

Einfluss subjektiver Faktoren auf das Börsengeschehen – ein experimenteller Ansatz zur Aktienkursprognose

Jürgen de Braaf, Juergen@deBraaf.de
Hans-Henning Gabriel, hanhengab@gmx.net
Jan Koserski, Koserski@gmx.de
Hendrik Stange, hstange@juttastange.de
Otto-von-Guericke-Universität Magdeburg

Zusammenfassung

Diese Arbeit befasst sich mit der Aktienkursprognose durch Techniken des maschinellen Lernens. Im Unterschied zu anderen Untersuchungen ist hier besonders die Frage von Interesse, ob Unternehmensnachrichten, Analystenratings und ähnliche subjektiv empfundene Merkmale Informationen über die Kursentwicklung enthalten, die für die Aktienkursprognose von Nutzen sein können.

Als maschinelles Lernverfahren werden Entscheidungsbäume zur Ein-Tages-Kursprognose für die Aktien des DAX30 modelliert und evaluiert. Zusätzlich zu den üblichen statistischen Attributen fließen psychologisch relevante Größen wie zum Beispiel Unternehmensnachrichten und Analystenratings in die Prognosen ein.

Durch die Transparenz der von uns verwendeten Entscheidungsbaumverfahren können wir deutliche Hinweise auf die große Bedeutung dieser psychologischen Faktoren auf die Kursentwicklung feststellen und somit die Bedeutung dieser Attribute für Technologien des maschinellen Lernens dokumentieren.

1 Einleitung

Die dynamische Börsenentwicklung der vergangenen Jahre hat das Dilemma offenbart, dem Aktienkäufer gegenüberstehen. Auf Basis welcher Informationen und Erfahrungen sollen sie ihre Investitionsentscheidungen am Aktienmarkt treffen? In diesem Zusammenhang ist zu analysieren, ob die Entwicklung von Aktienkursen zufällig ist oder explizierbaren Regeln folgt. Wer schon einmal an der Börse einen Teil seines Vermögens in Aktien investiert hat, kennt die Schwierigkeit, die Kursentwicklung einer Aktie richtig einzuschätzen und so Gewinne zu erzielen. Den Aktienkäufer interessieren Möglichkeiten, wie er seine Anlageentscheidungen mit Hilfe von Software optimieren kann. Dieser Thematik wird seit einigen Jahren mit Hilfe von Verfahren des maschinellen Lernens verstärkt nachgegangen. Hierbei kommen zum Beispiel neuronale Netze oder Entscheidungsbäume zum Einsatz [2,3].

Ziel dieser Arbeit ist die Erstellung von kurzfristigen Aktienkursprognosen mit Hilfe von Entscheidungsbaumverfahren. Prognosegegenstand ist die 1-Tages Kursentwicklung jeder der im DAX30 gelisteten Aktien. Vorhergesagt wird hierbei keine konkrete prozentuale Kursänderung, sondern eine von drei möglichen

Tendenzen. Die Tendenzen sind steigend, fallend oder in einem bestimmten Bereich gleich bleibend. Dabei definiert eine Schranke, ab wann eine Aktie als gestiegen, neutral bzw. gefallen gilt. Diese Einteilung genügt insofern den Bedürfnissen der Anleger, als dass sie eine Steuerung der Investitionsentscheidung ermöglicht. Im Unterschied zu zahlreichen bereits verfolgten Ansätzen auf diesem Gebiet [3] werden im Folgenden jedoch neben statistischen auch psychologische Einflussfaktoren mit in das Lernverfahren einbezogen. Insbesondere das in tagesaktuellen Nachrichten sowie Analystenratings enthaltene implizite Wissen dient als Entscheidungsgrundlage vieler Aktienkäufer und hat somit einen Einfluss auf den Kurs einer Aktie. Die Verfahren zur Informationsextraktion und zur Einflussbewertung sind speziell für dieses Projekt entwickelt worden.

Im Rahmen dieser Arbeit soll überprüft werden, welchen Einfluss die Hinzunahme psychologischer Faktoren auf das Lernverfahren und somit auf die Prognosequalität ausübt. Weiterhin soll untersucht werden, wie die Wahl einer oberen bzw. unteren Schranke die Prognoseergebnisse beeinflusst. Fernerhin wird der Ansatz untersucht, die Daten der erstellten Aktienkursprognosen als Input in das Lernverfahren erneut einfließen zu lassen, um darauf aufbauend Meta-Prognosen zu erzeugen. Der Vergleich „einfacher“ Prognosen mit Meta-Prognosen soll Aufschluss darüber geben, ob sich durch nochmaliges Anwenden des Lernverfahrens auf einem höheren Abstraktionsniveau Ergebnisverbesserungen realisieren lassen.

Die Arbeit gliedert sich wie folgt: Zunächst erfolgt in Abschnitt 2 ein kurzer Überblick über die Grundlagen von Entscheidungsbaumverfahren. In Abschnitt 3 wird beschrieben, welche Einflussfaktoren verwendet werden und wie die Prognosen erstellt werden. Um eine Aussage über die Leistung der Prognosen zu erhalten, wurden umfangreiche Experimente durchgeführt, die wir in Abschnitt 4 beschreiben. Auf die besondere Bedeutung der psychologischen Einflussfaktoren wird in Abschnitt 5 eingegangen. Schlussfolgerungen und ein Ausblick finden sich in Abschnitt 6 und 7.

