Aktienrendite-Schätzungen mit Hilfe künstlicher neuronaler Netze

1. Einleitung

Der erfolgreiche Test künstlicher neuronaler Netze (KNN) in verschiedenen Bereichen der Betriebswirtschaftslehre [1] legt es nahe, zu untersuchen, inwieweit diese Techniken im Bereich der Kapitalmarktforschung nutzbringend angewendet werden können. In diesem Aufsatz sollen nun erste vorläufige Resultate über den Einsatz von KNN zur Schätzung der Aktienrendite und zur Modellierung relevanter Einflussgrössen auf die Aktienrendite als Alternative zum Marktmodell von SHARPE (1963) präsentiert werden.

Der Artikel ist folgendermassen aufgebaut: Abschnitt 2 behandelt kurz die Grundlagen des Marktmodelles. Die verwendeten KNN und Regressionsverfahren werden in Abschnitt 3 eingeführt. Die Darstellung und Analyse der Schätz-Ergebnisse erfolgt in den Abschnitten 4 und 5. Eine zusammenfassende Beurteilung der Ergebnisse wird schliesslich in Abschnitt 6 vorgenommen.

2. Grundlagen des Marktmodells

Das Marktmodell von Sharpe [2] unterstellt eine lineare Beziehung zwischen der unsicheren Rendite eines Wertpapiers R_i und der Rendite des Marktportefeuilles R_M:

$$\tilde{R}_i = a_i + b_i \cdot \tilde{R}_M + \tilde{u}_i$$

Statistisch gesehen kann a_i als absolutes Glied, b_i als Regressionskoeffizient der Marktrendite und u_i als Störvariable gesehen werden; ökonomisch betrachtet lässt sich a_i als konstante marktunabhängige Rendite, u_i als unternehmensspezifische Rendite und $b_i * R_M$ als von der Marktentwicklung abhängiger Renditebestandteil der Aktienrendite erklären. Der Faktor b_i kann in den Betafaktor des CAPM im Gleichgewicht überführt werden [3]:

$$b_i = \beta_i = \frac{Cov(\tilde{R}_i;\tilde{R}_M)}{Var(\tilde{R}_M)}$$

Um Aussagen über den zukünftigen Betafaktor einer Aktie zu treffen, kann man im Rahmen einer Ex-post-Analyse einen historischen $\hat{b}_i$-Faktor berechnen und diesen als naiven Schätzwert für den zu erwartenden Betafaktor verwenden [4]:

$$\hat{b}_i = \frac{n \sum_{t=1}^{n} R_{it} R_{Mt} - \sum_{t=1}^{n} R_{it} \sum_{t=1}^{n} R_{Mt}}{n \sum_{t=1}^{n} R_{Mt}^2 - \left(\sum_{t=1}^{n} R_{Mt} \right)^2}$$

Als Substitut für das Marktportefeuille wird in dieser Untersuchung der Deutsche Aktienindex (DAX) genutzt. Die Rendite eines Wertpapiers wird hier wie folgt berechnet:

$$R_{it} = \ln\left(\frac{K_{it} + D_{it}}{K_{it-1}}\right)$$

mit
R_{it} = Rendite der Aktie i für den Zeitpunkt t
K_{it} = Kurs der Aktie i zum Zeitpunkt t
D_{it} = Dividendenabschlag für Aktie i zum Zeitpunkt t

3. Vorbereitung und Aufbau der Untersuchung

3.1 Verwendete Verfahren und Modelle

Das CAPM beschreibt als erklärendes Modell, welche Aktienrenditen Anleger zu bestimmten Zeitpunkten erwarten können. Die übliche Vorgehensweise zur Schätzung der erwarteten Rendite ist die Anwendung von Regressionsanalysen, um so die Parameter des Marktmodells anhand der vorangegangenen Zeitperiode zu berechnen und diese zur Schätzung für zukünftige Perioden zu verwenden. In dieser Untersuchung wird ein alternatives Verfahren, KNN, zur Schätzung der Renditen eingesetzt. Es wird versucht, mit Hilfe von KNN denjenigen Zusammenhang am Kapitalmarkt zu ermitteln, der die tatsächlich beobachteten Renditen am besten erklärt.
Die Anwendung statistischer Verfahren ist eng gekoppelt mit der Existenz von ökonomischen Modellen, welche die Wechselwirkungen in den beobachtbaren ökonomischen Daten beschreiben. KNN hingegen können auch ohne die Existenz eines detaillierten ökonomischen Modells eingesetzt werden, da sie anhand von repräsentativen Beispieldaten selbst ein internes Modell über die Zusammenhänge innerhalb des Datenmaterials aufbauen. Daher soll im folgenden untersucht werden, ob KNN geeignet sind, erwartete Aktienrenditen zu schätzen und inwieweit durch den Einsatz von KNN Rückschlüsse auf die Validität des Marktmodells möglich werden.

