzelnen Neuronen entlang der Sequenz t optimiert. Dies geschieht jedoch nicht durch den gesamten Datensatz auf einmal, sondern in einer sogenannten Fenstergröße (eng. „Window-Size“). Bei einer Fenstergröße von $t = 10$ prognostiziert das Modell die Zielgröße $y_{t=11}$ anhand der Merkmale $\{x_{D,t}\}_{t=0}^{10}$. Danach wird das Fenster eine Einheit von t weitergerückt. Diese Fenstergröße ist ebenso Teil des Optimierungsprozesses.

4.3.2. Modelloptimierung

Modelle können in vielen unterschiedlichen Strukturen (Neuronen und Schichten Kombinationen) aufgebaut werden und unter verschiedensten Parametereinstellungen trainiert werden. Die Struktur und die Parameter, welche für das Modell gesetzt werden, sind entscheidend für die optimale Leistung des Modells und werden durch eine Feldstudie optimiert. Der Optimierungsprozess unterteilt sich hier in zwei Teile. Zuerst werden drei Modellstrukturen definiert, welche eine unterschiedliche Komplexität aufweisen. In dem zweiten Schritt werden die Hyperparameter für jedes dieser drei Modellstrukturen in einer Feldstudie optimiert. Die Definition der Modelle und anschließendes Trainieren dieser erfolgt in diesem Versuch anhand der Python Bibliothek „Keras“ (François Chollet, 2016).

Die Komplexität der Modellstrukturen definiert sich hier durch die Anzahl an Neuronen pro Schicht. Alle Modellstrukturen weisen vier Schichten auf, davon zwei LSTM-Schichten und zwei klassische MLP-Schichten. Die letzte MLP-Schicht hat in allen Modellstrukturen ausschließlich ein Neuron, da dieses die Zielgröße y repräsentiert. Die Neuronenzahl pro

Hyperparameter	Beschreibung
Dropout Ratio	Hinter beiden LSTM-Schichten sitzt eine Dropout-Schicht. Durch eine Dropout-Schicht werden in jedem Durchgang zufällig Neuronen deaktiviert. Dies kann einer Überanpassung des Modells auf den Trainings-Datensatz vorbeugen.
Batch Size	Definiert in einem Lernalgorithmus die Anzahl der Datenpunkte, die gleichzeitig verarbeitet und für die Gewichtsaktualisierung verwendet werden.
Aktivierungsfunktion	Die Aktivierungsfunktion kann die Input-Signale eines Neurons transformieren und so die non-linearität des Modells erhöhen
Fenstergröße	Die Fenstergröße gibt wie vorab definiert die Zeitperioden t an, welche dem Modell als Basis der Prognose von $t + 1$ dienen.
Lernrate	Die Lernrate gibt an, wie schnell ein Modell die Neuronengewichte bei einem Optimierungszyklus anpasst. Eine große Lernrate erhöht die Lerngeschwindigkeit, kann aber auch das Risiko von einer Überanpassung des Modells auf den Trainings-Datensatz erhöhen

Tabelle 4.2.: Optimierte Hyperparameter

Schicht aller Modellstrukturen ist in Tabelle 4.3 dargestellt.

Anschließend wurden durch eine Feldstudie die optimalen Hyperparameter für jedes dieser beschriebenen Modellstrukturen festgestellt. Für die Feldstudie wurde die Python-Bibliothek „Optuna“ verwendet (Akiba et al., 2019). Mit Optuna wurden jeweils 30 Trainingsiterationen mit verschiedenen Hyperparametern durchgeführt. Das Modell wurde stets auf den Trainingsdaten trainiert. Anschließend wurden auf Basis der Input-Merkmale des Test-Datensatzes Prognosen für den Close-Preis des nächsten Tages generiert. Die Trainingsiteration wurde auf Basis der Abweichungen der normalisierten Prognosen von den tatsächlichen Zielgrößen durch den Mean Squared Error (MSE) bewertet. Die Definition und Berechnung der unterschiedlichen benutzen Leistungsparameter werden in Abschnitt 4.3.3 genauer beleuchtet. Während des Trainingsprozesses eines Modells besteht eine gewisse Zufälligkeit, die zum einen durch die zufälligen Startgewichte der Neuronen als auch durch den BPTT initiiert werden. Dies resultiert darin, dass bei gleicher Modellstruktur und gleichen Hyperparametern die Leistung des Modells nicht konstant ist, sondern fluktuiert. Um diese Schwankungen möglichst zu minimieren, wurden die Modelle für jede Hyperparameterkombination über 200 Epochen trainiert. Die Hyperparameter, welche durch die Optuna Feldstudie optimiert wurden, sind in Tabelle 4.2 aufgeführt. Für jede Feldstudie der drei Modellstrukturen wurde die beste Hyperparameterkombination

dokumentiert. Es zeigt sich, dass die Leistungen der drei Modellstrukturen bei optimierten Hyperparametern stark beieinander liegen (siehe Tabelle 4.4), weshalb sich hier für die Modellstruktur der mittleren Komplexität entschieden wurde.

Auf Basis der Feldstudien wurden folgende Hyperparameter für das Basis-Modell und die folgenden Modelle festgelegt. Da die Modelle mit einer Dropout-Ratio von null die besten Ergebnisse erzielt haben, wird in den Modellen auf eine Dropout-Schicht verzichtet. Für das Modell der mittleren Komplexität erzielte eine Batch-Size von 8 die besten Ergebnisse. Die Aktivierungsfunktion wurde für alle Schichten des Modells auf „Relu“ festgelegt. Die Daten für den Trainingsprozess werden mit einer Fenstergröße von 10 Tagen transformiert. Als Optimierungsalgorithmus für das Modell wurde der „Adam“ Optimierer gewählt, da sich dieser gerade bei Modellen mit einer größeren Parameteranzahl als effizient erweist (Kingma & Ba, 2014). Die Lernrate für diesen Optimierungsalgorithmus bleibt bei dem Standardwert von $0,001$. Dieser stellte sich während des Optimierungsprozesses als am zuverlässigsten dar.

Komplexität	Struktur
geringe Komplexität	32, 16, 8, 1
mittlere Komplexität	64, 32, 16, 1
hohe Komplexität	128, 64, 32, 1

Tabelle 4.3.: Modellstrukturen

Modellstruktur	MSE	Dropout	Batch	Act.	Fenster	Lernrate
Geringe Komplexität	$0,000235$	0	8	sigmoid	45	$0,001$
Mittlere Komplexität	$0,000202$	0	8	relu	10	$0,001$
Hohe Komplexität	$0,000204$	0	16	relu	45	$0,001$

Tabelle 4.4.: Optuna Feldstudie Resultate

4.3.3. Modell-Evaluation

Mit der ermittelten Modellstruktur und den optimalen Hyperparametern wurde das Basis-Modell erneut trainiert, um den Evaluationsprozess durchlaufen zu können. Wie bereits erwähnt, fluktuiert die Leistung der Modelle bei jedem Trainingsprozess leicht. Aus diesem Grund wurden für das Basis-Modell, sowie für die folgenden Modelle mit angehängten ökonomischen Merkmalen, mehrere Trainingszyklen bei gleichbleibender Modellstruktur und Hyperparametern durchlaufen und die Leistungsparameter dieser aggregiert betrachtet. Ebenso wurden alle Leistungsparameter auf Basis des normalisierten

Test-Datensatzes berechnet. Wir unterscheiden in dieser Thesis zwischen zwei Arten von Leistungsparametern. Zum einen die klassischen Leistungsparameter, die sich durch die Abweichung der Modellprognosen von den tatsächlichen Zielwerten ergeben und zum anderen der Handelserfolg gemessen durch die Rendite von Handelsstrategien basierend auf den Modellprognosen.

Als **klassische Leistungsparameter** wurden während des Evaluationsprozesses alle empirisch gängigen Leistungsparameter in der Zeitreihenprognose berechnet und dokumentiert (Kumbure et al., 2022). Eine Auflistung aller dokumentierten klassischen Leistungsparameter und dessen Formeln finden sich in der Tabelle B.1. Die Berechnung erfolgte durch die Python-Bibliothek „Scikit-learn“ (Fabian Pedregosa et al., 2011). Da alle der klassischen Leistungsparameter auf eine unterschiedliche Art die Abweichung der Prognosen von den tatsächlichen Zielgrößen messen, unterscheidet sich die Berechnung dieser nicht stark voneinander. Es kann eine starke Korrelation aller dieser Leistungsparameter festgestellt werden (siehe Abbildung A.11), weshalb die Analyse der Ergebnisse in Kapitel 5 primär auf dem MSE basiert. Zusätzlich zu den klassischen Leistungsparametern wurden zwei eigene Leistungskennzahlen implementiert. Die sogenannte Trading Accuracy (TA) gibt den Anteil der Prognosen an, welche die richtige Richtung prognostizieren. Es werden also die Ableitungen der tatsächlichen Zielgrößen und der Prognosen verglichen. Diese Kennzahl soll ein Indikator für die Leistung einer Prognose bei einer Handelsstrategie sein. Da sich im Verlauf dieser Arbeit die Richtung, in welche die Prognosen der Modelle abweichen, als eine relevante Information herausstellt, wird zudem der Mean Error (ME) dokumentiert. Alle empirisch am häufigsten genutzten klassischen Leistungsparameter stellen die Prognoseabweichungen entweder im Betrag oder im Quadrat dar, weshalb sich die Richtung dieser Abweichungen nicht feststellen lässt. Der ME entspricht der durchschnittlichen Differenz zwischen dem prognostizierten und dem tatsächlichen Wert. Ein stark positiver Wert lässt auf eine konstante Überprognose schließen und ein stark negativer wiederum auf eine Unterprognose.

Der zweite Teil der Leistungsparameter ergibt sich durch drei verschiedene **Handelsstrategien**, welche für jedes Modell simuliert wurden. Diese sollen hier kurz vorgestellt werden und sind auch in Abbildung A.12 nachzuvollziehen. Jede Handelsstrategie wurde über den Zeitraum des Test-Datensatzes simuliert. Es wird ein liquider Markt und die Möglichkeit in Teileinheiten zu handeln angenommen. Steuern und Transaktionskosten bleiben in der Simulation unbeachtet. Es können ausschließlich Long-Positionen gehandelt werden. Leerverkäufe sind nicht möglich. Alle Handelsstrategien starten mit einem Portfoliowert von 100 Einheiten. Den Benchmark für alle Handelsstrategien bildet die Buy-&-Hold-Strategie.

Diese Strategie hält die Anlage über den gesamten Handelszeitraum und veräußert sie zum Abschluss. Es findet kein aktiver Handel statt. Die erste aktive Handelsstrategie (fortan als M1 referiert) kauft das Wertpapier, wenn der prognostizierte Close-Kurs über dem aktuellen Open-Kurs steht und verkauft das Wertpapier zum tatsächlichen Close-Kurs wieder. Liegt der prognostizierte Kurs unterhalb des Open-Kurses, findet kein Handel an diesem Handelstag statt. Die zweite Handelsstrategie (fortan als M2 referiert) handelt alleinig basierend auf dem prognostizierten Kurs. Ist der prognostizierte Close-Preis von $t+1$ größer als der prognostizierte Close-Preis von t, wird das Wertpapier zum tatsächlichen Close Preis t gekauft und zum tatsächlichen Close Preis von $t+1$ verkauft. Die Strategie M2 ermöglicht erfolgreichen Handel, auch wenn die Prognosen des Modells durchschnittlich über- oder unter dem tatsächlichen Kurs liegen. Relevant ist nur, dass die Prognoserichtung des Modells korrekt ist. Diese Strategie hat eine starke Relation zu dem vorher definierten Leistungsparameter TA. Die dritte Handelsstrategie (fortan als M3 referiert) handelt durch einen Vergleich zwischen den prognostizierten und tatsächlichen Close-Preisen. Liegt der prognostizierte Close Preis $t+1$ über dem tatsächlichen Close Preis von t, wird das Wertpapier zum tatsächlichen Close Preis t gekauft und zum tatsächlichen Close Preis $t+1$ verkauft.

Nachdem nun das Basis-Modell erstellt, optimiert und evaluiert wurde, werden die Modelle mit den angehängten ökonomischen Variablen trainiert und evaluiert.

4.4. Erstellung der Versuchsmodelle

Neben dem Basis-Modell werden nun fünf Modelle mit neuen Merkmal-Konfigurationen trainiert und evaluiert (siehe Tabelle 4.5). Den Merkmalen des Basis-Modells wird jeweils eines der betrachteten ökonomischen Variablen angehängt. Es ergeben sich vier neue Modelle. Aufgrund der begrenzten Zeit können nicht alle möglichen Kombinationen der ökonomischen Variablen in einem Modell getestet werden. Daher wird ein einzelnes fünftes Modell trainiert und getestet, welches alle ökonomischen Variablen beinhaltet und Aufschluss über den allgemeinen Erfolg von einer Merkmal-Kombination geben soll.

Wichtig ist, dass die Versuchsmodelle mit den neuen Merkmal-Kombinationen identisch zu dem Basis-Modell trainiert und evaluiert werden, um pro Versuch nur eine Variable zu verändern. Zuerst werden also die neuen Merkmal-Kombinationen transformiert, um den Anforderungen eines LSTM-Modells zu entsprechen. Wiederum werden für jede Merkmal-Kombination mehrere Trainingszyklen gefahren, um der Zufälligkeit innerhalb des Trainingsprozesses entgegenzuwirken. Für jedes erstellte Modell werden Prognosen

Typ	Modell	ID	Merkmale
Basismodell	Kursdaten	base	- Open- High-, Low- & Close-Preis
Versuchsmodelle	Risikoloser-Zinssatz	ir	- Open- High-, Low- & Close-Preis - US 30Y Generic Treasury Bond Yield
	Inflation	cpi	- Open- High-, Low- & Close-Preis - Consumer Price Index (all urban)
	Währungskurse	fx	- Open- High-, Low- & Close-Preis - Bloomberg Dollar Spot Index
	Rohstoffpreise	com	- Open- High-, Low- & Close-Preis - Bloomberg Commodity Index
	Komplett	all	- Open- High-, Low- & Close-Preis - US 30Y Generic Treasury Bond Yield - Consumer Price Index (all urban) - Bloomberg Dollar Spot Index - Bloomberg Commodity Index

Tabelle 4.5.: Alle Merkmal-Kombinationen

auf Basis des Test-Datensatzes erstellt. Diese werden mit den tatsächlichen Zielgrößen verglichen und durch die in Abschnitt 4.3.3 genannten klassischen Leistungsparameter bewertet. Ebenso werden für alle Modelle die beschriebenen Handelsstrategien simuliert und die erreichten Renditen dokumentiert.

Zu Ende des Versuchsprozesses ergeben sich jeweils sechs Datensätze für alle Merkmal-Kombinationen in Tabelle 4.5 aufgezeigt. Jeder dieser Datensätze enthält eine Liste an trainierten Modellen, welche bei gleicher Struktur und Hyperparametern für diese Modell-Konfiguration trainiert wurden. Für jedes trainierte Modell finden sich alle sieben klassischen Leistungsparameter und die erzielte Rendite für die drei Handelsstrategien. Diese Ergebnisse werden anschließend in einem neuen Python-Notebook aggregiert analysiert.

5. Ergebnisse

5.1. Klassische Leistungsparameter

Für jede der Merkmal-Konfigurationen (siehe Tabelle 4.5) wurden jeweils 15 Modelle trainiert und evaluiert, um etwaige Schwankungen durch zufällige Prozesse auszugleichen. Unter aggregierter Betrachtung aller Leistungsparameter über alle Merkmale-Konfigurationen fällt eine starke Korrelation der klassischen Leistungsparameter MSE, RMSE, R2, MAPE und MAE auf (siehe Abbildung A.11). Diese ist auf die starke Kohärenz der Berechnung dieser Leistungsparameter zurückzuführen (siehe Tabelle B.1). Aus diesem Grund wird für den weiteren Analyseprozess primär der Leistungsparameter MSE als Repräsentation der klassischen Leistungsparameter herangezogen.