2 Grundlagen Entscheidungsbaumverfahren

Das Generieren von Entscheidungsbäumen ist im Bereich des Maschinellen Lernens ein seit längerer Zeit verwendetes und erprobtes Klassifikationsverfahren [1]. Dabei geht es darum, aus einer gegebenen Menge von Beispielen eine Hypothese in Form eines Entscheidungsbaumes zu generieren, die die bekannten Beispiele

le sowie noch unbekannte Beispiele aus derselben Domäne so fehlerfrei wie möglich klassifiziert. Beispiele sind durch Attribute und deren Werte beschrieben, wobei das Zielattribut das zu klassifizierende Merkmal darstellt. Die Knoten im Entscheidungsbaum repräsentieren einen Test eines Attributes, und die dazugehörigen Kanten im Baum entsprechen den möglichen Werten des Attributes.

Zur Erzeugung eines Entscheidungsbaumes werden Algorithmen wie zum Beispiel ID3, C4.5 oder CART [4] verwendet. Als Ausgangspunkt liegt eine Datenmenge, die sogenannte Trainingsmenge vor. Diese besteht aus bereits klassifizierten Instanzen, bei denen der jeweilige Wert des Zielattributes bekannt ist. Die Algorithmen ermitteln mit Hilfe bestimmter Maße, zum Beispiel Informationsgewinn, welche der Attribute die Daten bezüglich des Zielattributes am besten beschreiben. Attribute mit einem hohen Informationsgewinn stehen in den oberen Ebenen des Entscheidungsbaumes. Das Attribut mit dem höchsten Informationsgewinn minimiert die benötigte Information, um die Daten in den resultierenden Untermengen zu beschreiben. Die Aufteilung erfolgt an den Knoten entsprechend der zu den Folgeknoten führenden Kanten. Dieser Vorgang wird wiederholt durchlaufen, bis die Instanzen eindeutig beschrieben werden oder die Trainingsdaten nicht weiter aufgeteilt werden können.

Instanzen werden mittels eines Entscheidungsbaumes klassifiziert, indem man den Baum beginnend an der Wurzel über Knoten und Kanten gemäß den gegebenen Attributen und ihren Werten bis zu einem Blattknoten durchlaufen, aus dem sich dann der Wert des Zielattributes ablesen lässt.

Der in dieser Arbeit verwendete C4.5-Algorithmus stammt aus dem Java-Package weka [5]. Dies ist eine Sammlung verschiedener Algorithmen zum Bereich Maschinelles Lernen. Die Implementierung dieser Algorithmen wurde durch die Universität Waikato, Neuseeland vorgenommen.

3 Prognosen der Kursentwicklung

3.1 Faktoren mit psychologischer Wirkung und statistische Einflussfaktoren

Unter statistischen Größen werden hier objektiv mess- und erfassbare Größen verstanden. Folgende statistische Größen werden für das Lernverfahren verwendet:

- die prozentuale Kursveränderung einer Aktie zum letzten Handelstag (Attribut „Tag1“),
- die prozentuale Kursveränderung einer Aktie zum vorletzten Handelstag (Attribut „Tag2“),
- die prozentualen Veränderungen der Indizes DAX30 (Attribut „DAX“), DOW (Attribut „DOW“) und TecDax (Attribut „TecDax“) zum letzten Handelstag,
- die gehandelte Stückzahl einer Aktie multipliziert mit dem Kurs der Aktie (Attribut „Volumen“),
- die Volatilität einer Aktie (Attribut „Volatilität“)
- und die Kursveränderung einer Aktie am folgenden Handelstag (Zielattribut „Entwicklung“).

Da alle diese Größen als Zahlenwerte vorliegen, können diese direkt in das Lernverfahren einfließen.

Die Einbeziehung psychologischer Größen in ein maschinelles Lernverfahren gestaltet sich häufig schwieriger, da diese naturgemäß subjektiv von den Marktteilnehmern empfunden werden und kaum einheitlich zu messen sind. Die in dieser Arbeit berücksichtigten psychologischen Größen sind:

- die durchschnittliche Analystenbewertung zu einer Aktie (Attribut „Rating“),
- die durchschnittliche Tagestemperatur in Deutschland (Attribut „Wetter“),
- der durchschnittliche Luftdruck in Deutschland (Attribut „Luftdruck“),
- die Bewertung einer Aktie als Top oder Flop, d.h. ob sie zu den besten oder schlechtesten fünf des vorigen Handelstages zählte (Attribut „Top-Flop“),
- die Lage eines Handelstages zwischen freien Tagen oder Feiertagen (Attribut „Grenztag“),
- die aktuelle Mondphase (Attribut „Mondphase“),
- und die News zu einer Aktie (Attribut „News“).