Tabelle 1: Daten

DAX-Werte	Nicht-DAX-Werte
Siemens (723600)*	Didier (553700)
BASF (515100)	PWA (688980)
Kaufhof (781900)	KHD (630500)

*In den Klammern sind die Wertpapierkennummern der untersuchten Stammaktien angegeben.

Als Beispieldaten liegen dieser Untersuchung Zeitreihen von drei im DAX enthaltenen und drei nicht enthaltenen Aktien zugrunde. Das Datenmaterial besteht aus den jeweiligen bereinigten Tageskursen von 1983 bis 1986 und umfasst insgesamt 15.000 Einzeldaten (Vgl. Tabelle 1).
Des weiteren wurden die Renditen des DAX, des Indexes der Frankfurter Wertpapierbörse (F/M Börsenindex), des WestLB-Indexes sowie die logarithmierten Umsätze der betrachteten Aktien mit einbezogen.
Grundsätzlich besteht die Wahl, mit Tages- oder Wochenrenditen zu arbeiten. In dieser Untersuchung wurden Tagesrenditen gewählt, da dem KNN hierdurch 250 Datenwerte pro Jahr statt 50 zur Verfügung gestellt werden können, wenngleich die Wochenrenditen tendenziell eher normalverteilt sind als die Tagesrenditen [5].
Zum Vergleich, inwieweit Prognosen der Aktienrenditen mit Hilfe verschiedener Verfahren möglich sind und wie gut die gewählten Verfahren diese Aufgabe erfüllen, werden zwei Kenngrössen für jedes Verfahren pro Jahr und Aktie berechnet. Als Vergleichskriterien kommen die Summe der quadrierten Residuen (SQR) und die mittlere absolute Differenz (MAD) zum Einsatz:

$$SQR = \sum_{t=1}^{n} \left(R_{it} - \hat{R}_{it}\right)^2$$

und

$$MAD = \frac{1}{n} \cdot \sum_{t=1}^{n} \left|R_{it} - \hat{R}_{it}\right|$$

mit

$\hat{R}_{it}$ = prognostizierte Rendite für Aktie i im Zeitraum von t-1 bis t

n = Anzahl der Börsentage des betrachteten Jahres.

Aus der Vielzahl möglicher KNN-Paradigmen, die der Forschungsbereich des Konnektionismus bislang hervorgebracht hat, wurden für die hier vorliegende Aufgabenstellung mehrschichtige Backpropagation-Netzwerke, sogenannte Multilayer-Perceptrons zum empirischen Einsatz ausgewählt [6]. Diese KNN sind besonders gut zur Modellierung ökonomischer Strukturen geeignet, da die Modellbildung nicht auf einer restriktiven exakten a priori Spezifikation der Strukturen basiert, sondern nur auf grobe Vorgabe möglicher Einflussfaktoren, die automatisch durch Lernen aus Erfahrung anhand von Vergangenheitsdaten verfeinert wird.

KNN sind Informationsverarbeitungssysteme, bestehend aus einer Vielzahl miteinander verknüpfter, unabhängiger Verarbeitungseinheiten, den Neuronen. Über spezielle Verbindungen können diese Neuronen untereinander und mit der Aussenwelt Signale austauschen. Zur Vereinfachung werden diese Neuronen häufig in Schichten, den sogenannten Layern, gruppiert, wobei typischerweise jedes Neuron einer Schicht mit allen Neuronen der vorangegangenen sowie der nachfolgenden Schicht verbunden ist. Schichten, die Signale von der Aussenwelt empfangen, werden als Eingabeschichten bezeichnet, Schichten, in denen die Neuronen nur mit anderen Neuronen in Verbindung stehen, als Zwischenschichten oder "Hidden Layers" und Schichten, die Informationen an die Aussenwelt weiterleiten, als Ausgabeschichten. Im folgenden sollen beispielhaft die Vorgänge innerhalb eines KNN skizziert werden.