5.1.1. Kategorische Leistung nach MSE

Die durchschnittlichen klassischen Leistungsparameter pro Merkmal-Konfiguration sind in Tabelle 5.1 dargestellt. Mit einem MSE von $0,000207$ konnte das Basis-Modell die besten Ergebnisse erzielen. Durch das Anhängen weiterer oder auch aller ökonomischen Variablen verschlechterte sich der MSE in unterschiedlichen Raten. Obwohl die Leistung nach MSE bei den Merkmal-Konfigurationen „com“, „cpi“ und „fx“ schlechter als bei dem Basis-Modell ausfällt, liegen die Ergebnisse nah beieinander. Der Durchschnitt dieser

Config	MSE	RMSE	R2	TA	MAPE	MAE	ME
all	0.000359	0.018888	0.957425	48.118280	0.019100	0.015058	0.006721
base	0.000207	0.014383	0.975458	47.258065	0.014445	0.011433	-0.000130
com	0.000219	0.014807	0.973980	47.500000	0.014985	0.011909	-0.001075
cpi	0.000236	0.015357	0.971952	47.419355	0.015526	0.012346	-0.000868
fx	0.000226	0.015043	0.973146	48.387097	0.015102	0.011979	0.000132
ir	0.000465	0.021199	0.944786	47.741935	0.021073	0.017409	-0.009347

Tabelle 5.1.: Kategorische klassische Leistungsparameter

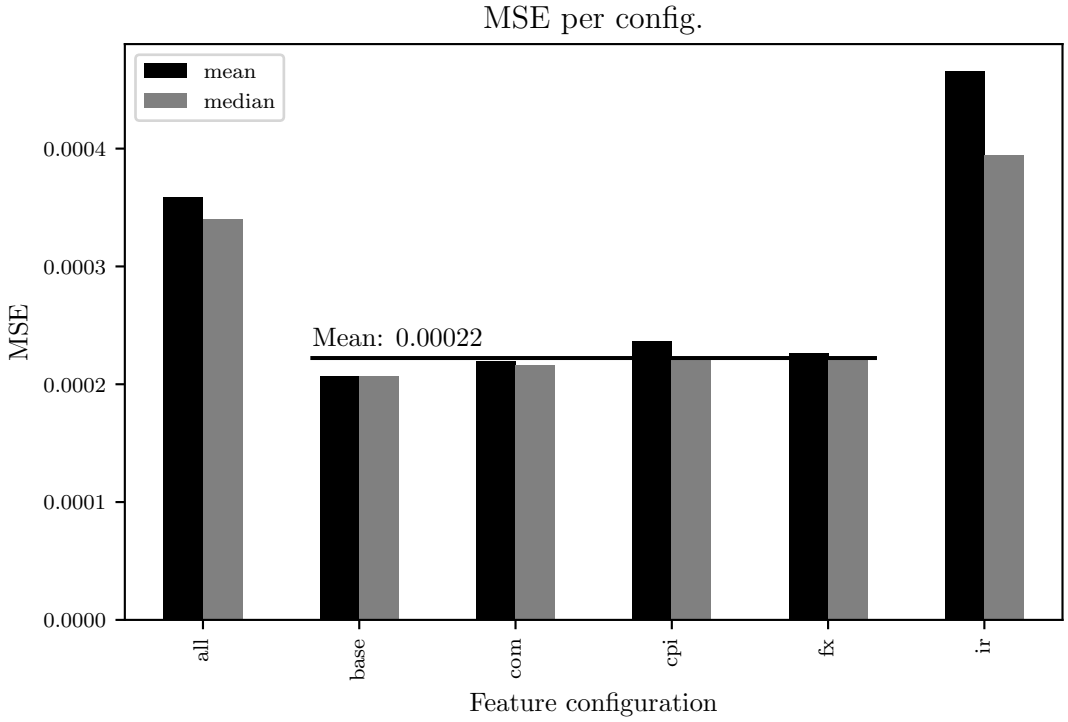

Abbildung 5.1.: MSE nach Merkmal-Konfiguration (Quelle: Eigene Darstellung)

vier Merkmal-Konfigurationen liegt mit $0,00022$ nicht weit weg von dem MSE des Basis-Modells. Auffällig ist jedoch, dass die Leistung der „ir“ Merkmal-Konfiguration drastisch schlechter als alle anderen Merkmal-Konfigurationen ist. Die Merkmal-Konfiguration mit allen ökonomischen Variablen („all“) liegt nach MSE zwischen der Merkmal-Konfiguration „ir“ und den anderen sehr nah beieinander liegenden Merkmal-Konfigurationen. Es ist zu erwarten, dass der negative Effekt der „ir“ Merkmal-Konfiguration die Leistung der „all“ Merkmal-Konfiguration schwächt. Diese Beobachtung wird durch die Varianz der Ergebnisse pro Merkmal-Konfiguration unterstrichen. Da für jede Merkmal-Konfiguration jeweils 15 Modelle trainiert wurden, kann der Variationskoeffizient für die Menge an MSE Beobachtungen je Merkmal-Konfiguration berechnet werden. Das Basis-Modell weist nicht nur den geringsten MSE auf, sondern auch den geringsten Variationskoeffizienten in Höhe von $1,5\%$. Aus der Gruppe „com“, „cpi“ und „fx“ weißt die Merkmal-Kombination „cpi“ einen leicht erhöhten Variationskoeffizienten von $10,8\%$ auf. Wie auch bei der absoluten Leistung nach MSE ist der Variationskoeffizient der „ir“ Merkmal-Konfiguration mit Abstand am höchsten und liegt bei fast 40%. Die Merkmal-Konfiguration „all“ liegt hier wiederum zwischen den beiden Extremen. Die weiteren deskriptiven Statistiken der MSE-Werte sind kategorisiert nach den Merkmal-Konfigurationen in Tabelle B.2 aufgeführt.

5.1.2. Interpretation und Bewertung

Allgemein lässt sich kein positiver Effekt durch das Beifügen der ökonomischen Merkmale erkennen. Eine geringe Leistungsverschlechterung, wie beispielsweise bei der Gruppe mit annähernd gleichen MSE-Werten, basiert womöglich auf dem Optimierungsprozess. Die Modellstruktur und die ausgewählten Hyperparameter entstammen dem Optimierungsprozess des Basismodells. Da die Modelle für die neuen Merkmal-Konfigurationen nicht erneut optimiert wurden, kann sich die Leistung verschlechtern. Gerade bei der Merkmal-Konfiguration „all“ mag es ein komplexeres Modell erfordern, um die Strukturen und Zusammenhänge in allen vier Variablen verarbeiten zu können. Auffällig ist dann jedoch, dass bei der Merkmal-Konfiguration „ir“ die Leistung signifikant schlechter ist, obwohl diese Konfiguration dem Basis-Modell nur eine weitere Variable als Merkmal anhängt.

Die Leistungsverschlechterung kann also auf die Zeitreihe an sich zurückgeführt werden und entsteht nicht durch die Modellstruktur oder die gewählten Hyperparameter. Auch wenn statistische und kausale Korrelation nicht gleichzusetzen ist, so findet sich hier eine mögliche Begründung in dem kausalen Zusammenhang des prognostizierten Kurses und dem risikolosen Zinssatz. Hier wurden zwei Ansätze beschrieben, wie sich der risikolose Zinssatz auf den intrinsischen Unternehmenswert auswirkt. Bei einer Betrachtung des theoretischen Fundaments des CAPM als Risiko-Rendite-Modell ist die Marktrisikoprämie variabel mit dem risikolosen Zinssatz. In diesem Ansatz hängt der Einfluss der risikolosen Rendite auf den intrinsischen Unternehmenswert von β ab. In dem zweiten Ansatz ist, wie heute in der Unternehmensbewertung meist angenommen, die Marktrisikoprämie konstanter Natur und wird nicht direkt von dem risikolosen Zinssatz verändert. Der in diesem Versuch verwendete S&P 500 Total Index spiegelt einen Marktindex wider, welcher nach dem CAPM ein $\beta = 1$ hat. Während nach dem zweiten Ansatz weiterhin der risikolose Zinssatz einen Einfluss auf den intrinsischen Unternehmenswert hat, so gleicht sich in Ansatz eins die Wirkung des risikolosen Zinssatzes durch das $\beta = 1$ aus. Nach Ansatz eins hat der risikolose Zinssatz kausal keine Wirkung auf den Preis des S&P 500 Total Index und verzerrt die Leistung des Modells in der Merkmal-Konfiguration „ir“. Obwohl dies ein Erklärungsansatz sein mag, lassen sich die genauen Prozesse innerhalb des Modells nicht nachvollziehen und eine sichere Begründung der schlechteren Leistung ist nicht möglich.

Ein weiterer Erklärungsansatz kann von den Zeitreihen an sich abgeleitet werden. Bei Betrachtung der Prognose eines einzelnen Modells der „ir“ Merkmal-Konfiguration fällt auf, dass die Prognose konstant unter dem tatsächlichen Wert liegt (siehe Abbildung A.14). Wenn die Zeitreihen des Schlusskurses und des risikolosen Zinssatzes über den Trainings-

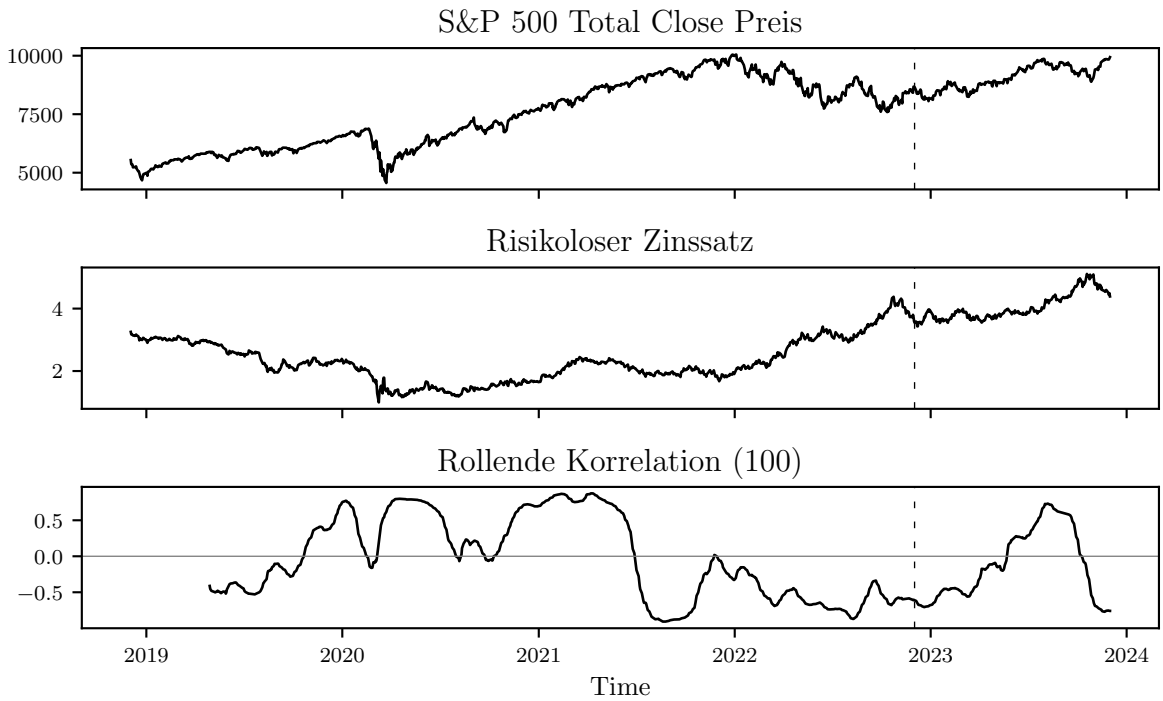

Notiz: Rollierende Korrelation über 100 Handelstage, Übergang von Trainings- zu Test-Zeitraum durch gestrichelte Linie gekennzeichnet.

Abbildung 5.2.: „ir“ Konfiguration Vergleich mit rollender Korrelation (Quelle: Eigene Darstellung)

und Testzeitraum in Abbildung 5.2 analysiert werden, ergibt sich eine Begründung für die Unterprognose. Gerade über den Zeitraum von 2022 bis 2023, welche noch in dem Trainings-Zeitraum liegt, korreliert der risikolose Zinssatz negativ mit dem Close-Preis. Das Modell wird jedoch anhand der Prognosen innerhalb des Test-Zeitraums bewertet. Hier ist von Anfang 2023 ein Umschwung zu einer positiven Korrelation der beiden Werte zu verzeichnen. Der steigende risikolose Zinssatz im Jahr 2023 mag dem Modell also ein Indikator für sinkende Close-Preise gewesen sein, da dies dem letzten Muster aus dem Trainings-Zeitraum (Jahr 2022) gleichkommen würde.

Zusammenfassend lässt sich durch die Erweiterung der Merkmale durch ökonomische Variablen keine Leistungsverbesserung des Modells im Sinne der klassischen Leistungsparameter verzeichnen. Bei Erweiterung durch den risikolosen Zinssatz (Merkmal-Konfiguration „ir“) verschlechtert sich die Leistung auffällig stärker als bei Erweiterung jeweils aller weiteren ökonomischen Variablen. Hierfür werden zwei Begründungsansätze angebracht. Zum einen hat der risikolose Zinssatz bei einem Marktportfolio wie dem S&P 500 Total Index mit einem $\beta = 0$ nach dem CAPM als Risiko-Rendite-Modell keinen Einfluss auf den

intrinsischen Unternehmenswert und sogleich den zu prognostizierenden Close-Preis. Des Weiteren lässt sich in dem Übergang von Trainings- zu Test-Zeitraum ein Umschwung in der Korrelation des risikolosen Zinssatzes zu dem Close-Preis verzeichnen, welcher dem Modell bei der Prognose des Test-Zeitraums falsche Signale gegeben haben mag und der Close-Preis zu gering prognostiziert wurde. Rohstoffpreise haben ebenso empirisch wenig Einfluss auf den intrinsischen Unternehmenswert, was die Verschlechterung der Leistung bei der Merkmal-Kombination „com“ begründen könnte. Jedoch die ökonomischen Variablen Inflation und Wechselkurse haben einen empirischen und kausalen Einfluss auf den intrinsischen Unternehmenswert und verschlechtern dennoch die Leistung des Modells. In Bezug auf die Hypothese, dass sich ein kausaler Zusammenhang der ökonomischen Variable in eine Verbesserung der Leistung des Modells auswirkt, muss diese hier bezogen auf die klassischen Leistungsparameter abgelehnt werden.

5.2. Handelsstrategien

Zusätzlich zu den klassischen Leistungsparametern wurden drei verschiedene Handelsstrategien simuliert, um die Leistung der Modelle in der ökonomischen Dimension einzuordnen. Die Renditen dieser drei Handelsstrategien sollen hier zuerst entlang des gesamten Datensatzes analysiert werden. In einem zweiten Schritt werden die Handelsstrategien kategorisiert nach den Merkmal-Konfigurationen analysiert.

5.2.1. Ergebnisse aller Versuche

Als Benchmark für alle simulierten Handelsstrategien steht die Buy-&-Hold-Strategie. Diese erwirtschaftete in dem Test-Zeitraum eine Rendite von $16,1\%$. Dem Durchschnitt nach konnten keine der auf den Modellprognosen basierenden Handelsstrategien eine bessere Rendite erzielen als die Buy-&-Hold-Strategie. Die durchschnittliche Rendite erstreckt sich hier von $2,42\%$ bei der „M2“ Strategie bis $11,67\%$ bei der „M3“ Strategie (siehe auch Tabelle B.3). Während sich die Strategie „M1“ und „M2“ in ihrer durchschnittlichen Rendite gleichen, so zeigt sich bei Betrachtung des Boxplots in Abbildung 5.3 ein starker Unterschied in der Varianz der Strategien. Die Handelsstrategien „M1“ und „M3“ weisen eine hohe Standardabweichung von aufgerundet 7 auf. Die Handelsstrategie „M2“ setzt sich hier mit einer geringeren Standardabweichung von $2,4$ ab. Mit einer hohen Standardabweichung und einem höheren Durchschnitt ist die Handelsstrategie „M3“ die einzige, welche vereinzelt die Buy-&-Hold-Strategie übertreffen konnte.