Obwohl einige psychologische Attribute bereits numerisch messbar sind, so steht hier deren psychologischer Einfluss im Vordergrund. Auch werden hier recht exotische Einflussfaktoren wie die Mondphase oder der Luftdruck verwendet, um zu prüfen, ob solche Größen einen Einfluss auf den Kursverlauf einer Aktie haben könnten. Um derartige psychologische Größen für ein Entscheidungsbaumverfahren nutzen zu können, ist häufig eine Transformierung in Zahlenwerte erforderlich. Diese Transformierung soll hier exemplarisch für die Größe News beschrieben werden, da hierfür im Rahmen dieses Projektes ein neues Verfahren entworfen wurde. Der grundlegende Ansatz besteht darin, mit Hilfe von Wortlisten den semantischen Inhalt der News messbar zu machen. Dabei wird wie folgt vorgegangen: Die News werden aus mehreren Quellen im Internet automatisch extrahiert. Dies gestaltet sich recht einfach, da die News auf den einschlägigen Seiten in verlinkter, meist in Stichpunkt-ähnlicher Form, vorliegen. Als Grundlage für die Bewertung der News dienen zwei Wortlisten, welche im Rahmen dieses Projektes erstellt wurden. Die eine enthält die gebräuchlichsten Abkürzungen und Bezeichnungen aller Aktien. Zum Beispiel wird die Deutschen Telekom auch mit „T-Aktie“ oder „Dt. Telekom“ bezeichnet. Mit Hilfe dieser Wortliste werden die News den Aktien bzw. den Wertpapierkennnummern zugeordnet. Die andere Wortliste enthält ca. 200 typische Schlagworte, wie zum Beispiel „Krise“, „Skandal“, „Plus“, „Zuwachs“ oder „übertroufen“. Jedes in dieser Liste enthaltene Wort ist mit einer Bewertung entsprechend seiner positiven oder negativen Wirkung versehen. Die Bewertungen sind -2 für „sehr schlecht“, -1 für „schlecht“, +1 für „gut“ und +2 für „sehr gut“. Diese Bewertungen werden für alle News zu einer Aktie ermittelt und zusammenaddiert. Diese Summe wird bei überschreiten einer oberen Schranke bzw. unterschreiten einer unteren Schranke bzw. einer Lage zwischen den Schranken zu „gut“ oder „schlecht“ oder „neutral“ umgewandelt. So ergibt sich eine kategorische Bewertung der Größe News, die von dem Entscheidungsbaumverfahren interpretiert werden kann.

3.2 Von der Datensammlung zur Prognose

Prognostiziert wird die Kursentwicklung jeder der im DAX30 gelisteten Aktien am folgenden Handelstag. Es wird dabei nicht die prozentuale Kursveränderung vorhergesagt, sondern lediglich, ob eine Aktie steigen, fallen oder in einem Bereich gleich bleiben wird.

Die Prognosen werden nach Handelschluss (20:00 Uhr) eines jeden Handelstages in fünf Schritten erstellt:

I) Zunächst werden die für das Lernverfahren benötigten Daten von verschiedenen Internetseiten automatisch bezogen. Das sind für die statistischen Größen die Kurse der Indizes, die Schlusskurse, die Volumina sowie die Volatilitäten aller im DAX30 vertretenen Aktien. Für die psychologischen Größen werden die News, die Temperatur, der Luftdruck, die Ratings und der Leitzins ausgelesen.

II) Die eingelesenen Daten werden anschließend aufbereitet:

Aus den Schlusskursen werden die prozentualen Veränderungen zum letzten und vorletzten Handelstag berechnet. Ebenso wird aus den Indizes DAX30, TecDax und DOW die prozentuale Veränderung zum letzten Handelstag ermittelt. Zur Normalisierung des Volumens einer Aktie wird die gehandelte Stückzahl mit dem Schlusskurs der Aktie multipliziert. Die prozentuale Veränderung der Tagestemperatur und des Luftdruckes zum letzten Handelstag wird berechnet. Aus den Schlusskursen wird ermittelt, welche Aktien unter den fünf Tops bzw. Flops sind. Der Leitzins wird entsprechend seiner Höhe und des Zeitpunktes seiner letzten Änderung gewichtet. Die Auswertung der News erfolgt wie beschrieben mit Hilfe zweier Wortlisten, anhand derer die News den Aktien zugeordnet und entsprechend ihrer positiven oder negativen Wirkung bewertet werden.

III) Es werden unter Einbeziehung aller bis zum letzten Handelstag gesammelten Daten für jede Aktie des DAX30 mehrere Entscheidungsbäume generiert. Durch die Variation der Schranken von $n=0,5, \dots, 2,5$ in 0,5er-Schritten ergeben sich für jede Aktie fünf verschiedene Entscheidungsbäume.

Dabei wird eine Aktie als „gestiegen“ bzw. „gefallen“ bewertet, wenn die prozentuale Kursveränderung eine obere Schranke überschritten, bzw. eine untere Schranke unterschritten hat. Liegt die Kursänderung zwischen den Schranken, so gilt die Veränderung der Aktie als „neutral“. Bei einer Schranke von n gilt eine Aktie als „gestiegen“, wenn sie stärker als $n\%$ gestiegen ist, und als „gefallen“, wenn die Aktie stärker als $n\%$ gefallen ist.