Die Signalverarbeitung in einem Neuron kann in etwa mit einem einfachen Entscheidungsprozess verglichen werden. Jedes einzelne Neuron bewertet die Signale von allen ihm zur Verfügung stehenden Informationskanälen (feedforward-Verbindung) mit speziellen Gewichten und fasst diese Einzelinformationen durch Summation zu einer Gesamtkennzahl zusammen. Diese wird dann mit einem Schwellenwert (Bias) verglichen, um das Ausgabesignal des jeweiligen Neurons, quasi die Entscheidung des Neurons, zu ermitteln und an die anderen Neuronen zur Weiterverarbeitung oder als KNN-Ausgabewert zur Aussenwelt weiterzuleiten.

Legt man einem KNN ein bestimmtes Muster von Eingangssignalen an die Eingabeschicht an, so kann man, nachdem die oben skizzierte Informationsverarbeitung abgeschlossen ist, an den Neuronen der Ausgabeschicht den oder die KNN-Ausgabewerte ablesen. Falls dieser, was zu Beginn des Trainings eines KNN zu erwarten ist, nicht mit dem gewünschten Ausgabewert übereinstimmt, muss die Entscheidungsfindung im KNN korrigiert werden. Hierzu wird die Differenz zwischen dem real vorliegenden KNN-Ausgabewert und dem gewünschten berechnet und anhand dessen Fehler mit Hilfe des Backpropagation-Algorithmus die Gewichtung der jeweiligen Informationskanäle aller Neuronen verändert. Auf diese Weise wird erreicht, dass das KNN das angelegte Eingangsmuster mit dem gewünschten Ausgabewert assoziiert [7]. Wiederholt man dieses Training für verschiedene Beispiele, also Eingangsmuster- und Ausgabewert-Kombinationen, so wird das KNN zunehmend den für die jeweilige Aufgabenstellung relevanten Informationskanälen eine höhere Gewichtung und den unwichtigen ein geringes Gewicht beimessen. Nach beendetem Training hat das KNN die Gewichte zwischen den einzelnen Neuronen derart angepasst, dass es sowohl bei den bekannten trainierten Eingangsmustern als auch bei unbekannten Eingangsmustern weitgehend den gewünschten Ausgabewert liefert [8]. Durch den Trainingsalgorithmus und einen Satz an Beispieldaten können KNN somit automatisch, das heisst ohne menschliche Interaktion, eine Transferfunktion bzw. mathematische Abbildung zwischen Eingangsdaten - den möglichen Einflussgrössen - und den Ausgabewerten - den ökonomischen Zielgrössen - approximieren [9].

Die in dieser Untersuchung verwendeten KNN-Modelle unterscheiden sich voneinander in der Anzahl der Zwischenschichten, der Anzahl der Neuronen und dem Vorhandensein von feedback-

Schichten. Diese feedback-Schichten speichern die Signale einer anderen Schicht zu einer vorangegangenen Periode. Sie bilden somit eine Art Gedächtnis für das KNN, in dem Informationen über vorangegangene Arbeitsschritte früherer Zeitpunkte gespeichert werden können. KNN mit feedback-Schichten werden auch als recurrent-KNN bezeichnet, die hier verwendeten recurrent-KNN können auf die Eingangsdaten sowie ihre eigenen Prognosen der vorhergehenden zwei Perioden zurückgreifen [10]. Sie können somit in Abhängigkeit vom zeitlichen Kontext der Eingabemuster unterschiedlich auf gleiche Eingaben reagieren und somit nicht lineare autoregressive Prozesse beschreiben [11]. Abbildung 1 skizziert in komprimierter Form die Struktur der getesteten KNN-Modelle 1 bis 6.