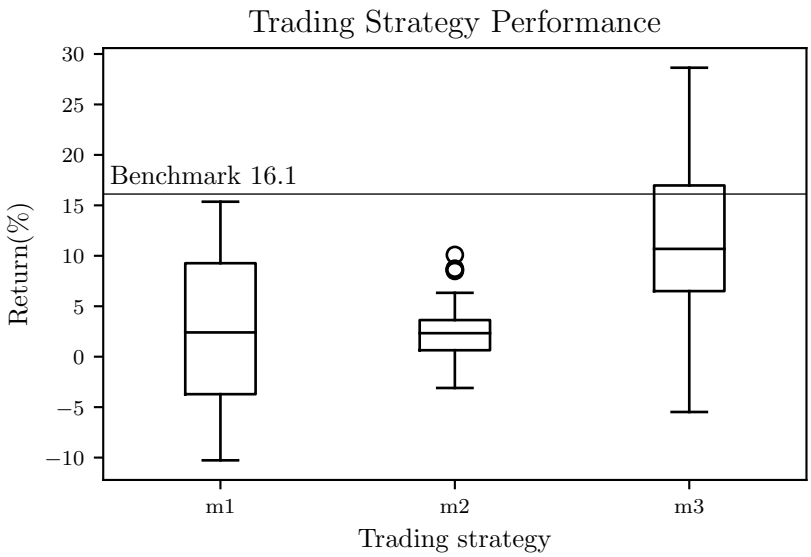

Abbildung 5.3.: Allgemeine Handelsleistung (Quelle: Eigene Darstellung)

Unter Betrachtung der Korrelation, der Standardabweichung und der Handelsmethodik lassen sich die Strategien „M1“ und „M3“ gruppieren. Von der Methodik her basieren die Handelssignale dieser beiden Strategien auf einem Vergleich zwischen der Kursprognose und dem tatsächlichen Kurs. Überprognostiziert (eng. overshooting) das Modell in einem gewissen Zeitraum, also sind die Prognosen konstant zu hoch, so senden diese Strategien durchgehend Kaufsignale und umgekehrt. Durch konstante Über- oder Unterbewertung des Modells, entstehen lange Perioden ohne aktiven Handel. Hier sind die Renditen nicht mehr Produkt der Handelsstrategie, sondern des generellen Verlaufs des Wertpapiers. Die Handelsstrategie „M2“ hingegen sendet Handelssignale alleinig basierend auf der Ableitung des prognostizierten Kurses. Eine Über- oder Unterbewertung des Modells hat hier also keine Perioden zu Folge, in denen kein aktiver Handel stattfindet. Die Strategie „M2“ ist somit stark abhängig von der richtigen Prognoserichtung des Modells. Dies zeigt sich auch durch eine starke Korrelation der Ergebnisse von der Handelsstrategie „M2“ und dem klassischen Leistungsparameter TA, welcher genau diese Genauigkeit misst. Das Verhalten der drei Handelsstrategien lässt sich exemplarisch an der Abbildung A.15 erkennen. Während bei Strategie „M1“ und „M3“ handelsfreie Perioden auftreten, findet bei Strategie „M2“ konstanter aktiver Handel statt. Die unterschiedlichen Ansätze in der Methodik schlagen sich auch in der Korrelation der drei Handelsstrategien aus. Während zwischen der Handelsstrategie „M1“ und „M3“ eine leicht positive Korrelation von $0,68$ besteht, so ist die Korrelation mit der Strategie „M2“ mit $0,23$ sehr gering.

Config	bh	m1	m2	m3
all	16.12	9.82	3.59	13.30
base	16.12	2.20	1.36	13.08
com	16.12	-1.47	1.16	8.42
cpi	16.12	2.81	1.94	15.36
fx	16.12	5.70	3.39	13.48
ir	16.12	-2.12	3.10	6.39

Tabelle 5.2.: Kategorische Renditen der Handelsstrategien

Insgesamt ist die Korrelation zwischen den klassischen Leistungsparametern und den erzielten Renditen gering (siehe A.17). Beispielsweise ein guter MSE-Wert gibt Aussage für eine gute absolute Prognosegenauigkeit, impliziert aber nicht direkt Erfolg durch eine Handelsstrategie basierend auf den Prognosen.

5.2.2. Kategorische Ergebnisse

Die durchschnittlichen Renditen aller Handelsstrategien und Merkmal-Konfigurationen sind in der Tabelle 5.2 dokumentiert. Wie auch schon im vorherigen Abschnitt dargestellt, konnte im Durchschnitt keine der Handelsstrategien die Buy-&-Hold-Strategie übertreffen. Dennoch sollen die Unterschiede der erzielten Renditen nach den Merkmal-Konfigurationen analysiert werden. Die Handelsstrategien „M1“ und „M2“ zeigten die beste Rendite auf der Merkmal-Konfiguration „all“, welche alle betrachteten ökonomischen Variablen inkludiert. Die Strategie „M3“ zeigte die beste Rendite auf Basis der „cpi“ Merkmal-Konfiguration. Die Verteilung der Beobachtungen nach den Merkmal-Kombinationen entlang der Handelsstrategien ist konsistent mit den Verteilungen basierend auf dem gesamten Datensatz (siehe Abbildung A.16). Die Varianz ist bei allen Merkmal-Konfigurationen höher bei den Handelsstrategien „M1“ und „M3“, während sie bei der Handelsstrategie „M2“ am niedrigsten ist.

In Tabelle 5.3 sind die durchschnittlichen Renditen aller Handelsstrategien pro Merkmal-Konfiguration dokumentiert. Das Basis-Modell erzielt über den Testzeitraum im Durchschnitt eine Rendite von $5,55\%$. Drei der Versuchsmodelle konnten hier im Durchschnitt höhere Renditen erzielen. Die Rendite der „all“ Merkmal-Konfiguration mit $8,9\%$ ist am höchsten und hat zudem von allen Merkmal-Konfigurationen den geringsten Variationskoeffizienten. Es folgt das Versuchsmodell „fx“ mit einer durchschnittlichen Rendite von $7,52\%$. Das letzte Versuchsmodell, welches eine höhere Rendite als die des Basis-Modells

Config	count	mean	std	min	max	CV
all	15	8.90	2.40	4.39	13.01	0.27
fx	15	7.52	4.21	0.77	15.54	0.56
cpi	15	6.71	4.46	-0.70	15.60	0.67
base	15	5.55	4.60	-1.47	12.60	0.83
com	15	2.70	4.19	-1.85	11.35	1.55
ir	15	2.46	3.60	-2.51	9.70	1.46

Tabelle 5.3.: Handelsleistung Deskriptive Statistik

aufweist, ist „cpi“ mit $6,71\%$. Verglichen mit dem Basis-Modell erzielten zwei Versuchsmodelle eine schlechtere Rendite. Die geringste Rendite wird mit $2,46\%$ auf Basis der „ir“ Merkmal-Konfiguration erzielt. Mit einer Rendite von $2,7\%$ ist die Handelsleistung der Merkmal-Konfiguration „com“ gleichermaßen im unteren Segment angesiedelt.

5.2.3. Interpretation und Bewertung

Zusammenfassend konnte keine der Handelsstrategien im Durchschnitt eine einfache Buy-&-Hold-Strategie übertreffen. Die Handelsstrategien, welche auf Basis eines Vergleiches der Prognose mit dem tatsächlichen Kurs handeln, sind anfällig gegenüber handelsfreien Perioden aufgrund von konstanter Unter- oder Überbewertung des Modells. Gerade bei diesen Modellen ist eine höhere Varianz in den Renditen zu erkennen und es werden auch im Durchschnitt höhere Renditen erzielt als bei einer Handelsstrategie, die basierend auf der prognostizierten Kursrichtung handelt. Durch die handelsfreien Perioden steigt auch der Einfluss des Zufalls auf diese Systeme und gute Leistungen sind nicht mehr direkt auf die Qualität der Prognosen zurückzuführen. Jedoch auch bei der Handelsstrategie „M2“, bei welcher das Problem von handelsfreien Perioden nicht besteht, zeigt sich grundlegend eine schlechtere Rendite verglichen mit der Buy-&-Hold-Strategie. Diese Resultate sind auf die Prognosegenauigkeit des Modells zurückzuführen. Diese scheint nach klassischen Leistungsparametern gut, basiert jedoch auf den absoluten Differenzen zwischen dem tatsächlichen Kurs und der Prognose. Bei Betrachtung der relativen Prognosegenauigkeit zeigt sich eine schlechte Leistung in der Prognose der täglichen Veränderungen des Kurses. Die TA über alle Modelle ist durchschnittlich $47,74\%$, was bedeutet das nur zu $47,74\%$ die Kursrichtung richtig prognostiziert wurde. Als kritisch hier zu betrachten ist nicht die Prognose des generellen Trends des Kurses, sondern genau jene täglichen Kursschwankungen basierend auf der Volatilität des Kurses. Eine tagesgenaue Prognose erweist sich schwierig

und resultiert demnach ebenso in einer schlechten Handelsleistung der in täglicher Frequenz handelnden Strategien.

Bereits nach der „Efficient Market Hypothesis“ in der schwächsten Form ist der aktuelle Kurs die beste Prognose des Kurses auf Basis historischer Kursdaten. Somit ist eine Prognose allein auf Basis des Aktienkurses nicht möglich und der Aktienkurs gleicht einer zufälligen Zeitreihe (auch „Random Walk“). Es lassen sich also keine Strukturen oder Korrelationen innerhalb des Kurses ableiten, welche für die Prognose hilfreich wären. Bei Betrachtung der Autokorrelation des S&P 500 Total Index über den Trainings- und Testzeitraum, zeigt sich für keinen Lag eine signifikante Autokorrelation, was ein Indikator für eine zufällige Zeitreihe ist (siehe Abbildung A.18). Es finden sich also innerhalb der Zeitreihe keine signifikanten wiederholenden Strukturen, welche bei der Prognose relevant wären. Dies lässt sich als eine mögliche Erklärung dafür interpretieren, warum sowohl die TA als auch die Handelsleistungen des Basis-Modells zu unbefriedigenden Ergebnissen geführt haben. Unterstützend sind die Beobachtungen von Fischer und Krauss, 2018, welche basierend auf den Kursdaten des S&P 500 nach 2009 mit Ihrem Modell keine Renditen mehr oberhalb des Marktes erzielen konnten.

Die Beifügung von ökonomischen Variablen resultierte nach den klassischen Leistungsparametern in keiner Leistungsverbesserung der Modelle. Nach der Handelsleistung der Modelle zeigt sich ein anderes Bild. Drei der Merkmal-Konfigurationen führen zu einer Steigerung der Handelsleistung gegenüber dem Basis-Modell und zwei zu einer Verschlechterung. Die Merkmal-Kombinationen „ir“ und „com“ resultierten in einer schlechteren Handelsleistung verglichen mit dem Basis-Modell. Bereits in Abschnitt 5.1.2 wurden kausale sowie statistische Ansätze für die schlechte Leistung der „ir“ Merkmal-Kombination angebracht. Kausal lässt sich auch bei der „com“ Merkmal-Kombination argumentieren, dass der geringe empirische Einfluss Grund für die schlechte Handelsleistung sein kann. Dennoch finden sich ebenso drei Merkmal-Konfigurationen („all“, „fx“ und „cpi“), welche bessere Handelsleistungen als das Basis-Modell verzeichnen. Alle dieser Merkmal-Konfigurationen weisen einen schlechteren MSE auf. Besonders die „all“ Merkmal-Konfiguration. Es scheint nicht plausibel zu sein, dass sich eine schlechtere Genauigkeit der Modelle in bessere Handelsleistungen übersetzt. Tatsächlich begründen sich diese Ergebnisse durch Intervalle konstanter Über- oder Unterprognose. Solch eine Unterprognose wurde bereits vorher bei der „ir“ Merkmal-Kombination festgestellt. Anhand des ME lässt sich dies auch für die anderen Merkmal-Kombination analysieren. Der ME der „ir“ Merkmal-Kombination ist mit $-0,009$ relativ negativ und bestätigt die Unterprognose des Modells. Diese wirkt sich bei einem durchschnittlich steigenden Kurs (Buy-&-Hold von $16,21\%$) negativ auf

die Rendite der Handelsstrategie aus. Der ME der „all“ Merkmal-Kombination ist mit $0,007$ relativ hoch und deutet auf eine Überprognose hin, welche sich bei allgemein steigendem Kurs auch positiv auf die Handelsleistung auswirkt. Abbildung A.19 zeigt den ME für alle Merkmal-Kombinationen, sortiert nach Handelsleistung. Es zeigt sich, dass die besten Merkmal-Kombinationen nach Handelsleistung eher eine Überprognose und die schlechtesten Merkmal-Kombinationen eher eine Unterprognose aufweisen. Dies lässt sich durch das Korrelationsdiagramm in Abbildung A.20 unterstreichen. Es zeigt sich eine positive Korrelation von $0,73$ zwischen ME und den durchschnittlichen Renditen der Handelsstrategien „M1“ und „M3“.

Nach diesen Erkenntnissen sind die besseren Handelsleistungen dieser Merkmal Kombinationen nicht auf deren positiven Einfluss auf das Modell, sondern teils eher auf deren negativen Einfluss zurückzuführen. Zwar zeigen sich auch bei der Handelsstrategie „M2“ Merkmal-Kombinationen mit besseren Handelsleistungen als das Basis-Modell, diese sind jedoch so marginal, dass sich hier kein positiver Effekt nachweisen lässt.

Zusammenfassend lässt sich die zu Beginn gestellte Hypothese in Anbetracht der Handelsleistung ebenso nicht bestätigen. Auch wenn bei den ökonomischen Variablen des risikolosen Zinssatzes und den Rohstoffpreisen Zweifel an der kausalen Relevanz in diesem Versuch bestehen, so bleibt der kausale Einfluss der Inflation und den Währungskursen bestehen. Auch wenn diese eine bessere Rendite gegenüber des Basis-Modells aufweisen, entspringt diese eher der Handelsstrategiemethodik an sich als einem positiven Einfluss der Variablen auf die Modellprognosen. Keine der Merkmal-Kombinationen konnte im Durchschnitt eine Buy-&-Hold-Strategie übertreffen, was unter Annahme eines effizienten Marktes eine nicht ausreichende Datenlage unterstellt. Es benötigt weitere relevante Variablen für eine bessere Prognose.

5.3. Kritische Reflexion

Während des Versuchsprozesses konnten einige Erkenntnisse gesammelt werden, welche zur Optimierung der Resultate beitragen könnten, jedoch begründet durch die Zeitbegrenzung nicht implementiert wurden.

Die klassischen Leistungsparameter sind für alle Versuchsmodelle schlechter ausgefallen als die des Basis-Modells. In diesem Versuch wurde der Ansatz gewählt, nur die Merkmale zu verändern, um die Ergebnisse direkt auf den Effekt der ökonomischen Variablen auf die Leistung des Modells ableiten zu können. Demnach wurden die Hyperparameter und die Modellstruktur für alle Versuchsmodelle konstant gehalten. Jedoch ist es möglich,

dass die Leistung der Modelle durch dessen Modellstruktur und Hyperparameterwahl bei den Versuchsmodellen (gerade der „all“ Merkmal-Kombination) begrenzt wurde. Ein weiterer Ansatz bestünde darin, die Modellstruktur sowie die Hyperparameter für jede der Versuchsmodelle erneut durch eine Feldstudie zu optimieren. Bei einem identischen Optimierungsprozess entlang aller Modelle, wären Veränderungen in der Modellleistung weiterhin auf den Einfluss der ökonomischen Variablen zurückzuführen.