Zusätzlich wird die Anzahl der einfließenden Größen variiert. Es werden dabei zwei Attributmengen unterschieden:

- nur die statistischen Einflussfaktoren werden verwendet,
- alle Einflussfaktoren (statistische und psychologische) werden verwendet.

Aus der Verwendung von fünf verschiedenen Schranken in Kombination mit den oben genannten Attributmengen

zur Generierung der Entscheidungsbäume ergeben sich für jede Aktie insgesamt zehn verschiedene Entscheidungsbäume.

IV) Die Daten des aktuellen Tages werden dann mittels der gelernten Entscheidungsbäume klassifiziert, um so die Prognosen für den nächsten Tag zu erhalten. Da zu jeder Aktie des DAX30 zehn Entscheidungsbäume existieren, ergeben sich auch zu jeder Aktie zehn Prognosen. Dabei wird entsprechend der Entscheidungsbäume in zwei Prognosetypen unterschieden:

- fünf Prognosen auf Grundlage statistischer Einflussfaktoren, folgend „Basisprognose S“ (BS)
- fünf Prognosen auf Grundlage statistischer und psychologischer Einflussfaktoren, folgend „Basisprognose A“ (BA)

Durch diese Unterscheidung der Prognosetypen ist es später möglich, in einer Auswertung zu prüfen, ob die psychologischen Größen einen Einfluss haben, das heißt, ob der Prognosetyp BA andere Ergebnisse erzielt, als der Prognosetyp BS.

V) In einem letzten Schritt wird das Lernverfahren noch einmal angewendet. Die Entscheidungsbäume werden nicht mit allen bis zum letzten Handelstag gesammelten Daten trainiert, sondern mit allen bis zum letzten Handelstag erstellten Prognosen. Die Attribute für den Entscheidungsbaumalgorithmus sind also die zehn verschiedenen Prognosen, welche einen der drei Werte „gestiegen“, „gefallen“ und „neutral“ annehmen können. Das Zielattribut ist nach wie vor die Kursveränderung einer Aktie am folgenden Handelstag. Auch hier wird wieder zwischen sechs Schranken variiert, welche aussagen, ab wann eine Aktie als „gestiegen“ bzw. als „gefallen“ gilt. Die Schranken liegen im Intervall von 0 bis 2,5 in 0,5er-Schritten. Bei dieser Art der Prognoseerstellung hat sich gezeigt, dass bei den hohen Schranken sehr viele Aktien als „neutral“ klassifiziert wurden, aus diesem Grund wurde noch die niedrige Schranke 0 hinzugenommen. So entstehen für jede Aktie noch einmal sechs Entscheidungsbäume. Die Daten des aktuellen Tages werden wiederum mit diesen Entscheidungsbäumen klassifiziert. Daraus ergeben sich für jede Aktie sechs weitere Prognosen. Da diese Prognosen auf der Grundlage der Basisprognosen BS und BA entstanden sind, werden sie folgend „Metaprognose“ (MP) genannt. Insgesamt entstehen so an jedem Handelstag für jede Aktie 16 verschiedene Prognosen: fünf Prognosen vom Typ BS, fünf Prognosen vom Typ BA und sechs Prognosen vom Typ MP.

4 Experimente

Um die Qualität der beschriebenen Prognosen zu untersuchen, wurden im Zeitraum 26.06.2002-28.08.2002 sowie 11.11.2002-16.04.2003 an insgesamt 148 Handelstagen die Daten wie beschrieben gesammelt und die 1-Tages-Prognosen für jede der 30 Aktien durch die verschiedenen Entscheidungsbäume erstellt. Die Trainingsmengen der Bäume wurden dabei täglich um die Informationen des vorigen Handelstages erweitert, um eine Verbesserung der Prognosen durch eine größere