Zur Verdeutlichung der in Abbildung 1 skizzierten KNN-Topologien wird in Abbildung 2 die Struktur von KNN3 detailliert dargestellt. Das KNN3 entwirft ein Modell der allgemeinen Form

$$\hat{R}_{i,t} = f\left(\hat{R}_{i,t-1};\hat{R}_{i,t-2};\hat{R}_{M,t-1};\hat{R}_{M,t-2}\right)$$

Abbildung 1: Struktur der in der Untersuchung verwendeten KNN-Modelle

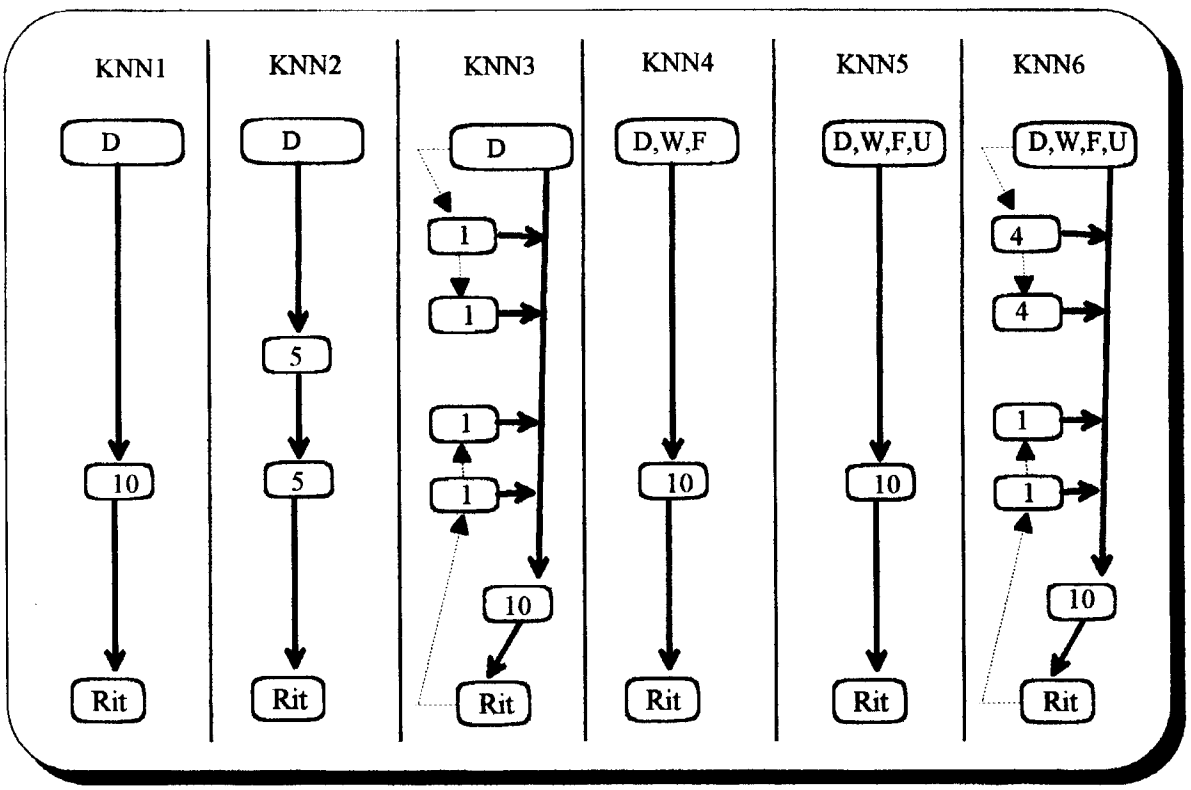

Eine dicke durchgezogene Linie steht für eine vollständige feedforward-Verbindung von zwei Schichten, wobei jedes Neuron der oberen Schicht mit jedem der unteren verbunden wird, eine gepunktete Linie für Verbindung zu einer feedback-Schicht (Gedächtnis), ein Rechteck für eine Neuronenschicht, wobei die Zahl in dem Rechteck die Anzahl an Neuronen in der jeweiligen Schicht angibt,

D für den Eingangswert Tagesrendite DAX zum Zeitpunkt *t* in der Eingabeschicht,

W für den Eingangswert Tagesrendite WestLB-Index zum Zeitpunkt *t* in der Eingabeschicht,

F für den Eingangswert Tagesrendite F/M Börsenindex zum Zeitpunkt *t* in der Eingabeschicht,

U für den Eingangswert logarithmierte Umsätze der Aktie *i* zum Zeitpunkt *t* in der Eingabeschicht und R_{it} für den Ausgabewert Tagesrendite der Aktie *i* zum Zeitpunkt *t*.