In diesem Versuch wurden die absoluten Close-Preise prognostiziert, um den Kurs anschaulich darstellen zu können. Gleichwohl basiert die Evaluation auf den absoluten Differenzen der prognostizierten und tatsächlichen Werte. Durch die Analyse der Ergebnisse fällt auf, dass die Herausforderung nicht auf der absoluten Genauigkeit, sondern auf der Prognose der Kursdifferenzen liegt, da der Kurs unabdinglich stark von dem absoluten Wert des Vortages abhängt. Das durchschnittliche Bestimmtheitsmaß (R2) über alle trainierten Modelle hinweg liegt bei 96%. Das bedeutet, dass durchschnittlich 96% der Varianz in der abhängigen Variable durch das Modell erklärt werden können. Dabei bleibt jedoch unbeachtet, dass ein Großteil dieser Varianz bereits durch die Berücksichtigung des letzten Kurses erklärt wird. Die TA aller Modelle liegt im Durchschnitt bei $47,74\%$ und zeigt einen starken Abfall gegenüber der Genauigkeit des Modells auf absoluter Basis. Ein alternativer Ansatz könnte darin bestehen, nicht die absoluten Close-Preise, sondern die Veränderungen der Close-Preise zu prognostizieren. Dies könnte die Interpretation der Ergebnisse gerade für eine Handelsstrategie vereinfachen und den Modellierungsprozess auf die herausfordernde Komponente der Prognose der täglichen Veränderungen fokussieren.

Alle drei in diesem Versuch verwendeten Handelsstrategien operieren auf einer rein täglichen Basis und sind damit besonders von der täglichen Prognosegenauigkeit des Modells abhängig. Diese hat sich entlang aller Modelle als die schwierigste Komponente erwiesen. Zusätzlich zu diesen kurzfristigen Handelsstrategien könnten weitere langfristigere Handelsstrategien implementiert werden, welche beispielsweise den rollierenden Durchschnitt der Prognose betrachten, um Trend-basiert zu handeln. Ebenso könnten Handelssignale erst nach mehrfacher Indikation des Modells ausgelöst werden. Dies könnte Handelssignale aufgrund von kurzfristigen volatilen Kursumschwankungen verringern, um den Fokus auf längerfristige Kursbewegungen zu legen. Zusätzlich wurden in diesem Versuch Steuern und Transaktionskosten außer Acht gelassen. Diese würden zudem von einer langfristigeren Handelsfrequenz profitieren.

6. Schlussteil

6.1. Fazit

Der Einfluss der ausgewählten ökonomischen Variablen auf die Leistung von LSTM-Modellen unterscheidet sich nach den klassischen Leistungsparametern und der Handelsleistung. Diese beiden Leistungsindikatoren zeigen eine geringe Korrelation, weshalb diese gesondert betrachtet wurden.

Die durchschnittliche Leistung in MSE des Basis-Modells, trainiert alleinig auf den Kursmerkmalen, beträgt normiert $0,000207$ mit einem Variationskoeffizienten von $1,5\%$. Die Leistung nach MSE sowie der Variationskoeffizient hat sich bei allen Versuchsmodellen mit den ökonomischen Variablen risikoloser Zinssatz, Inflation, Währungskurse und Rohstoffpreise verschlechtert. Bei einzelner Beifügung der ökonomischen Variablen Inflation, Währungskurse und Rohstoffpreisen zeigt sich nur eine leichte Verschlechterung des MSE auf im Durchschnitt $0,000227$. Ebenso der Variationskoeffizient verschlechtert sich nur leicht auf durchschnittlich $6,4\%$. Auffällig ist eine starke Verschlechterung des MSE und dessen Variationskoeffizient bei Beifügung des risikolosen Zinssatzes auf $0,000465$ mit einer Variation von 40%. Dies kann kausal dadurch begründet werden, dass der risikolose Zinssatz bei einem Marktportfolio mit einem $\beta = 1$ keine Auswirkungen auf das klassische Modell des CAPM hat und sich somit nicht auf den intrinsischen Unternehmenswert auswirkt. Des Weiteren besteht ein kurzfristiger Umschwung von einer negativen zu einer positiven Korrelation des risikolosen Zinssatzes mit der Prognosezeitreihe zwischen dem Trainings- und dem Testzeitraum, welcher ein Grund für die starke Unterbewertung des Modells in dem Test-Zeitraum sein kann. Durch den nachteiligen Einfluss der ökonomischen Variable des risikolosen Zinssatzes auf das Modell zeigt sich eine Leistung des Versuchsmodells mit allen ökonomischen Variablen, die zwischen den zuvor genannten Modellen mit ähnlicher Leistung (Inflation, Währungskurse und Rohstoffpreise) und der deutlich schlechteren Leistung des Versuchsmodells mit dem risikolosen Zinssatz liegt. Der MSE-Wert beträgt dabei $0,000359$. Bezogen auf die klassischen Leistungsparameter ist die gesetzte Hypothese zu negieren, da sich alle getesteten ökonomischen Variablen negativ auf die Leistung der

Modelle nach MSE auswirken.

Durch eine Buy-&-Hold-Strategie wird innerhalb des Test-Zeitraums eine Rendite von $16,12\%$ erzielt. Die durchschnittliche Rendite des Basis-Modells, sowie die aller Versuchsmodelle liegen unterhalb dieses Benchmarks. Die durchschnittliche Rendite des Basis-Modells liegt bei $5,55\%$. Der Einfluss der ökonomischen Variablen auf die Handelsleistung unterscheidet sich. Ebenso wie bei der Leistung nach MSE resultiert die Beifügung des risikolosen Zinssatzes in der schlechtesten Rendite von durchschnittlich $2,46\%$. Die Leistung bei Beifügung der Rohstoffpreisdaten resultiert mit $2,7\%$ ebenfalls in einer schlechteren Leistung als die des Basis-Modells. Drei der Versuchsmodelle weisen eine höhere durchschnittliche Rendite gegenüber dem Basis-Modell auf. Modelle, welchen alle ökonomischen Variablen angehangen wurden, erzielten mit $8,9\%$ die beste Handelsleistung aller Versuchsmodelle. Die Versuchsmodelle mit den ökonomischen Variablen Wechselkurse und Inflation erzielten zudem bessere Handelsleistungen als das Basis-Modell mit jeweils $7,52\%$ und $6,71\%$. Die Verbesserung der Handelsleistung dieser ökonomischen Variablen lässt sich jedoch nicht auf deren positiven Einfluss auf das Modell zurückführen. Da der Kurs in dem gegebenen Handelszeitraum durchschnittlich steigt (Buy-&-Hold-Strategie von $16,12\%$) steigt die Rendite der Handelsstrategie durchschnittlich mit der Menge an Kauf-Signalen. Die Modelle mit allen ökonomischen Variablen angehangen resultieren in einer schlechteren Prognosegenauigkeit nach MSE. Ein durchschnittlicher ME von $0,007$ bei diesen Modellen zeigt eindeutig eine konstante Überprognose des Modells an. Dies resultiert bei zwei der simulierten Handelsstrategien in konstanten Kauf-Signalen, was bei einem allgemein steigendem Kurs des Wertpapiers die Handelsleistung dieser Handelsstrategien steigert. Dies gilt im umgekehrten Sinne für die Handelsleistung bei Beifügung des risikolosen Zinssatzes (ME von $-0,009$). Im Umkehrschluss sind die positiven Auswirkungen durch die genannten Merkmal-Kombinationen nicht auf deren positiven Einfluss auf das Modell, sondern eher auf deren schlechten Einfluss auf das Modell zurückzuführen und begründen sich durch die Methodik von zwei der drei Handelsstrategien. Zudem konnten selbst die Merkmal-Kombinationen, welche die Handelsleistung des Basis-Modells übertrafen, im Durchschnitt keine höheren Renditen als die Buy-&-Hold-Strategie erreichen. Die Hypothese kann ebenso für die Handelsleistungen nicht bestätigt werden, da sich bessere Handelsleistungen nicht auf den positiven Einfluss der ökonomischen Variablen zurückführen lassen.

Während sich Zweifel an dem Einfluss des risikolosen Zinssatzes und der Rohstoffpreise auf das Prognoseobjekt in diesem Versuch feststellen lassen, so bleibt der kausale Einfluss der weiteren Variablen unbestritten. Somit lässt sich in dieser Arbeit kein positiver Einfluss von kausal relevanten ökonomischen Variablen auf die Leistung von LSTM-Modellen nach-

weisen. Die Beobachtungen lassen sich durch die „Efficient Market Hypothesis“ erklären. In effizienten Märkten tragen alle verfügbaren Informationen zu der Preisbildung bei. Das Modell hat mit keiner der Merkmal-Kombinationen ausreichend Informationen, um den Markt erfolgreich zu prognostizieren. Des Weiteren wurden während dieser Arbeit weitere Versuchsansätze diskutiert, welche zu anderen Ergebnissen führen könnten. Es benötigt weitere Forschung, um eine statistisch allgemeine Aussage über den direkten Einfluss ökonomischer Variablen auf LSTM oder ML-Modelle an sich treffen zu können.

6.2. Ausblick

Der Versuch dieser Thesis unterliegt Ansätzen, welche geändert zu anderen Ergebnissen führen könnten. Die Struktur und Hyperparameter wurden ausschließlich für das Basis-Modell optimiert, könnten jedoch auch für alle anderen Versuchsmodelle erneut optimiert werden. Dies könnte den Modellen ermöglichen, neue Strukturen und Abhängigkeiten zu erkennen. Die Handelsstrategien operieren auf Basis täglicher Evaluation des Kurses. Als eine der größten Schwierigkeiten der Modelle zeigt sich die richtige Prognose der Kursänderungen von Tag zu Tag. Durchschnittlich über alle Modelle wird die Kursrichtung nur zu $47,74\%$ korrekt prognostiziert. Obwohl die Modelle den allgemeinen Trend richtig verfolgen, sind die täglichen Prognosen durch die Volatilität des Kurses oft ungenau. Dies führt zu schlechten Handelsergebnissen. Ein weiterer Ansatz wäre hier Handelsstrategien zu implementieren, welche in einer langsameren Frequenz handeln.

Diese Thesis legt Grundlage für weitere Erforschung des direkten Einflusses von ökonomischen Variablen auf die Leistung, auch von ML-Modellen im Allgemeinen. Ziel ist es, die Einflüsse besser zu verstehen, ohne die Möglichkeit, die komplexen Modelle in Ihrer Entscheidungsstruktur direkt einsehen zu können. Basierend auf dem kausalen Einfluss der ökonomischen Variablen wurden in dieser Thesis die direkten Auswirkungen auf die Modellleistungen erforscht. Anhand von Tests wie der Granger-Kausalitätsprüfung könnte der statistische Nutzen der ökonomischen Variablen für die Prognose getestet werden. Auch spielt die Wahl des Versuchszeitraums eine wichtige Rolle, wurde jedoch in dieser Thesis als fix angenommen. Der kausale Einfluss von ökonomischen Variablen ändert sich im Verlaufe der Zeit. Spiegelt sich diese Veränderung auch in der Leistung der Modelle wider? Wie wirken sich fundamentale Variablen auf die Leistung aus?

Die Prognose von Aktienkursen mit ML-Modellen ist höchst komplex. Eine auf den ersten Blick annähernd deckende Prognosezeitreihe setzt sich nicht direkt in eine erfolgreiche Handelsleistung um. Für eine erfolgreiche Nutzung von Prognosen in einer Handelsstrategie

benötigt es tagesgenaue Prognosen, die besonders die Kursrichtung erfassen. Schon nach der „Efficient Market Hypothesis“ der schwachen Form ist eine korrekte Prognose alleinig durch die Kursdaten nicht möglich. Unter Annahme eines semi-effizienten Marktes ist es relevant, die Modelle zukünftig mit einer Vielzahl an fundamentalen und ökonomischen Variablen zu speisen, weshalb die Forschung in diesem Bereich von höchster Relevanz ist. Ein gutes Verständnis der kausalen und statistischen Zusammenhänge der einzelnen Variablen mit dem Aktienkurs und dem Unternehmenswert sind demnach obligatorisch, um funktionierende Modelle zu entwickeln.

Literaturverzeichnis

Akiba, T., Sano, S., Yanase, T., Ohta, T., & Koyama, M. (2019). Optuna: A Next-generation Hyperparameter Optimization Framework. https://doi.org/10.48550/ARXIV.1907.10902

Arnold, G., & Lewis, D. S. (2019). *Corporate financial management* (Sixth edition). Pearson. https://ebookcentral.proquest.com/lib/kxp/detail.action?docID=5832818

Bartram, S. M. (2005). The Impact of Commodity Price Risk on Firm Value - An Empirical Analysis of Corporate Commodity Price Exposures. *Multinational Finance Journal*, *9*(3/4), 161–187. https://doi.org/10.17578/9-3/4-2

Beck, T., & Levine, R. (2004). Stock markets, banks, and growth: Panel evidence. *Journal of Banking & Finance*, *28*(3), 423–442. https://doi.org/10.1016/S0378-4266(02)00408-9

Bellman, R. E. (1978). *Artificial intelligence: Can computers think?* Boyd & Fraser.

Bengio, Y., Frasconi, P., & Simard, P. (1993). The problem of learning long-term dependencies in recurrent networks, 1183–1188. https://doi.org/10.1109/ICNN.1993.298725

Bengio, Y., Simard, P., & Frasconi, P. (1994). Learning long-term dependencies with gradient descent is difficult. *IEEE transactions on neural networks*, *5*(2), 157–166. https://doi.org/10.1109/72.279181

Bloomberg. (2023a). BBDXY DES Description Screen: Bloomberg Dollar Spot Index.

Bloomberg. (2023b). BBDXY GP Price Chart 01/12/2018 to 01/12/2021 daily.

Bloomberg. (2023c). BCOM DES Description Screen: Bloomberg Commodity Index.

Bloomberg. (2023d). BCOM GP Price Chart 01/12/2018 to 01/12/2021 daily.

Bloomberg. (2023e). SPXT GP Price Chart 01/12/2018 to 01/12/2021 daily: S&P 500 Total Return Index.

Bloomberg. (2023f). USGG30YR GP Price Chart 01/12/2018 to 01/12/2021 daily: US 30 Year Generic Treasury Bond Yield.

Bodie, Z. (1976). COMMON STOCKS AS A HEDGE AGAINST INFLATION. *The Journal of Finance*, *31*(2), 459–470. https://doi.org/10.1111/j.1540-6261.1976.tb01899.x

Cho, K., van Merrienboer, B., Gulcehre, C., Bahdanau, D., Bougares, F., Schwenk, H., & Bengio, Y. (2014). Learning Phrase Representations using RNN Encoder-Decoder for Statistical Machine Translation. http://arxiv.org/pdf/1406.1078v3

Christopher Olah. (2015). Understanding LSTM Networks. Verfügbar 13. Dezember 2023 unter https://colah.github.io/posts/2015-08-Understanding-LSTMs/

Damodaran, A. (2012). *Investment valuation: Tools and techniques for determining the value of any asset* (3rd ed.). Wiley. https://ebookcentral.proquest.com/lib/kxp/detail.action?docID=817866

David Stutz. (2014). Introduction to Neural Networks. https://davidstutz.de/wordpress/wp-content/uploads/2014/03/seminar.pdf

Fabian Pedregosa, Gaël Varoquaux, Alexandre Gramfort, Vincent Michel, Bertrand Thirion, Olivier Grisel, Mathieu Blondel, Peter Prettenhofer, Ron Weiss, Vincent Dubourg, Jake Vanderplas, Alexandre Passos, David Cournapeau, Matthieu Brucher, Matthieu Perrot & Édouard Duchesnay. (2011). Scikit-learn: Machine Learning in Python. *Journal of Machine Learning Research*, *12*(85), 2825–2830. http://jmlr.org/papers/v12/pedregosa11a.html

Fama, E. F. (1970). Efficient Capital Markets: A Review of Theory and Empirical Work. *The Journal of Finance*, *25*(2), 383. https://doi.org/10.2307/2325486

Fama, E. F. (1995). Random Walks in Stock Market Prices. *Financial Analysts Journal*, *51*(1), 75–80. https://doi.org/10.2469/faj.v51.n1.1861

Fama, E. F., & French, K. R. (2004). The Capital Asset Pricing Model: Theory and Evidence. *Journal of Economic Perspectives*, *18*(3), 25–46. https://doi.org/10.1257/0895330042162430

Fama, E. F., & Schwert, G. (1977). Asset returns and inflation. *Journal of Financial Economics*, *5*(2), 115–146. https://doi.org/10.1016/0304-405X(77)90014-9

Fischer, T., & Krauss, C. (2018). Deep learning with long short-term memory networks for financial market predictions. *European Journal of Operational Research*, *270*(2), 654–669. https://doi.org/10.1016/j.ejor.2017.11.054

Flood, E., & Lessard, D. R. (1986). On the Measurement of Operating Exposure to Exchange Rates: A Conceptual Approach. *Financial Management*, *15*(1), 25. https://doi.org/10.2307/3665275

François Chollet. (2016). Keras. Verfügbar 13. Dezember 2023 unter https://github.com/keras-team/keras

Goodfellow, I., Bengio, Y., & Courville, A. (2018). *Deep Learning: Das umfassende Handbuch : Grundlagen, aktuelle Verfahren und Algorithmen, neue Forschungsansätze*

(1st edition). mitp. https://ebookcentral.proquest.com/lib/kxp/detail.action?docID=5598176

Gordon, M. J. (1959). Dividends, Earnings, and Stock Prices. *The Review of Economics and Statistics*, *41*(2), 99. https://doi.org/10.2307/1927792

Grunert, P. (2021). *Machine Learning und neuronale Netze: Der verständliche Einstieg mit Python*. BMU Media GmbH.