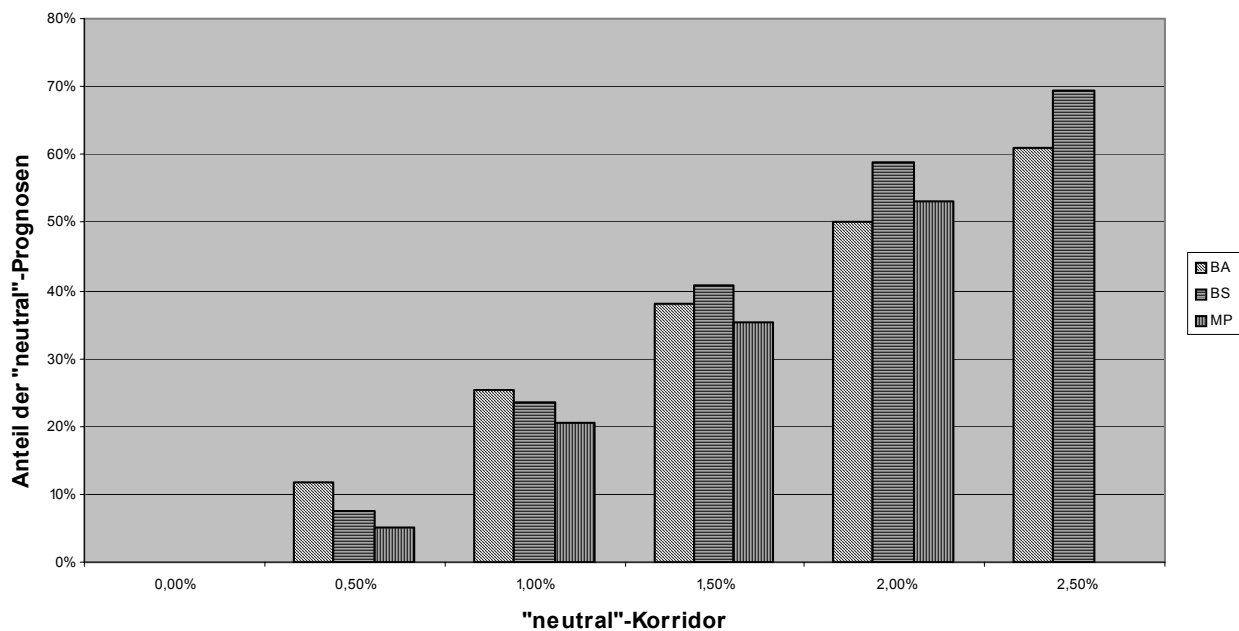


Abb. 1: Anteil der „neutral“-Prognosen je Prognosemodell

Trainingsmenge zu erzielen. Wir betrachten im Folgenden insgesamt 15 Prognosemodelle:

Für die Korridore von 0,50% bis 2,00% sowohl Basisprognosen mit allen Attributen (BA), Basisprognosen mit lediglich statistischen Attributen (BS), als auch Meta-Prognosen (MP). Für den Korridor 2,50% wurden lediglich die beiden Basisprognosen, für den Korridor 0,00% lediglich die Metaprognose erstellt. In einer vorangegangenen Untersuchung ergab sich, dass mit den übrigen Prognosen in diesen Korridoren keine brauchbaren Aussagen abgeleitet werden konnten.

4.1 Anteil der „neutral“-Prognosen bei unterschiedlichen „neutral“ Korridoren

Zunächst wurde untersucht, ob die unterschiedliche Wahl des neutral Korridors, also dem Bereich, in dem die Modelle einen Kurs als gleichbleibend interpretieren sollen, eine Auswirkung auf die Anzahl der „steigend“- bzw. „fallend“-Prognosen hatten.

In Abb. 1 ist zu erkennen, dass die mit größeren Schranken trainierten Entscheidungsbäume mehr „neutral“-Prognosen ausgeben. Dieser Umstand kann als ein vorsichtigeres Agieren am Aktienmarkt interpretiert werden, schließlich sollten diese Modelle nur dann eine „steigend“- bzw. „fallend“-Prognose geben, wenn deutliche Anzeichen für Kursanstiege bzw. -verluste identifiziert werden konnten. In den folgenden Abschnitten soll nun untersucht werden, ob sich dies in präziseren „steigend“- bzw. „fallend“-Prognosen widerspiegelt. Das MP 0,00%- Modell sprach keine einzige „neutral“-Prognose aus und entspricht damit unseren Erwartungen, da ein identischer Schlusskurs als sehr unwahrscheinlich angesehen werden kann.

4.2 Vorhersageleistung der Modelle

Darauf aufbauend war von Interesse, wie viele der „steigend“- bzw. „fallend“-Prognosen tatsächlich eintraten. Wir erwarteten eine Zunahme der korrekten Prognosen mit zunehmendem „neutral“-Korridor, da diese Modelle nur dann eine solche Prognose erzeugen, wenn deutliche Anzeichen für ein Ansteigen oder Fallen des Kurses vorliegen. Da in etwa gleich viele steigende wie fallende Kurse aufgezeichnet wurden, liegt der Erwartungswert der Entwicklung bei zufälligem Raten bei 50%. Eine diesen Wert übersteigende Trefferquote ist demnach als Leistung der Prognosemodelle zu interpretieren.

In Abb.2 ist zu erkennen, dass sich alle Anteile recht nah bei der 50% Marke bewegen, somit konnten steigende bzw. fallende Kurse unabhängig von der Art der Prognose und dem „neutral“-Korridor nur begrenzt zuverlässig identifiziert werden, einzig die BS-Prognosen konnten bei allen untersuchten Korridoren die 50%-Marke übersteigen. Als Ursachen hierfür kommen hauptsächlich zwei Dinge in Frage: Entweder enthalten die Attribute keinerlei verwertbare Informationen über die Kursentwicklung oder die von uns genutzten Prognosemodelle können diese Informationen nicht korrekt identifizieren. Da Kursprognosen mit ähnlichen Attributen in anderen Fällen bereits zu deutlich besseren Resultaten geführt haben [2], ist es sehr wahrscheinlich, dass die von uns verwendete Entscheidungsbaumverfahren nicht gut mit den Attributen zu rechkamen. Insbesondere die metrischen Attribute wie z.B. Kursveränderung des letzten Handelstages könnten von den Verfahren nur schwer interpretiert worden sein – Entscheidungsbäume sind für nominale Attribute (Z.B. „Gut“, „Schlecht“) besser geeignet als für metrische (wie z.B. „+1,5% Kursveränderung“). Dies legt den Schluss nahe, dass mit einem anderen Lernverfahren, wie z.B. neuronalen Netzen, bessere Resultate erzielt werden könnten [2].