Abbildung 2: Detaillierter Aufbau des KNN3-Modells

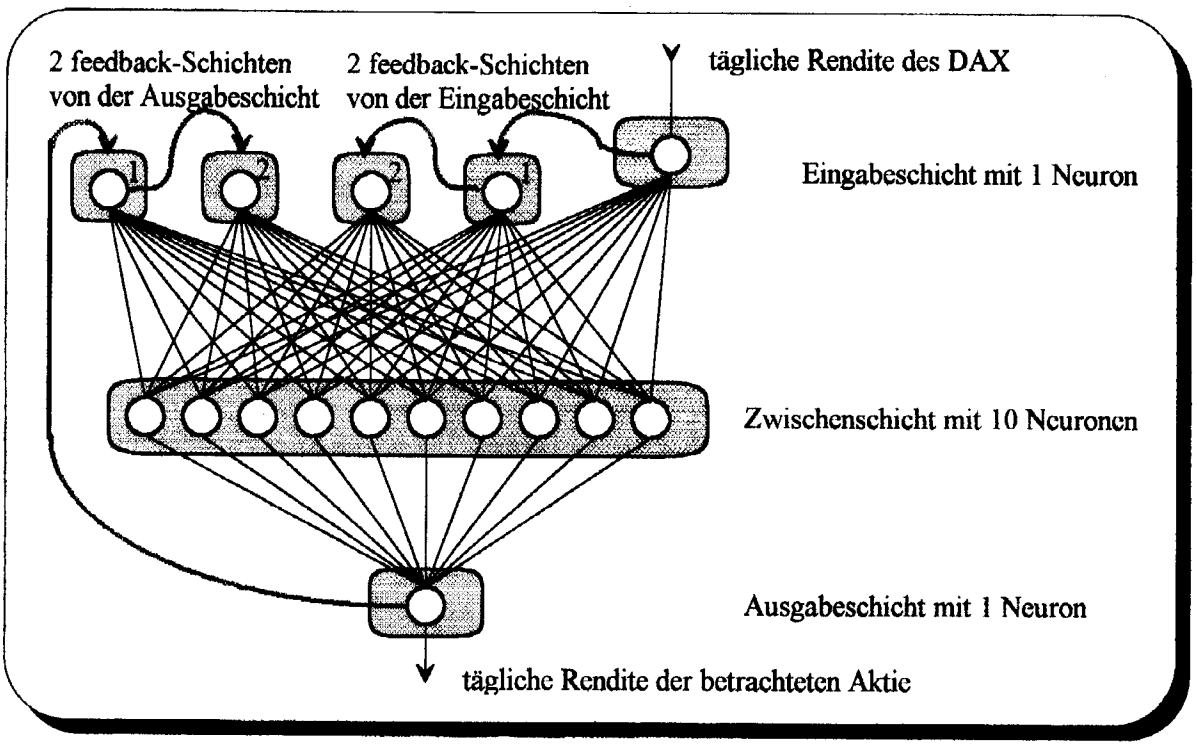

unter Verwendung des DAX-Indexes für R_M. Während der Renditeschätzung wird der Eingabeschicht nur der Wert der DAX-Rendite für den Tag t ($R_{M,t}$) extern vorgegeben. In dem Neuron der feedback-Schicht 1 der Eingabeschicht befindet sich aus dem vorangegangenen Durchlauf die DAX-Rendite des Vortages, in dem Neuron der feedback-Schicht 2 entsprechend der Wert der DAX-Rendite aus dem Durchlauf für den Tag t-2. Analog ist der KNN-Schätzwert $\hat{R}_{i,t-1}$ für $R_{i,t-1}$ aus dem Vortagesdurchlauf in dem Neuron der feedback-Schicht 1 der Ausgabeschicht und $\hat{R}_{i,t-2}$ in dem Neuron der feedback-Schicht 2 der Ausgabeschicht.

Die Ausgangssignale dieser fünf Neuronen werden den zehn Neuronen der Zwischenschicht übergeben, die hieraus ihre eigenen Ausgabesignale berechnen und diese wiederum dem Neuron der Ausgabeschicht als Eingabe zur Verfügung stellen. Nachdem das Neuron der Ausgabeschicht einen Schätzwert für die Rendite $R_{i,t}$ der betrachteten Aktie ermittelt hat, wird das aktuelle Ausgabesignal der jeweils ersten feedback-Schicht in die jeweils zweite feedback-Schicht kopiert und das Ausgabesignal des Neurons der Ausgabe- und Eingabeschicht in die jeweils korrespondierende erste feedback-Schicht kopiert [12].