Hicks, J. (1939). *Value and capital: An inquiry into some fundamental principles of economic theory* (2. ed., reprint). Clarendon Press.

Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural computation*, *9*(8), 1735–1780. https://doi.org/10.1162/neco.1997.9.8.1735

Hochreiter, S. (1991). Untersuchungen zu dynamischen neuronalen Netzen.

Jaeger, H., & Haas, H. (2004). Harnessing nonlinearity: predicting chaotic systems and saving energy in wireless communication. *Science (New York, N.Y.)*, *304*(5667), 78–80. https://doi.org/10.1126/science.1091277

Kendall, M. G., & Hill, A. B. (1953). The Analysis of Economic Time-Series-Part I: Prices. *Journal of the Royal Statistical Society. Series A (General)*, *116*(1), 11. https://doi.org/10.2307/2980947

Kingma, D. P., & Ba, J. (2014). Adam: A Method for Stochastic Optimization. https://doi.org/10.48550/ARXIV.1412.6980

Kumbure, M. M., Lohrmann, C., Luukka, P., & Porras, J. (2022). Machine learning techniques and data for stock market forecasting: A literature review. *Expert Systems with Applications*, *197*, 116659. https://doi.org/10.1016/j.eswa.2022.116659

Lintner, J. (1965). The Valuation of Risk Assets and the Selection of Risky Investments in Stock Portfolios and Capital Budgets. *The Review of Economics and Statistics*, *47*(1), 13. https://doi.org/10.2307/1924119

Lo, A. W., & MacKinlay, A. C. (1988). Stock Market Prices Do Not Follow Random Walks: Evidence from a Simple Specification Test. *Review of Financial Studies*, *1*(1), 41–66. https://doi.org/10.1093/rfs/1.1.41

Maass, W., Natschläger, T., & Markram, H. (2002). Real-time computing without stable states: a new framework for neural computation based on perturbations. *Neural computation*, *14*(11), 2531–2560. https://doi.org/10.1162/089976602760407955

Markowitz, H. (1952). PORTFOLIO SELECTION*. *The Journal of Finance*, *7*(1), 77–91. https://doi.org/10.1111/j.1540-6261.1952.tb01525.x

McKinney, W. (2010). Data Structures for Statistical Computing in Python. *Proceedings of the 9th Python in Science Conference*, 56–61. https://doi.org/10.25080/Majora-92bf1922-00a

Mishkin, F. S. (2016). *The economics of money, banking, and financial markets* (Eleventh edition, global edition). Pearson. https://search.ebscohost.com/login.aspx?direct=true&scope=site&db=nlebk&db=nlabk&AN=1419607

Murphy, K. (2014). *Machine Learning - A Probabilistic Perspective*. MIT Press. http://gbv.eblib.com/patron/FullRecord.aspx?p=3339490

Muth, J. F. (1961). Rational Expectations and the Theory of Price Movements. *Econometrica*, *29*(3), 315. https://doi.org/10.2307/1909635

Niaki, S. T. A., & Hoseinzade, S. (2013). Forecasting S&P 500 index using artificial neural networks and design of experiments. *Journal of Industrial Engineering International*, *9*(1). https://doi.org/10.1186/2251-712X-9-1

Nti, K. O., Adekoya, A., & Weyori, B. (2019). Random Forest Based Feature Selection of Macroeconomic Variables for Stock Market Prediction. *SSRN Electronic Journal*. https://doi.org/10.2139/ssrn.3446053

Peiró, A. (2016). Stock prices and macroeconomic factors: Some European evidence. *International Review of Economics & Finance*, *41*, 287–294. https://doi.org/10.1016/j.iref.2015.08.004

Purves, D. (Hrsg.). (2004). *Neuroscience* (3. ed.). Sinauer Associates.

Rich, E., & Knight, K. (1996). *Artificial intelligence* (2. ed., repr. in India). Tata McGraw-Hill.

Rumelhart, D. E., Hinton, G. E., & Williams, R. J. (1986). Learning representations by back-propagating errors. *Nature*, *323*(6088), 533–536. https://doi.org/10.1038/323533a0

Russell, S., & Norvig, P. (2016). *Artificial intelligence: A modern approach* (Third edition). Pearson. https://elibrary-pearson-de.hs-ruhrwest.idm.oclc.org/book/99.150005/9781292153971

Schwert, G. W. (2013). Chapter 15 Anomalies and market efficiency. In G. M. Constantinides, M. Harris & R. M. Stulz (Hrsg.), *Handbook of the economics of finance* (S. 941–970, Bd. 1). North Holland. https://doi.org/10.1016/S1574-0102(03)01024-0

Sharpe, W. F. (1964). CAPITAL ASSET PRICES: A THEORY OF MARKET EQUILIBRIUM UNDER CONDITIONS OF RISK*. *The Journal of Finance*, *19*(3), 425–442. https://doi.org/10.1111/j.1540-6261.1964.tb02865.x

S&P Global (Hrsg.). (2024). S&P 500 Index Übersicht. Verfügbar 14. Februar 2024 unter https://www.spglobal.com/spdji/en/indices/equity/sp-500/#overview

Tsai, C.-F., & Hsiao, Y.-C. (2010). Combining multiple feature selection methods for stock prediction: Union, intersection, and multi-intersection approaches. *Decision Support Systems*, *50*(1), 258–269. https://doi.org/10.1016/j.dss.2010.08.028

US Bureau of Labor Statistics. (2023). Consumer Price Index for All Urban Consumers Table 2018-2023. Verfügbar 1. Dezember 2023 unter https://data.bls.gov/pdq/SurveyOutputServlet

Winston, P. H. (1993). *Artificial intelligence* (3. ed., repr. with corr). Addison-Wesley.

Zhong, X., & Enke, D. (2019). Predicting the daily return direction of the stock market using hybrid machine learning algorithms. *Financial Innovation*, *5*(1). https://doi.org/10.1186/s40854-019-0138-0

A. Zusätzliche Abbildungen

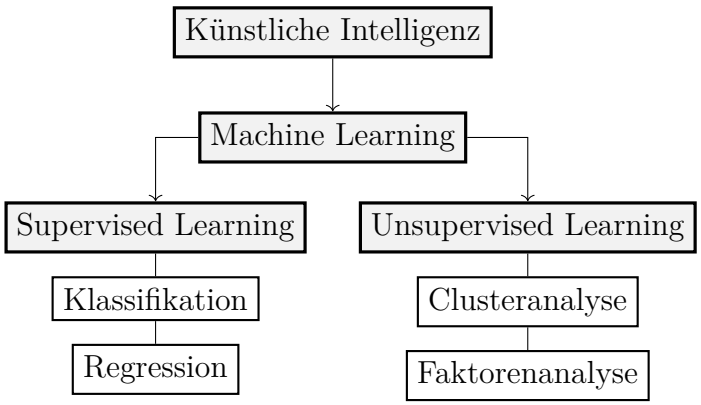

Abbildung A.1.: Ansätze des Machine Learning
(Quelle: Eigene Darstellung)

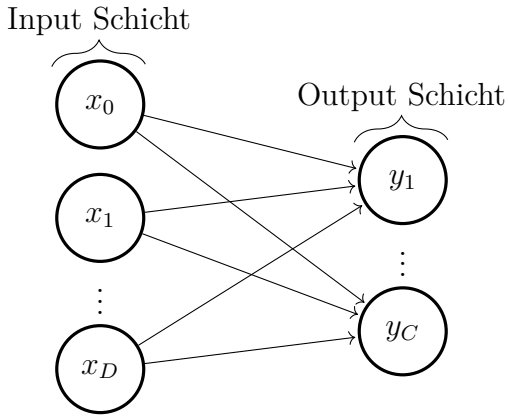

Abbildung A.2.: Einfaches Neuronales Netzwerk
(Quelle: In Anlehnung an David Stutz, 2014)

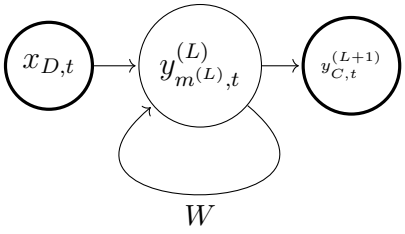

Abbildung A.3.: Versteckes Neuron eines RNN´s
(Quelle: Eigene Darstellung)

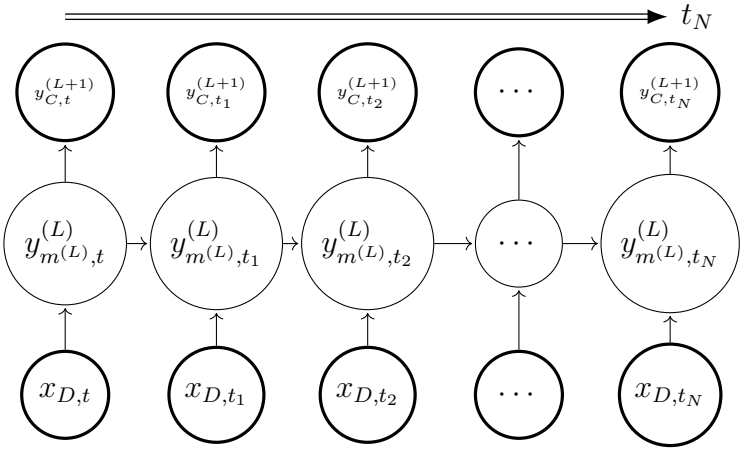

Abbildung A.4.: RNN´s im Verlauf von t
(Quelle: Eigene Darstellung)

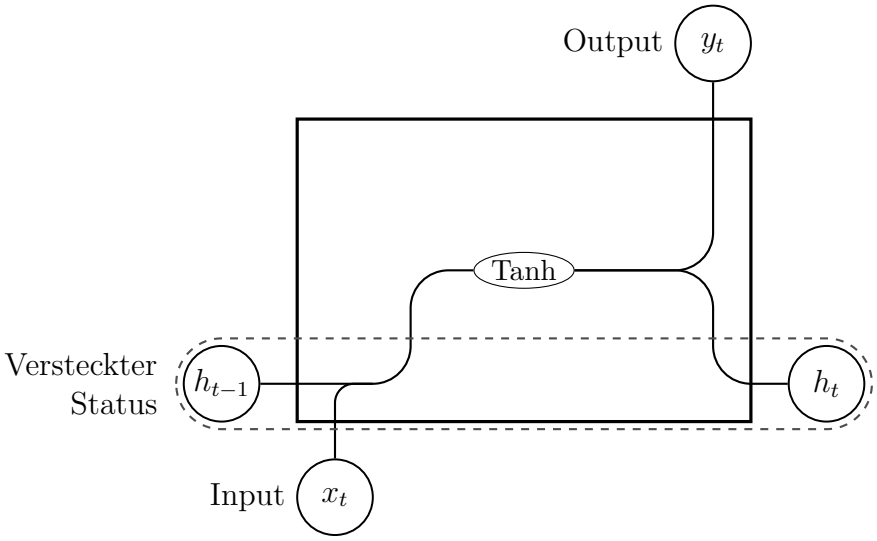

Abbildung A.5.: RNN-Zelle
(Quelle: In Anlehnung an Christopher Olah, 2015)

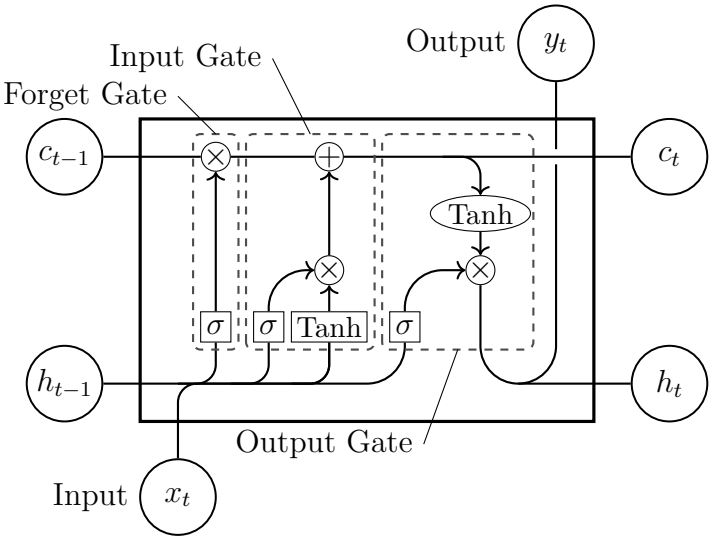

Abbildung A.6.: Die Gates einer LSTM-Zelle
(Quelle: In Anlehnung an Christopher Olah, 2015)

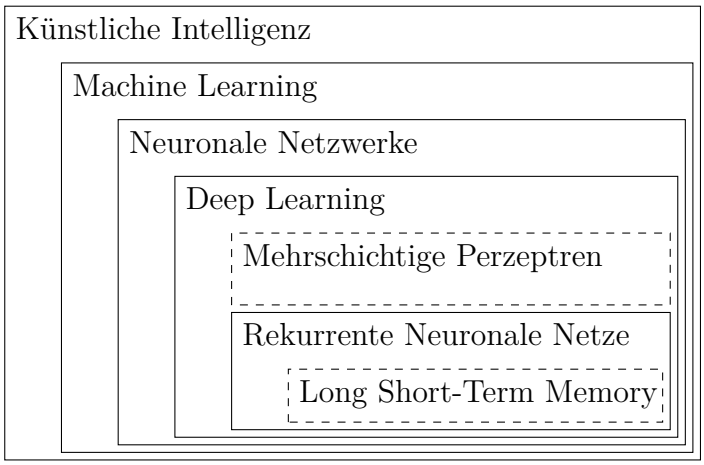

Abbildung A.7.: Bereiche der KI
(Quelle: Eigene Darstellung)

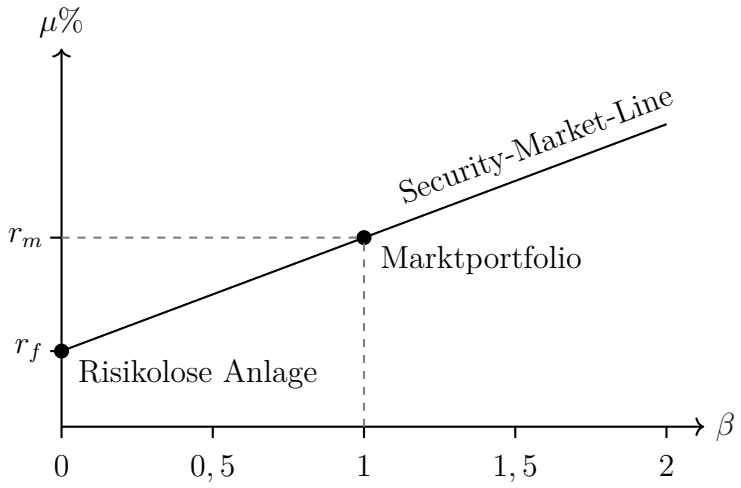

Abbildung A.8.: CAPM: Security-Market-Line
(Quelle: in Anlehnung an Arnold und Lewis, 2019, S. 290)