Abb. 2: Anteil der korrekten „steigend“- bzw. „fallend“-Prognosen

Weiterhin hat die Wahl größerer Schranken nicht wie erhofft zu einer Verbesserung der Treffgenauigkeit geführt. Möglicherweise standen den Modellen durch die größeren Schranken zu wenige Beispiele zum Trainieren der „steigend“- und „fallend“-Prognosen zur Verfügung: Bei einer Schranke von 2,50% entfielen 55,9% aller Trainingsbeispiele in die Kategorie „neutral“, so dass möglicherweise nicht genug Beispiele für signifikant steigende bzw. fallende Kurse in den Trainingsdaten vorhanden waren.

Die Hinzunahme der psychologischen Attribute brachte nicht den erwünschten Erfolg: Die Prognosen, die nur die statistischen Attribute berücksichtigen (BS) schnitten durchweg besser ab, als die BA-Prognosen. Als wahrscheinlichste Ursache kommt wiederum die zu geringe Anzahl von Trainingsbeispielen bei einem vergrößerten Attributraum in Frage. Eine eventuell schlechte Qualität der Attribute oder gar eine Unabhängigkeit von eingetretener Kursentwicklung und den gewählten psychologischen Attributen (wie z.B. Mondphase) ist zwar in manchen Fällen als wahrscheinlich einzustufen – sollte jedoch tatsächlich keine Korrelation mit der eingetretenen Kursentwicklung vorliegen, so müssten diese beim Training der Entscheidungsbäume durch den niedrigen Informationsgewinn automatisch ausgeschlossen werden [1]. Sie würden dann für das Training nicht berücksichtigt werden, da die Verfahren keinen Zusammenhang zwischen Ihnen und der tatsächlich eingetretenen Kursentwicklung erkennen könnten. Die Erstellung von Metaprognosen aufbauend auf den 10 Basisprognosen BS und BA führte in der Regel zu einem Abnehmen der Prognoseleistung. Interessanterweise liegen diese Prognosen regelmäßig unterhalb der 50% Marke, d.h. sie sagten tendenziell das Gegenteil der tatsächlich eingetretenen Entwicklung voraus. Zukünftige Untersuchungen sollen die Ursachen hierfür zeigen und der Frage nachgehen, ob möglicherweise

durch eine geeignete Gewichtung der Basisprognosen eine Verbesserung der Vorhersagegenauigkeit eintritt.

4.3 Wertentwicklung von virtuellen Aktiendepots

Abschließend wurde die Wertentwicklung von virtuellen Aktiendepots untersucht, um der Frage nachzugehen, wie sich ein Geldbetrag entwickelt hätte, wenn man ihn gemäß der Prognosen unsere Modelle in einzelne Aktien investiert hätte. Der Investor kann sein Geld hierbei je nach der Prognose in steigende Kurse (Long-Position) oder fallende Kurse (Short-Position) investieren, oder sein Kapital nicht in die jeweilige Aktie investieren (Out-Position). Vertretend für die übrigen Aktien seien hier die Wertentwicklungen der verschiedenen Prognosemodelle bei der Infineon-Aktie über die 148 Handelstage dargestellt. Zur besseren Übersicht werden nur vier der fünfzehn ausgewerteten Depots dargestellt (vgl. Abb.3).

Am besten schnitt hier der Prognosetyp BS mit einem „neutral“-Korridor von 0,5% (Stat05) mit einer Performance von knapp +150% ab. Deutlich sind jedoch die großen Abweichungen der einzelnen Prognosemodelle zu erkennen (vgl. Abb.3). Nur in wenigen Fällen sind parallele Entwicklungen der Depots zu erkennen, somit sind kaum gleiche Einschätzungen der Kursentwicklung zu gleichen Zeitpunkt vorhanden.

Bei den anderen betrachteten Aktien schnitten die Prognosen jedes Mal sehr unterschiedlich ab. Eine Erklärung für die jeweils gute bzw. schlechte Performance könnte das Existieren einer Zufallskomponente sein. Eine weitere, dass sich einige Aktien besser zur Prognose eignen als andere, weil sie im untersuchten Zeitraum möglicherweise deutlich häufiger als in 50% der Fälle gestiegen, bzw. gefallen sind: Ist eine Aktie z.B. in 70% aller Fälle gestiegen und passt sich das Prognosemodell dieser Tatsache an, so werden deutlich mehr