Im Rahmen eines Vorversuches wurden ausser den hier angeführten noch weitere, komplexere Modelle betrachtet:

- KNN mit einer grösseren Zahl von Zwischenschichten,
- KNN mit Kontextschichten [13],
- KNN mit mehr Neuronen in den Zwischenschichten,
- KNN mit zusätzlichen feedback-Schichten.

Als konsistentes Resultat lässt sich nur festhalten, dass mit zunehmender Komplexität der KNN der Trainingsaufwand deutlich steigt, während sich die Prognosequalität im Vergleich zu den hier angeführten Modellen nur geringfügig ändert. So führt zum Beispiel die Einführung weiterer feedback-Schichten oder die Verdopplung der Neuronen in

den Zwischenschichten zu keiner signifikanten Verbesserung der Schätzungen, daher werden solche KNN-Strukturen hier nicht weiter dargestellt.

3.2 Vorbereitungen und Besonderheiten des Trainings der KNN

Bevor die KNN zur Schätzung der Aktienrenditen eingesetzt werden können, müssen sie mit Hilfe des Backpropagation-Algorithmus anhand von Beispieldaten trainiert werden [14]. Da das Training der KNN mit zufällig gewichteten Verbindungen zwischen den Neuronen beginnt, kann jedes erneute Training zu geringfügig anderen Lösungen führen. Zur Vermeidung von hieraus resultierenden Fehlern wurde jedes KNN-Experiment zweimal wiederholt und der Mittelwert dieser drei Experimente als Ergebnis weiter verwendet.

Die KNN werden mit einer Lernrate von 0,0075 ohne Momentum mit zufälligen Startgewichten aus dem Intervall von {-0,65; +0,65} anhand der 250 Eingangswerte des Jahres J trainiert. Nach absolviertem Training müssen sie anhand der 250 Eingangswerte des Jahres J+1 Prognosewerte für die jeweilige Aktienrendite liefern. Während des Trainings wird nun protokolliert, ob die Änderungen der einzelnen Gewichte zwischen den Neuronen vermutlich durch das Erkennen systematischer Zusammenhänge in den Beispieldaten oder durch den Versuch, Störvariablen zu prognostizieren, resultieren. Falls letzteres der Fall sein sollte, werden die jeweiligen Verbindungen gelöscht [15] (auf Null gesetzt). Als weiteres Hilfsmittel, um Effekte wie Overtraining oder Overfitting weitgehend auszuschalten [16], wurde ein Teil der Trainingsdaten als Holdout-Werte aus den Lerndaten ausgeschlossen, um so die Generalisierungsfähigkeit des KNN zu testen; diese Technik wird auch als Crossvalidation bezeichnet. Trainiert werden die KNN nur so lange, wie sich der Schätzfehler bezogen auf die Holdout-Werte nicht verschlechtert.

Der Einsatz von KNN ist im Gegensatz zur Anwendung der meisten statistischen Verfahren nicht an bestimmte Prämissen bezüglich der Verteilung des Datenmaterials wie zum Beispiel Standardnormalverteilung, gekoppelt [17]. KNN haben keine Prämissen über die den Beispieldaten zugrunde liegende statistische Verteilung, die Trainingsdaten sollten jedoch für die Problemstellung repräsentativ sein. Ausserdem erfordern die hier verwendeten KNN, dass das Datenmaterial nur Werte aus dem Intervall von 0 bis 1 enthält. Um dieses zu erreichen, wird das Datenmaterial transformiert. Ex-ante wird postuliert, dass alle Renditen innerhalb des Intervalls von -3,75% bis +3,75% liegen sollen; Renditen, die ausserhalb dieses Intervalls liegen, werden durch den jeweiligen Intervallgrenzwert ersetzt. Bei den Umsätzen wird anhand der Trainingsdaten ein um den Mittelwert symmetrisches Intervall ermittelt, in dem 97,5% der Trainingsdaten liegen. Die untere und obere Grenze dieses Intervalls werden nun als minimaler und maximaler Wert für den Umsatz postuliert, um so den möglichen Einfluss von Ausreissern zu reduzieren. Die Rendite-Trainingsdaten des Netzes ergeben sich nun gemäss folgender Transformation:

$$R'_{it} = \frac{R_{it} - \min(R)}{\max(R) - \min(R)}$$

Diese Vorgehensweise impliziert, dass die prognostizierten minimalen und maximalen Renditen und Umsätze des Prognosejahres den realen Renditen des Trainingsjahres entsprechen, da das KNN nur innerhalb dieser Intervalle prognostizieren kann. Die Verwendung der realen Maxima und Minima aus Trainings- und Prognosejahr verbietet sich von selbst, da diese Untersuchung als Ex-ante-Betrachtung ausgelegt ist. Ein weiteres gebräuchliches Verfahren besteht in der Standardisierung der Beispieldaten [18]:

$$R'_{it} = \frac{1}{1 + e^{-\left(\frac{R_{it} - \mu_R}{\sigma_R}\right)}}$$

Der Einsatz dieser Transformationsregel scheint, wie verschiedene Testläufe ergaben, zur Transformierung von Renditen weniger gut geeignet zu

sein, da sich das Lernverhalten der KNN leicht verschlechterte (geringere Konvergenz) und auch die Schätzungen der Renditen sich verschlechterten.

3.3 Regressionsanalysen als Vergleichsverfahren

Um einen Vergleichsmassstab für die Fehlermasse der KNN-Modelle zu bekommen, wurden verschiedene uni- und multivariate Regressionsanalysen zur Schätzung der Aktienrenditen durchgeführt. Das erste Vergleichsverfahren (EinfReg) basiert auf der Annahme stationärer Betafaktoren. Es entspricht der üblichen Vorgehensweise zur Schätzung des Marktmodells und der zu erwarteten Betafaktoren [19]. Anhand der 250 Aktien- und Marktportefeuilletagesrenditen im Jahr J werden mit Hilfe einer linearen Kleinste-Quadrate-Regression Schätzwerte für a_i und b_i ermittelt. Diese Schätzwerte werden nun benutzt, um im Jahr J+1 für die gegebenen 250 Tagesrenditen des Marktportefeuilles die erwarteten Aktienrenditen zu schätzen. Das zweite Regressionsverfahren (EinfReg $a = 0$) unterscheidet sich vom ersten nur dadurch, dass der Wert a_i auf Null gesetzt wird, da die Vernachlässigung des marktunabhängigen Renditebestandteils zu besseren Schätzwerten führen kann [20].
Als Benchmark im eigentlichen Sinne für diese Untersuchung soll das dritte Regressionsmodell (ProgReg) herangezogen werden. Für diesen Zweck soll eine lineare Kleinste-Quadrate-Regression über R_i und R_M im Jahr J+1 durchgeführt werden, um die so ermittelten Koeffizienten a_i und b_i zur Berechnung der Schätzwerte der Aktienrenditen im Jahr J+1 zu verwenden. Bei Gültigkeit des Markmodells müsste dieses Modell die optimalen Schätzwerte für die Aktienrendite liefern.
Für das vierte Verfahren (MultReg) wurde eine multiple Regression über die Renditen der drei Indizes sowie die logarithmierten Aktienumsätze im Jahr J durchgeführt und diese vier Regressionskoeffizienten wurden zur Ermittlung der Aktienrendite im Jahr J+1 herangezogen. Dieses Verfahren soll zeigen, inwieweit, durch die Hinzunahme der zusätzlichen Eingangsdaten von KNN6 in eine multiple Regressionsanalyse, sich die Genauigkeit der Schätzungen der tatsächlichen Renditen verändert.

4. Durchführung der Untersuchung und Darstellung der Resultate

Im ersten Schritt werden anhand der Daten von 1983 die Schätzwerte für die Regressionskoeffizienten ermittelt und die KNN anhand der transformierten Beispieldaten trainiert. Im nächsten Schritt müssen die angeführten Verfahren die Aktienrenditen für die 250 Börsentage in 1984 anhand gegebener Indexrenditen und Aktienumsätze schätzen. Zwischen diesen Schätzwerten und den real aufgetretenen Aktienrenditen, also ohne die Eliminierung sogenannter Ausreisser, werden schliesslich die Fehlermasse MAD und SQR berechnet. In analoger Weise werden mit Hilfe der zehn Verfahren die Renditen für 1985 und 1986 anhand der jeweiligen Vorjahresdaten geschätzt und die Fehlermasse berechnet.
Tabelle 2 zeigt exemplarisch die auf diese Weise ermittelten Fehlermasse für die Renditeschätzungen der Aktie der Didier AG von 1984 bis 1986.
Da die gesamten Ergebnisdaten nur unübersichtlich in einer Tabelle dargestellt werden können (6 Aktien à 3 Jahre, 10 Verfahren mit 2 Fehlermassen = 360 Werte), empfiehlt es sich, die Ergebnisse weiter zu verdichten.
Dazu werden jeweils die Daten über die betrachteten drei Jahre und über die jeweiligen Gruppen (DAX bzw. Nicht-DAX) zusammengefasst. Bei der SQR erfolgt diese Zusammenfassung durch das Aufsummieren aller Werte, bei der MAD durch die Mittelung der einzelnen Werte. Anhand dieser zusammengefassten Fehlermasse wird die Rangfolge der jeweiligen Verfahren ermittelt. Die Rangfolgen nach Summe der SQR sind in Tabelle 3 dargestellt.