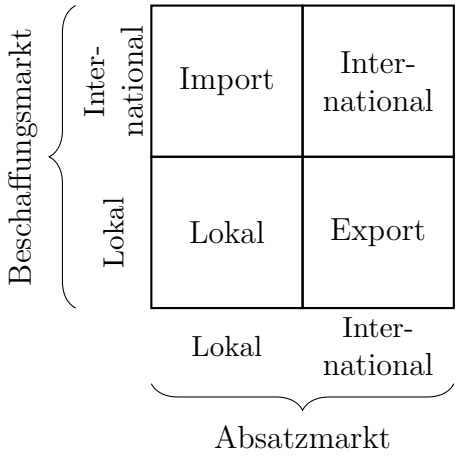

Abbildung A.9.: Unternehmensklassen nach Flood und Lessard, 1986
(Quelle: Eigene Darstellung)

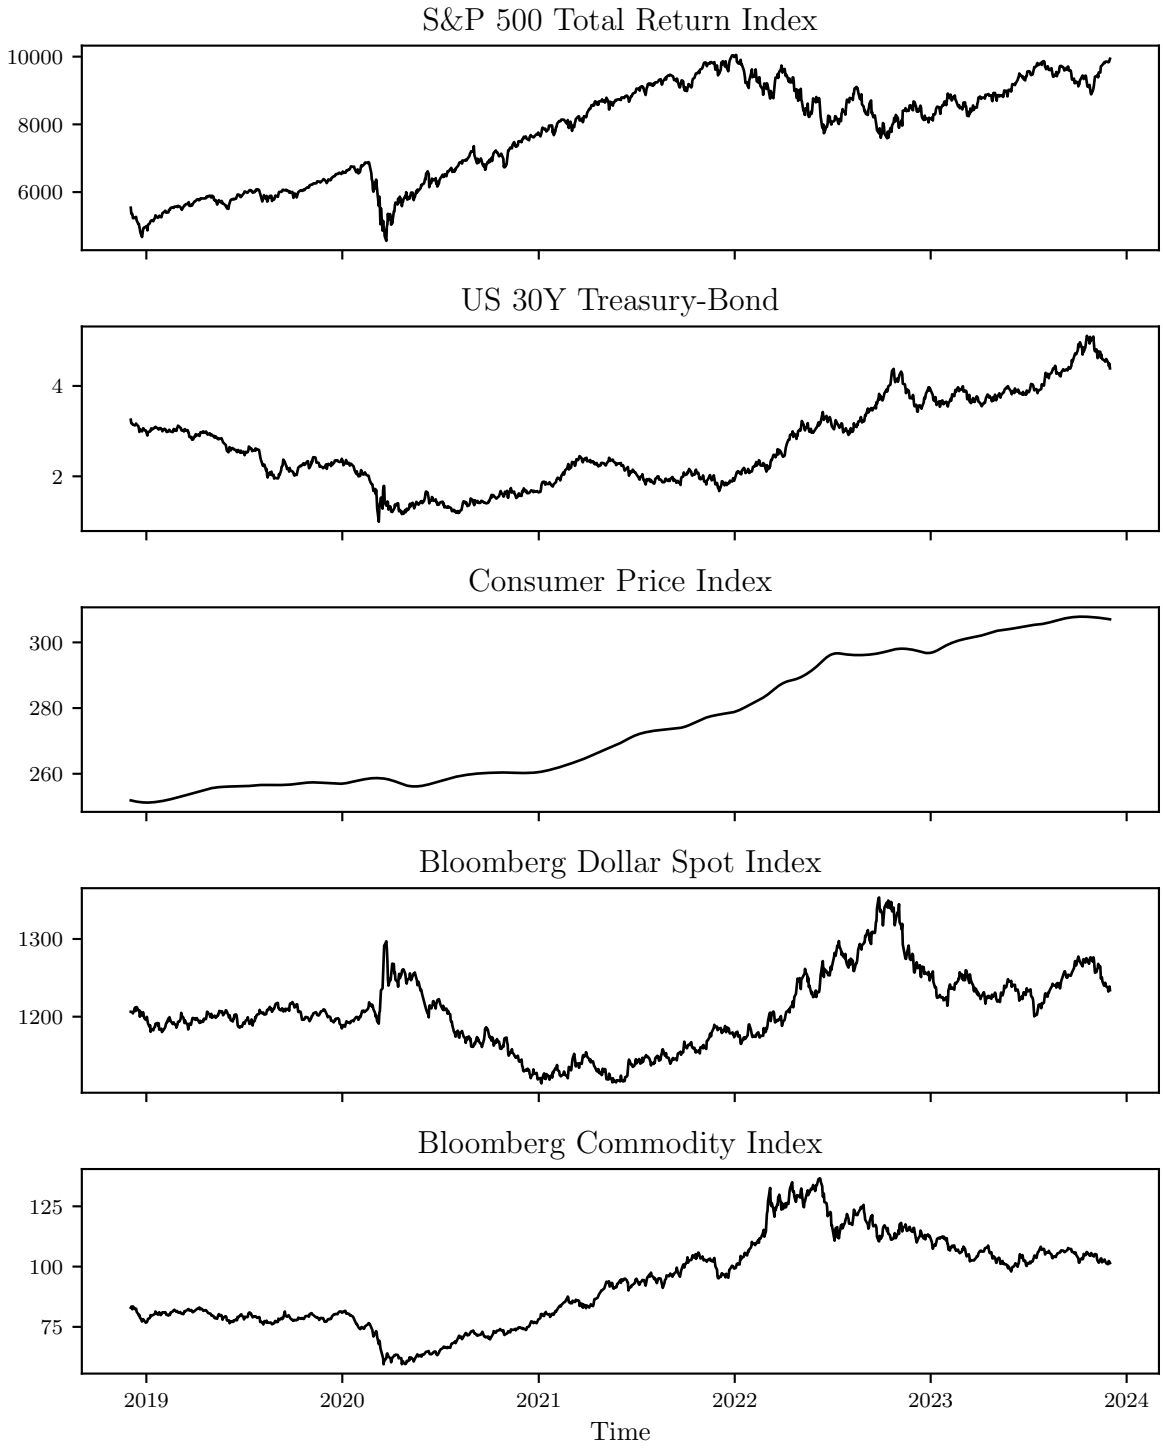

Abbildung A.10.: Alle Merkmale in der Zeitfolge
(Quelle: Eigene Darstellung)

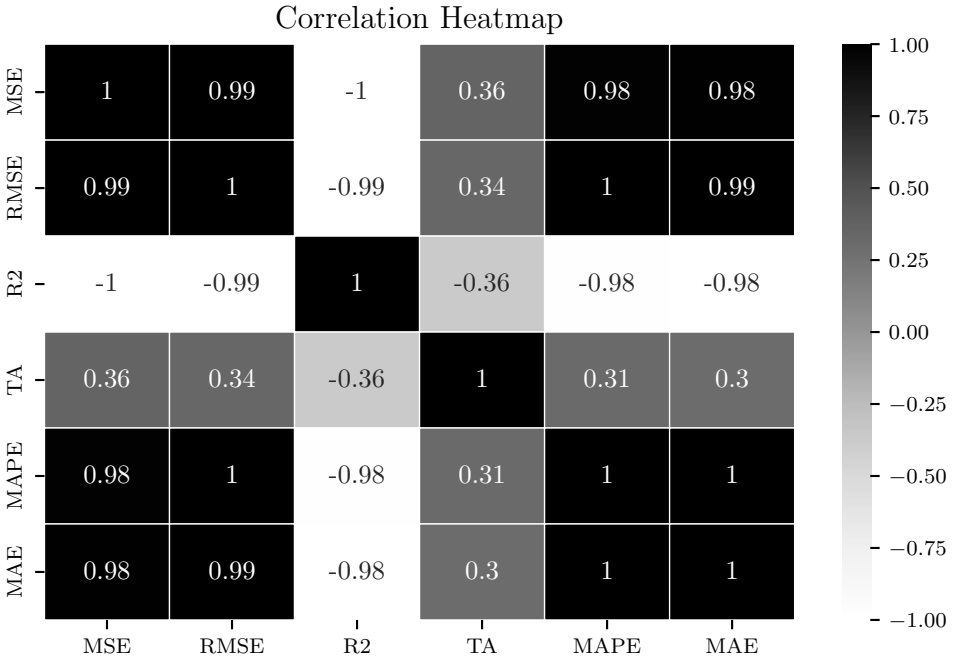

Abbildung A.11.: Korrelation der Leistungsparameter (Quelle: Eigene Darstellung)

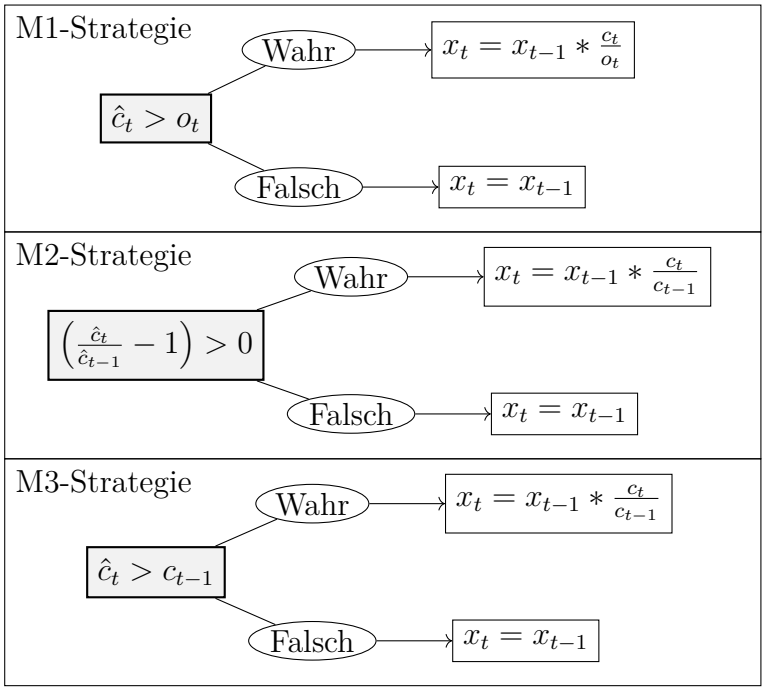

Notiz: Entscheidungsprozess für die Bewertung des Portfolios x zu jedem Handelstag t auf Basis der Prognose des Close-Preises $\hat{c}$ und der tatsächlichen Open- & Close-Preise o,c.

Abbildung A.12.: Prozess: Simulierte Handelsstrategien (Quelle: Eigene Darstellung)

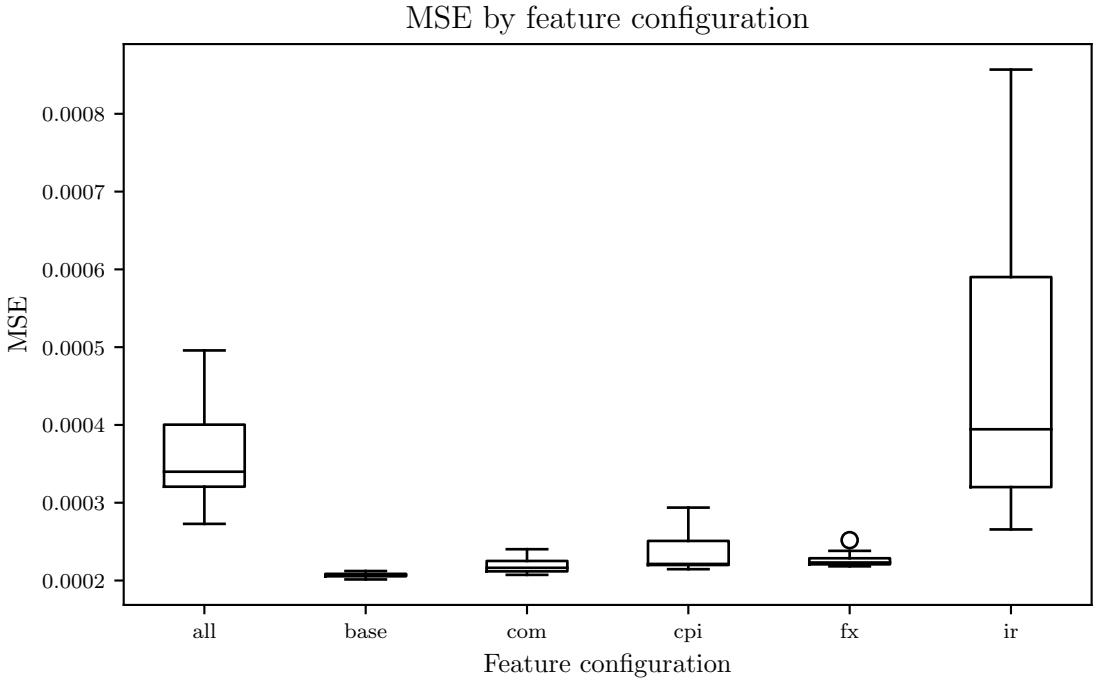

Abbildung A.13.: MSE Boxplot (Quelle: Eigene Darstellung)

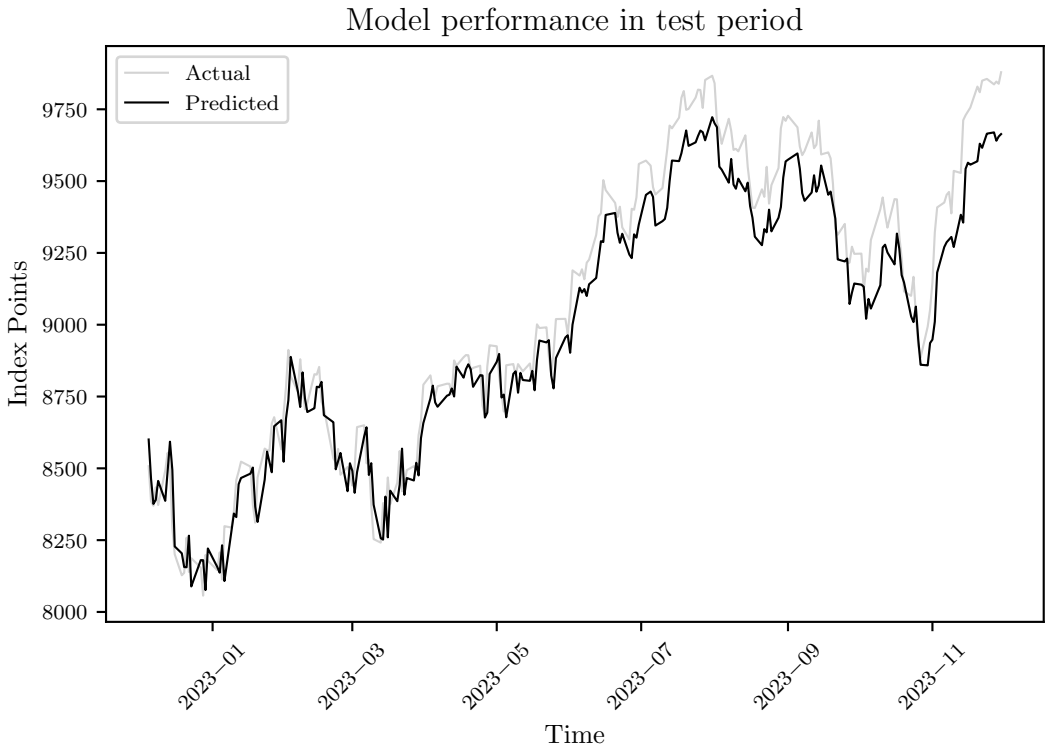

Abbildung A.14.: Model „ir“ Prognosen im Testzeitraum (Quelle: Eigene Darstellung)