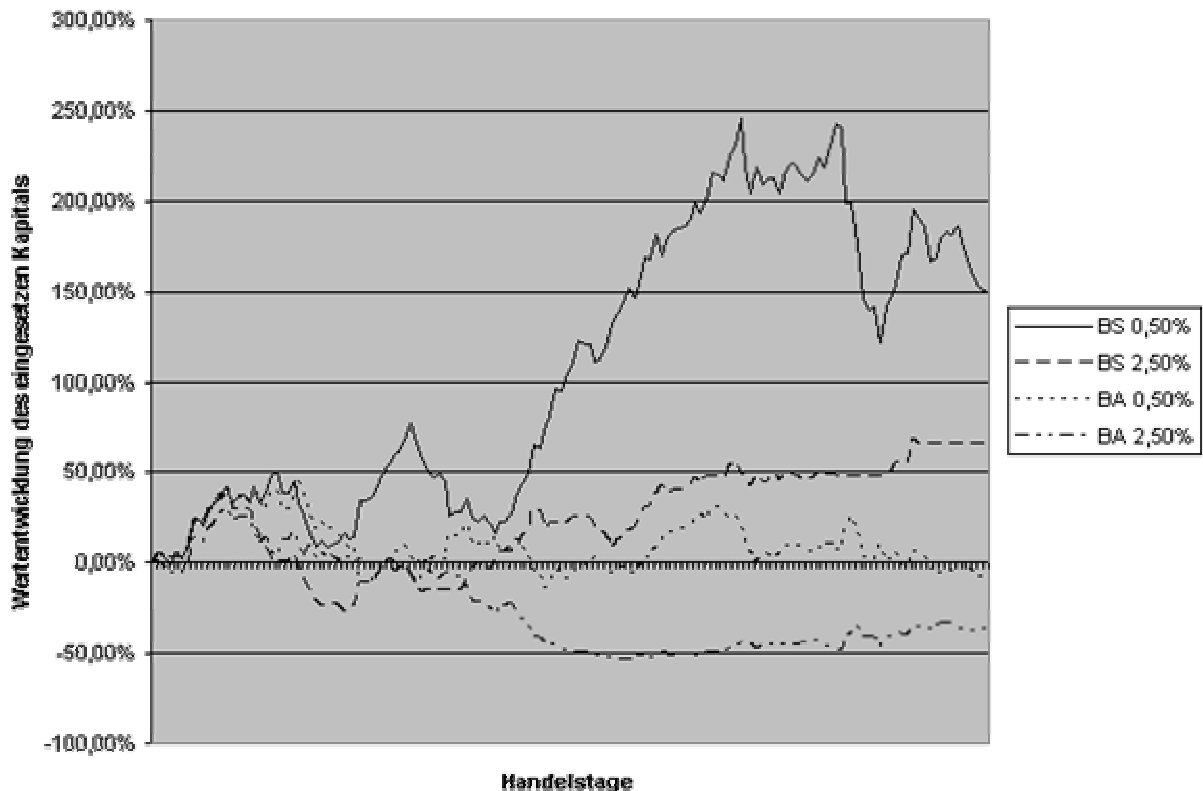


Abb. 3: Performance des virtuellen Infineon-Depots

„steigend“ als „fallend“-Prognosen erzeugt und das Modell liegt (so dieser Aufwärtstrend weiterhin Bestand hat) in mehr als der Hälfte der Fälle richtig, ohne hierfür tatsächlich einen Zusammenhang zwischen den Attributen und der tatsächlichen Entwicklung identifizieren zu müssen. Die erstellten Modelle konnten kaum treffsichere Prognosen über die Kursentwicklung der DAX30 Aktien am folgenden Tag abgeben.

5 Auswirkung psychologischer Faktoren auf Entscheidungsbaumverfahren basierte Aktienprognosen

Die Analyse war darauf ausgerichtet, den Informationsgewinn durch die Hinzunahme psychologischer Attribute zu messen. Dazu wurden die Entscheidungsbäume aller im DAX30 gelisteten Unternehmen visualisiert. Insgesamt wurden sieben verschiedene Zeiträume als Trainingsmenge betrachtet und jeweils alle Attribute oder alle statistischen Attribute und psychologische Attribute in Kombination zum Erzeugen der Bäume verwendet.

Für die Analyse betrachtete Zeiträume:

- 22.05.2002 – 22.06.2002
 - 22.05.2002 – 22.07.2002
 - 22.05.2002 – 22.08.2002
 - 22.05.2002 – 22.12.2002*
 - 01.01.2003 – 02.02.2003
 - 15.03.2003 – 15.04.2003
 - 22.05.2002 – 22.06.2003*
- *mit Unterbrechungen aufgrund fehlender Daten

Pro Aktie wiederum wurden die Entscheidungsbäume für vier verschiedene Schranken (0,5, 1, 1,5 u. 2) erstellt. Auch wenn die gesamte Trainingsmenge gering ausfällt, konnten bei der Analyse der Entscheidungsbäume bereits aussagekräftige Eigenschaften festgestellt werden, die teilweise eine direkte Beziehung zum allgemeinen Marktgeschehen aufweisen. Folgendes konnte beobachtet werden:

- Bei der Berücksichtigung aller Attribute, tauchen die drei psychologischen Attribute News, Rating und TopFlop am häufigsten als Wurzelknoten oder in den obersten Ebenen im Entscheidungsbaum auf. Sie besitzen somit den höchsten Informationsgewinn.
- Wählt man nur alle statistischen Attribute und das News Attribut aus, so erscheint in 8 von 10 Fällen das News Attribut als Wurzelknoten. Eine Ausnahme z.B. bildet die Thyssen Krupp Aktie, bei der das News Attribut nicht über die zweite Ebene hinauskommt und statistische Attribute an der Wurzel stehen.
- Statistische Attribute besitzen einen hohen Informationsgewinn, wenn eine kleine Schranke (0,5) gewählt wird, während psychologische Attribute vor allem bei großen Schranken einen hohen Informationsgewinn vorweisen. Diese Beobachtung kann mit der Annahme in Verbindung gebracht werden, dass bei einer positiven bzw. negativen Nachrichtenwelle der Kurs kurzfristig besonders stark beeinflusst wird. Fehlen ereignisreiche Nachrichten, dann bewegt sich der

Kurs einer einzelnen Aktie in der Regel im Trend des DAX Index.