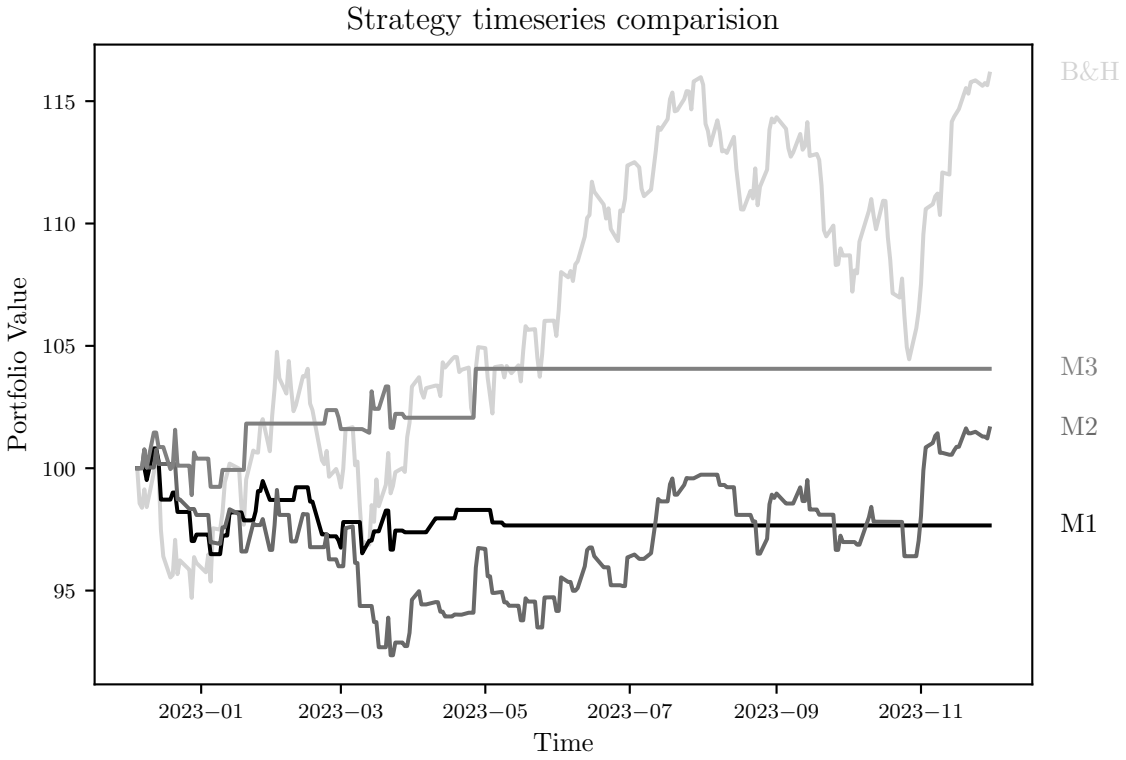

Notiz: Exemplarische Darstellung des Portfoliowertes eines Modells der „ir“ Merkmal Konfiguration. Die Prognosen genau dieses Modells sind in Abbildung A.14 dargestellt. Durch die Unterbewertung des Modells entsteht eine lange Periode ohne aktiven Handel der Handelsstrategien „M1“ und „M3“.

Abbildung A.15.: Model „ir“ Handelsleistung
(Quelle: Eigene Darstellung)

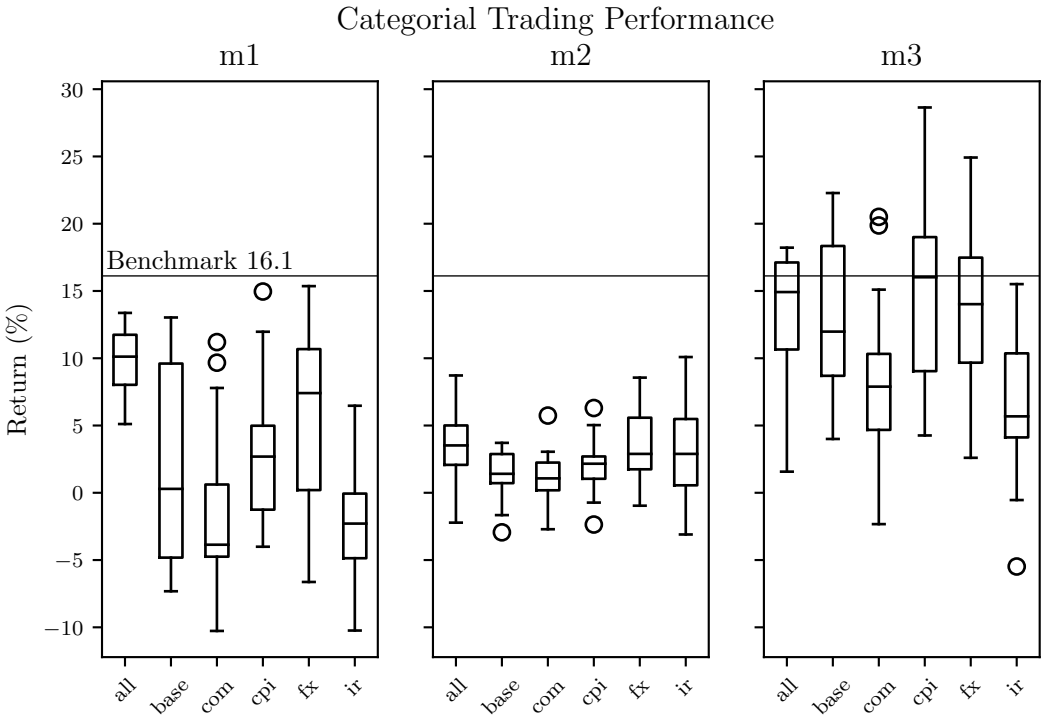

Abbildung A.16.: Rendite nach Merkmal-Kombination
(Quelle: Eigene Darstellung)

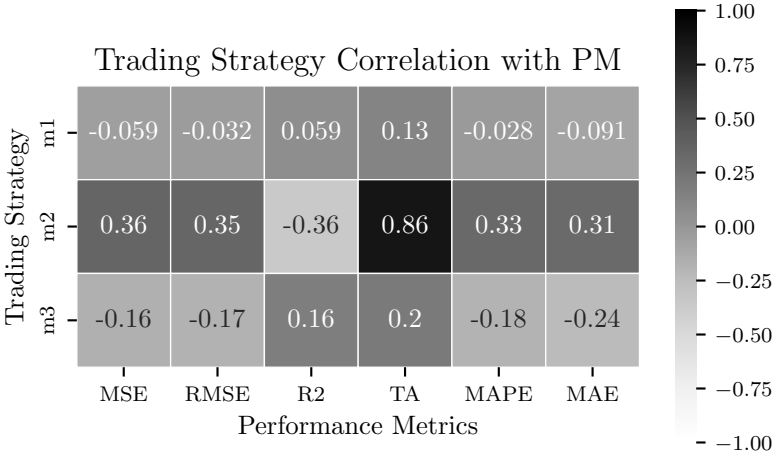

Abbildung A.17.: Korrelation Handelsleistung und Leistungsparameter
(Quelle: Eigene Darstellung)

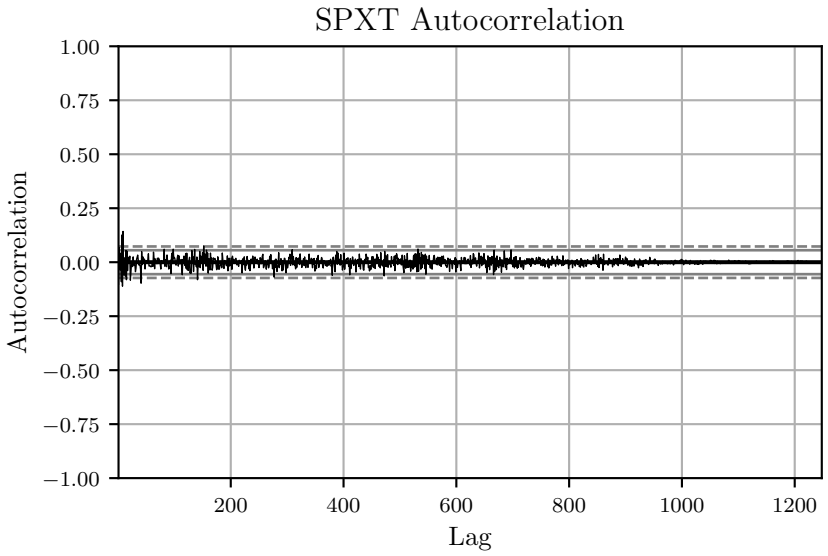

Abbildung A.18.: S&P 500 Total Index Autokorrelation
(Quelle: Eigene Darstellung)

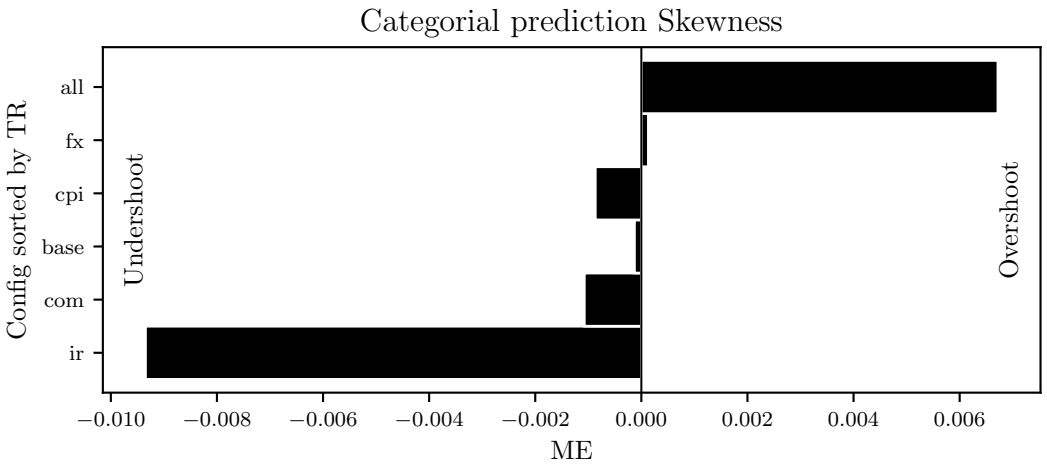

Notiz: Darstellung der ME für alle Merkmal-Kombinationen. Ein positiver ME-Wert steht für eine durchschnittliche Überbewertung (eng. Overshooting) und ein negativer Wert für eine durchschnittliche Unterbewertung (eng. Undershooting). Die Kategorien sind nach der durchschnittlichen Handelsleistung sortiert (oben beste; unten schlechteste).

Abbildung A.19.: Prognose Abweichungsrichtung nach Merkmal-Kombination
(Quelle: Eigene Darstellung)

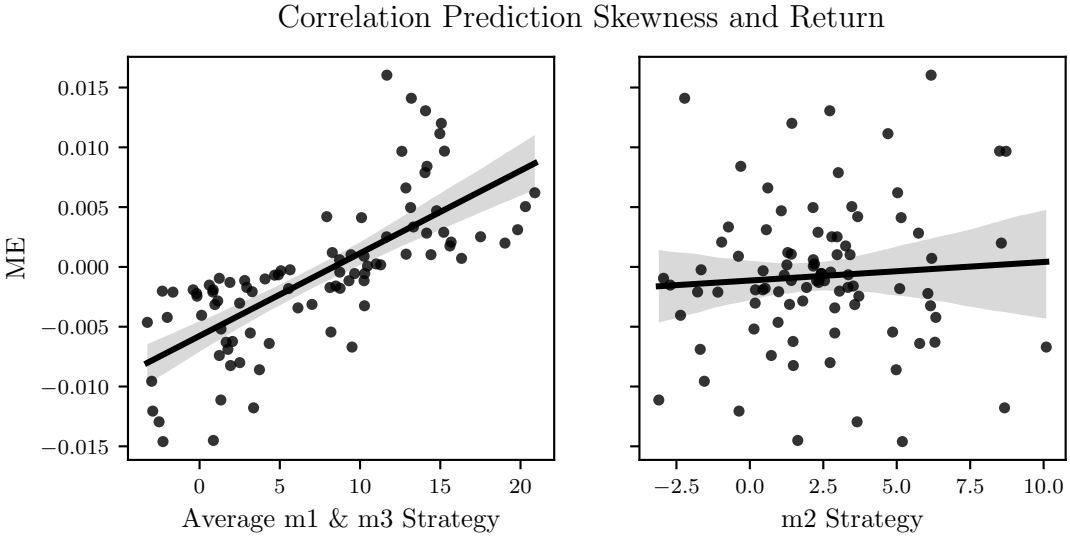

Notiz: Korrelationskoeffizient der durchschnittlichen Rendite der Handelsstrategien „M1“ und „M3“ gegenüber dem ME liegt bei $0,73$. Der Korrelationskoeffizient zwischen der Handelsstrategie „M2“ und ME liegt bei $0,07$. Dies beweist, dass sich eine konstante Überprognose positiv auf die Rendite der Handelsstrategien „M1“ und „M3“ auswirkt.

Abbildung A.20.: Korrelation zwischen ME und Handelsstrategien
(Quelle: Eigene Darstellung)

B. Zusätzliche Tabellen

Leistungsparameter	Formel
Mean Error (ME)	$\frac{1}{n}\sum_{i=0}^{n-1}\hat{y}_i - y_i$
Mean Absolute Error (MAE)	$\frac{1}{n}\sum_{i=0}^{n-1}\lvert y_i - \hat{y}_i\rvert$
Mean Absolute Percentage Error (MAPE)	$\frac{1}{n}\sum_{i=0}^{n-1}\frac{\lvert y_i-\hat{y}_i\rvert}{\lvert y_i\rvert}$
Mean Squared Error (MSE)	$\frac{1}{n}\sum_{i=0}^{n-1}(y_i - \hat{y}_i)^2$
Root Mean Squared Error (RMSE)	$\sqrt{\frac{1}{n}\sum_{i=0}^{n-1}(y_i - \hat{y}_i)^2}$
Bestimmtheitsmaß (R2)	$1 - \frac{\sum_{i=1}^{n}(y_i-\hat{y}_i)^2}{\sum_{i=1}^{n}(y_i-\bar{y}_i)^2}$

Notiz: Die Zielgröße ist hier definiert durch y_i und die Prognose der Zielgröße als $\hat{y}_i$. Die Formeln (abgesehen ME) entstammen der Python Bibliothek „scikit learn“ (Fabian Pedregosa et al., 2011).