- Das Attribut „Zinsentwicklung“ ist bei der Aktie von der Deutschen Bank in der zweiten Ebene platziert und bei der Deutschen Börse AG steht es sogar an der Wurzel des Entscheidungsbaumes. Dies ist insofern erstaunlich, da gerade der Kursverlauf der Deutschen Börse AG stark von der Zinsentwicklung abhängt. Denn die Zinsentwicklung hat einen direkten Einfluss auf das Handelsvolumen aller Aktien. Fällt z.B. der Leitzinssatz um einige Prozentpunkte, so wird der Aktienmarkt für die Anleger lukrativer im Vergleich zu risikolosen Anlagen. Dies wiederum führt zu einer höheren Nachfrage von risikobehafteten Anlagen und davon profitiert die Deutsche Börse AG im Besonderen. Bei den verbleibenden DAX30 Unternehmen taucht das Attribut nicht auf oder besitzt nur einen sehr geringen Informationsgewinn.
- Das Attribut „Wetter“ ist Wurzelknoten der Münchener Rück und der Deutschen Post, während es sonst von geringer Bedeutung ist.

6 Schlussfolgerung

Diese Arbeit befasste sich mit der Aktienkursprognose durch Techniken des maschinellen Lernens. Von besonderem Interesse war dabei die Frage, ob subjektiv empfundene Faktoren wie Unternehmensnachrichten oder Analystenratings einen Einfluss auf die Kursentwicklung einer Aktie haben. Zur Ein-Tages-Kursprognose der Aktien des DAX30 wurden Entscheidungsbäume modelliert und evaluiert.

Die Modelle konnten nur begrenzt zuverlässige Prognosen zur Kursentwicklung abgeben. Vermutlich sind die verwendeten Entscheidungsbaumverfahren insbesondere auf Grund der verwendeten metrischen Attribute nicht ideal für diese Aufgabe geeignet, da mit ähnlichen Eingabedaten trainierte neuronale Netze deutlich bessere Resultate erzielen konnten [2]. Der deutliche Vorteil der von uns verwendeten Verfahren besteht in der Transparenz der Entscheidungsfindung innerhalb der Bäume, die es uns gestattet, die Priorität einzelner Attribute zu untersuchen und zu bewerten. Als einen Hinweis auf die hohe Relevanz der psychologischen Attribute bei der Prognoseerstellung ist die hohe Häufigkeit, mit der insbesondere das News-Attribut in den obersten Ebenen der Entscheidungsbäume auftritt, festzuhalten. Durch eine Analyse der Entscheidungsbäume konnten wir die hohe Priorität von psychologischen Attributen (insb. den Einfluss von Unternehmensnachrichten auf die kurzfristige Kursentwicklung) erfolgreich dokumentieren. Obwohl die Hinzunahme dieser Attribute in die Lernverfahren zu einer Verschlechterung der Performance geführt hat, vermuten wir, dass die Ursachen hier ebenfalls bei den Schwächen der Entscheidungsbäume sowie bei der geringen Zahl an Trainingsbeispielen liegen.

Folglich sind psychologische Attribute für Kursprognosen als wertvoll einzustufen und können bereits bestehende Verfahren sinnvoll ergänzen, um die Prognosegüte zu optimieren.

7 Ausblick

Nachfolgende Arbeiten sollten vor allem die Prognosequalität bei gleichem Datensatz und somit identischen Attributen mit anderen maschinellen Lernverfahren evaluieren, um eine bessere Einschätzung der Eignung von psychologischen Attributen bei diesen Modellen zu erhalten. Weiterhin könnte eine Form der Gewichtung von Attributen implementiert werden, die dem Investor erlaubt, eigene Erfahrungen in den Lernprozess einzubringen. Die Hinzunahme weiterer geeigneter Attribute könnte ebenfalls eine Verbesserung der Prognosequalität bewirken. Außerdem sollten die Schranken noch genauer angepasst werden bzw. sollten durch zukünftige Modelle optimiert werden.

Danksagung

Wir bedanken uns für die freundliche Unterstützung bei Susanne Hoche vom Fraunhofer-Institut für Autonome intelligente Systeme AIS.KD.

Literaturverzeichnis

- [1] Mitchel. Machine Learning. McGraw-Hill 1997.
- [2] Neuneiner. Optimale Investitionsentscheidungen mit Neuronalen Netzen. 1998.
- [3] Rehkugler. Zimmermann. Neuronale Netze in der Ökonomie. Grundlagen und finanzwirtschaftliche Anwendungen München 1994.
- [4] Spiliopoulou. Schult. Krogel. Intensive Course on Data Mining. 2003.
- [5] Witten. Frank. Data Mining: Practical Machine Learning Tools and Techniques with Java Implementations. 1999.