Tabelle B.1.: Dokumentierte klassische Leistungsparameter

Config	count	mean	std	min	max	median	cv
all	15	0.000359	0.000059	0.000273	0.000496	0.000340	0.163688
base	15	0.000207	0.000003	0.000201	0.000212	0.000207	0.014662
com	15	0.000219	0.000010	0.000207	0.000240	0.000216	0.045952
cpi	15	0.000236	0.000025	0.000215	0.000294	0.000221	0.107568
fx	15	0.000226	0.000009	0.000218	0.000252	0.000223	0.039169
ir	15	0.000465	0.000186	0.000266	0.000857	0.000394	0.399825

Tabelle B.2.: MSE Deskriptive Statistik

	m1	m2	m3
count	90.00	90.00	90.00
mean	2.82	2.42	11.67
std	6.98	2.78	6.87
min	-10.27	-3.10	-5.48
max	15.36	10.09	28.64
CV	2.47	1.15	0.59

Tabelle B.3.: Handelsstrategien Deskriptive Statistik

ID	MSE	RMSE	R2	TA	MAPE	MAE	ME	bh	m1	m2	m3	config
0	0,000202	0,014218	0,9760	47,58	0,014269	0,011289	-0,000323	16,12	0,14	0,45	10,00	base
1	0,000210	0,014485	0,9751	45,56	0,014600	0,011595	-0,002109	16,12	-7,32	-1,09	4,00	base
2	0,000201	0,014191	0,9761	47,58	0,014264	0,011296	-0,000689	16,12	-3,96	1,17	13,31	base
3	0,000208	0,014433	0,9753	48,39	0,014462	0,011501	-0,002448	16,12	-5,68	3,71	5,36	base
4	0,000204	0,014287	0,9758	47,98	0,014329	0,011327	0,001023	16,12	9,55	2,97	19,29	base
5	0,000208	0,014420	0,9753	47,98	0,014511	0,011446	0,002522	16,12	12,87	2,79	22,15	base
6	0,000212	0,014567	0,9748	47,98	0,014649	0,011685	-0,003149	16,12	-7,17	3,57	9,08	base
7	0,000205	0,014329	0,9756	47,58	0,014415	0,011384	0,001064	16,12	11,29	1,41	14,45	base
8	0,000206	0,014341	0,9756	47,18	0,014421	0,011405	0,000174	16,12	0,29	1,26	22,28	base
9	0,000211	0,014524	0,9750	47,58	0,014640	0,011535	0,002896	16,12	13,03	2,32	17,40	base
10	0,000207	0,014386	0,9754	46,77	0,014433	0,011469	-0,002074	16,12	-3,74	0,98	10,30	base
11	0,000209	0,014450	0,9752	45,16	0,014500	0,011467	-0,000952	16,12	-5,85	-2,94	8,31	base
12	0,000208	0,014426	0,9753	47,58	0,014469	0,011421	0,000603	16,12	5,46	2,16	11,98	base
13	0,000206	0,014337	0,9756	45,97	0,014309	0,011305	-0,000240	16,12	4,50	-1,66	6,78	base
14	0,000206	0,014350	0,9756	47,98	0,014401	0,011371	0,001753	16,12	9,66	3,26	21,54	base
15	0,000496	0,022267	0,9412	50,40	0,022915	0,017944	0,016034	16,12	7,80	6,17	15,54	all
16	0,000307	0,017521	0,9636	47,58	0,017709	0,014270	-0,001598	16,12	6,94	3,52	10,04	all
17	0,000337	0,018368	0,9600	49,60	0,018621	0,014585	0,009667	16,12	11,34	8,72	13,87	all
18	0,000337	0,018357	0,9600	49,19	0,018463	0,014339	0,009681	16,12	13,37	8,50	17,15	all
19	0,000311	0,017621	0,9632	47,58	0,017789	0,013992	0,004203	16,12	9,16	3,67	6,69	all
20	0,000273	0,016517	0,9676	50,00	0,016537	0,013060	0,004119	16,12	6,66	5,15	13,52	all
21	0,000343	0,018511	0,9593	46,77	0,018648	0,014548	0,008412	16,12	10,12	-0,31	18,22	all
22	0,000436	0,020884	0,9483	44,76	0,021311	0,016624	0,014103	16,12	9,30	-2,22	17,09	all

ID	MSE	RMSE	R2	TA	MAPE	MAE	ME	bh	m1	m2	m3	config
23	0,000307	0,017531	0,9635	47,18	0,017720	0,013865	0,007882	16,12	13,17	3,01	14,92	all
24	0,000331	0,018185	0,9608	48,39	0,018228	0,014700	-0,000658	16,12	8,25	3,35	1,57	all
25	0,000355	0,018843	0,9579	48,79	0,018950	0,015481	-0,005446	16,12	5,11	4,86	11,26	all
26	0,000404	0,020100	0,9521	48,39	0,020270	0,015710	0,012006	16,12	11,95	1,43	18,18	all
27	0,000397	0,019918	0,9529	49,19	0,020272	0,015777	0,011144	16,12	11,99	4,70	17,95	all
28	0,000410	0,020259	0,9513	48,39	0,020618	0,016080	0,013055	16,12	11,54	2,72	16,62	all
29	0,000340	0,018436	0,9597	45,56	0,018442	0,014898	-0,001791	16,12	10,56	0,52	6,95	all
30	0,000519	0,022782	0,9384	45,97	0,022884	0,019148	-0,014509	16,12	-2,34	1,63	4,06	ir
31	0,000706	0,026568	0,9163	50,40	0,025837	0,021709	-0,014604	16,12	-10,24	5,19	5,68	ir
32	0,000857	0,029272	0,8984	52,42	0,028269	0,023536	-0,011785	16,12	-4,25	8,67	10,98	ir
33	0,000661	0,025715	0,9216	52,02	0,024636	0,020210	-0,006701	16,12	3,49	10,09	15,51	ir
34	0,000445	0,021089	0,9472	47,58	0,021490	0,017888	-0,012952	16,12	-5,67	3,65	0,62	ir
35	0,000394	0,019860	0,9532	46,77	0,019892	0,016413	-0,008245	16,12	-4,30	1,48	8,16	ir
36	0,000714	0,026713	0,9153	47,18	0,024954	0,020730	-0,006400	16,12	2,12	5,78	6,56	ir
37	0,000372	0,019299	0,9558	44,76	0,019761	0,016298	-0,011127	16,12	-1,52	-3,10	4,17	ir
38	0,000266	0,016299	0,9685	47,58	0,016608	0,013455	-0,005527	16,12	-5,80	2,89	12,12	ir
39	0,000468	0,021626	0,9445	46,37	0,021654	0,018071	-0,012056	16,12	-0,36	-0,37	-5,48	ir
40	0,000281	0,016757	0,9667	47,98	0,016969	0,013686	-0,003248	16,12	6,47	6,15	14,08	ir
41	0,000365	0,019106	0,9567	47,98	0,019161	0,015799	-0,008597	16,12	-2,29	4,98	9,75	ir
42	0,000296	0,017208	0,9649	47,58	0,017631	0,014404	-0,008003	16,12	0,24	2,73	4,77	ir
43	0,000294	0,017144	0,9651	45,56	0,017378	0,014171	-0,006892	16,12	-1,93	-1,69	5,46	ir
44	0,000344	0,018550	0,9592	45,97	0,018968	0,015623	-0,009559	16,12	-5,43	-1,55	-0,54	ir
45	0,000220	0,014824	0,9739	45,97	0,014971	0,011741	0,003341	16,12	5,78	-0,73	20,87	cpi
46	0,000240	0,015498	0,9715	47,98	0,015627	0,012194	0,005043	16,12	11,97	3,47	28,64	cpi

ID	MSE	RMSE	R2	TA	MAPE	MAE	ME	bh	m1	m2	m3	config
47	0,000215	0,014648	0,9745	47,58	0,014787	0,011691	0,000072	16,12	1,94	2,16	18,99	cpi
48	0,000220	0,014836	0,9739	47,18	0,014969	0,011878	-0,000553	16,12	4,38	2,43	14,94	cpi
49	0,000220	0,014845	0,9739	46,77	0,015029	0,011944	-0,001156	16,12	3,09	2,27	15,53	cpi
50	0,000271	0,016471	0,9678	48,79	0,016671	0,013481	-0,006295	16,12	-3,17	6,30	6,48	cpi
51	0,000262	0,016173	0,9690	47,98	0,016391	0,013272	-0,006233	16,12	-3,64	1,47	7,74	cpi
52	0,000221	0,014870	0,9738	47,18	0,015073	0,011901	0,000894	16,12	1,48	-0,39	19,02	cpi
53	0,000271	0,016460	0,9679	47,98	0,016587	0,012893	0,006200	16,12	14,96	5,03	26,82	cpi
54	0,000234	0,015289	0,9723	45,16	0,015482	0,012420	-0,004045	16,12	-4,01	-2,36	4,26	cpi
55	0,000294	0,017139	0,9652	46,77	0,017448	0,014257	-0,007405	16,12	-2,74	0,73	5,20	cpi
56	0,000221	0,014876	0,9737	47,98	0,014977	0,011934	-0,001722	16,12	0,23	1,93	16,02	cpi
57	0,000227	0,015057	0,9731	48,79	0,015290	0,012232	-0,003135	16,12	3,67	1,35	10,34	cpi
58	0,000217	0,014715	0,9743	47,98	0,014820	0,011644	0,002516	16,12	5,59	2,97	17,72	cpi
59	0,000215	0,014649	0,9745	47,18	0,014768	0,011714	-0,000548	16,12	2,69	2,43	17,90	cpi
60	0,000219	0,014789	0,9741	46,37	0,015002	0,011961	-0,003030	16,12	-4,24	0,18	9,23	com
61	0,000216	0,014709	0,9743	48,79	0,014701	0,011575	0,002825	16,12	7,79	5,74	20,51	com
62	0,000208	0,014437	0,9753	48,39	0,014532	0,011518	-0,001006	16,12	-2,61	2,37	10,77	com
63	0,000207	0,014396	0,9754	48,79	0,014544	0,011544	-0,001136	16,12	-4,26	1,41	9,88	com
64	0,000240	0,015500	0,9715	47,58	0,015851	0,012736	-0,005193	16,12	-4,24	0,14	6,91	com
65	0,000211	0,014535	0,9749	46,37	0,014664	0,011655	-0,002094	16,12	-3,86	-1,78	5,51	com
66	0,000212	0,014569	0,9748	45,97	0,014765	0,011742	-0,001519	16,12	-5,24	-2,71	6,45	com
67	0,000213	0,014594	0,9747	47,58	0,014688	0,011702	-0,002847	16,12	-6,19	1,80	8,45	com
68	0,000224	0,014968	0,9734	46,77	0,015292	0,012199	-0,001917	16,12	1,29	0,19	0,40	com
69	0,000226	0,015040	0,9732	47,58	0,015269	0,012031	0,004694	16,12	9,67	1,07	19,87	com
70	0,000214	0,014619	0,9746	47,58	0,014822	0,011773	-0,001296	16,12	-0,06	2,34	3,84	com

ID	MSE	RMSE	R2	TA	MAPE	MAE	ME	bh	m1	m2	m3	config
71	0,000230	0,015151	0,9728	47,18	0,015400	0,012328	-0,004635	16,12	-10,27	0,96	3,76	com
72	0,000224	0,014958	0,9735	48,79	0,015192	0,012130	-0,002025	16,12	-2,31	3,05	-2,33	com
73	0,000235	0,015333	0,9721	47,18	0,015421	0,012121	0,004963	16,12	11,20	2,15	15,10	com
74	0,000210	0,014501	0,9751	47,58	0,014629	0,011621	-0,001915	16,12	-8,69	0,44	7,89	com
75	0,000221	0,014867	0,9738	47,58	0,014764	0,011683	0,000253	16,12	7,41	2,20	14,60	fx
76	0,000231	0,015197	0,9726	49,19	0,015338	0,012304	-0,004220	16,12	-6,63	6,33	2,60	fx
77	0,000228	0,015087	0,9730	49,19	0,015103	0,011933	0,001020	16,12	8,30	3,41	10,57	fx
78	0,000238	0,015431	0,9718	48,39	0,015483	0,012397	-0,003425	16,12	-2,98	2,89	15,24	fx
79	0,000223	0,014939	0,9735	46,37	0,014906	0,011722	0,003111	16,12	15,36	0,56	24,28	fx
80	0,000218	0,014773	0,9741	48,79	0,014895	0,011873	-0,002222	16,12	-5,25	6,06	4,88	fx
81	0,000219	0,014812	0,9740	49,60	0,014803	0,011716	0,000715	16,12	13,34	6,19	19,31	fx
82	0,000252	0,015871	0,9701	46,77	0,016085	0,012679	0,006603	16,12	10,06	0,61	15,65	fx
83	0,000221	0,014880	0,9737	47,98	0,014972	0,011913	-0,001152	16,12	6,48	2,54	14,02	fx
84	0,000225	0,015010	0,9733	49,60	0,015096	0,012042	-0,001815	16,12	0,63	5,10	10,46	fx
85	0,000221	0,014861	0,9738	47,98	0,014847	0,011777	-0,000438	16,12	6,87	2,75	10,60	fx
86	0,000230	0,015153	0,9728	48,79	0,015283	0,012190	-0,001712	16,12	-0,23	3,34	6,10	fx
87	0,000227	0,015062	0,9731	50,00	0,015282	0,012062	0,001992	16,12	13,14	8,56	24,92	fx
88	0,000221	0,014856	0,9738	47,58	0,014874	0,011711	0,002076	16,12	11,30	-0,96	20,05	fx
89	0,000220	0,014846	0,9739	47,98	0,014802	0,011680	0,001200	16,12	7,66	1,29	8,88	fx

Tabelle B.4.: Leistungsparameter aller trainierten Modelle

C. Dateianhang

```
Alexander Schmidt_Dateianhang.zip
├── Data preperation
│   ├── Data Preparation.ipynb
│   ├── dataframe.xlsx
│   ├── CPURNSA_Consumer Price Index for All Urban Consumers_
│   │   US Bureau of Labor Statistics.xlsx
│   ├── BBDXY Index_USD Price Index_Bloomberg.xlsx
│   ├── SPXT_Bloomberg.xlsx
│   ├── BCOM_Commodity Index_Bloomberg.xlsx
│   ├── USGG30YR.xlsx
│   ├── Figures
│   │   ├── snp500total_s.pdf
│   │   ├── allfeatures.pdf
│   │   ├── autocorrelation.pdf
│   │   ├── snp500total.pdf
│   │   └── ir_comparison.pdf
│   └── PDF Exports
│       ├── Data Preparation_web export.pdf
│       └── Data Preparation_Latex export.pdf
├── Optimization Process
│   ├── dataframe.xlsx
│   ├── Optimization study.ipynb
│   ├── Trials
│   │   └── [...]
│   └── PDF Exports
│       ├── Optimization study_web export.pdf
│       └── Optimization study_latex export.pdf
└── Feature Models
    ├── Results.ipynb
    ├── 00_PDF Exports
    │   ├── Results_latex export.pdf
    │   └── Results_web export.pdf
    └── 00_Figures
        └── perfcorr.pdf
```

```
│
│   ├── ts_overall.pdf
│   ├── ts_box_perconfig_strat.pdf
│   ├── mse_per_config_box.pdf
│   ├── ts_pred_skewness.pdf
│   ├── ts_pred_skewness_corr.pdf
│   ├── ts_perfm_corr.pdf
│   └── mse_per_config.pdf
├── All Features
│   ├── Feature Model_all features.ipynb
│   ├── dataframe.xlsx
│   ├── Model Backup
│   │   ├── directory.xlsx
│   │   └── [...]
│   └── PDF Exports
│       ├── Feature Model_all features_latex export.pdf
│       └── Feature Model_all features_web export.pdf
├── No Features
│   ├── Feature Model_no features.ipynb
│   ├── dataframe.xlsx
│   ├── Model Backup
│   │   ├── directory.xlsx
│   │   └── [...]
│   └── PDF Exports
│       ├── Feature Model_no features_web export.pdf
│       └── Feature Model_no features_latex export.pdf
├── Commodity Prices
│   ├── dataframe.xlsx
│   ├── Feature Model_Commodity Prices.ipynb
│   ├── Model Backup
│   │   ├── directory.xlsx
│   │   └── [...]
│   └── PDF Exports
│       ├── Feature Model_Commodity Prices_web export.pdf
│       └── Feature Model_Commodity Prices_latex export.pdf
└── Exchange Rates
    ├── dataframe.xlsx
    ├── Feature Model_Exchange Rates .ipynb
    ├── Model Backup
    │   ├── directory.xlsx
    │   └── [...]
    └── PDF Exports
        ├── Feature Model_Exchange Rates_latex export.pdf
        └── Feature Model_Exchange Rates_web export.pdf
```

```
├── Interest Rate
│   ├── dataframe.xlsx
│   ├── Feature Model_Interest Rate.ipynb
│   ├── Figures
│   │   ├── ir_strat_comp.pdf
│   │   └── ir_pred_gap.pdf
│   ├── Model Backup
│   │   ├── directory.xlsx
│   │   └── [...]
│   └── PDF Exports
│       ├── Feature Model_Interest Rate_latex export.pdf
│       └── Feature Model_Interest Rate_web export.pdf
└── Inflation
    ├── dataframe.xlsx
    ├── Feature Model_Inflation.ipynb
    ├── Model Backup
    │   ├── directory.xlsx
    │   └── [...]
    └── PDF Exports
        ├── Feature Model_Inflation_latex export.pdf
        └── Feature Model_Inflation_web export.pdf
```