Tabelle 2: Darstellung der Fehlermasse der Didier Aktie

Verfahren	SQR 1984	SQR 1985	SQR 1986	MAD 1984	MAD 1985	MAD 1986
EinfReg	0,0584564	0,0911720	0,0959314	0,0106445	0,0143305	0,0145588
EinfReg $a = 0$	0,0583476	0,0911767	0,0959096	0,0105301	0,0143328	0,0145908
ProgReg	0,0580537	0,0852299	0,0954767	0,0105609	0,0133502	0,0146441
MultReg	0,0581252	0,0909034	0,0907416	0,0106565	0,0144370	0,0141507
KNN 1	0,0600037	0,0851519	0,0960010	0,0106807	0,0133117	0,0145276
KNN 2	0,0706422	0,0850898	0,1104277	0,0115647	0,0133129	0,0156716
KNN 3	0,0604040	0,0844409	0,0929801	0,0107008	0,0132000	0,0143920
KNN 4	0,0587430	0,0811682	0,0902566	0,0106132	0,0131012	0,0141024
KNN 5	0,0571696	0,0790889	0,0920247	0,0106066	0,0127648	0,0143942
KNN 6	0,0572320	0,0791537	0,0911767	0,0106189	0,0128323	0,0143677

Tabelle 3: Rangfolge nach Summe der SQR aller DAX- und Nicht-DAX-Werte

Verfahren	DAX SQR	Nicht-DAX SQR	Alle Werte SQR	DAX Rang	Nicht-DAX Rang	Alle Werte Rang
EinfReg	0,2818840	0,6335571	0,9154411	8	9	9
EinfReg $a = 0$	0,2810983	0,6335216	0,9146198	7	8	8
ProgReg	0,2769922	0,6147044	0,8916966	6	6	6
MultReg	0,2358149	0,6116412	0,8474561	3	4	4
KNN 1	0,2826088	0,6285336	0,9111424	9	7	7
KNN 2	0,3707186	0,6876504	1,0583689	10	10	10
KNN 3	0,2738059	0,6144395	0,8882454	5	5	5
KNN 4	0,2376303	0,5900157	0,8276460	4	3	3
KNN 5	0,2347227	0,5808382	0,8155608	2	2	2
KNN 6	0,2334067	0,5695979	0,8030046	1	1	1

Tabelle 4: Rangfolge nach Mittelwerten der MAD aller DAX- und Nicht-DAX Werte

Verfahren	DAX MAD	Nicht-DAX MAD	Alle Werte MAD	DAX Rang	Nicht-DAX Rang	Alle Werte Rang
EinfReg	0,0081259	0,0123370	0,0102314	9	9	9
EinfReg $a = 0$	0,0081138	0,0123136	0,0102137	8	8	8
ProgReg	0,0080028	0,0120792	0,0100410	6	5	6
MultReg	0,0071830	0,0121974	0,0096902	3	7	4
KNN 1	0,0080565	0,0121543	0,0101054	7	6	7
KNN 2	0,0089707	0,0127085	0,0108396	10	10	10
KNN 3	0,0078866	0,0120313	0,0099590	5	4	5
KNN 4	0,0071961	0,0118060	0,0095010	4	3	3
KNN 5	0,0071769	0,0117426	0,0094597	2	2	2
KNN 6	0,0071732	0,0116660	0,0094196	1	1	1

Tabelle 5: Prozentuale Differenzen der SQR relativ zur Einfachregression

Verfahren	Kaufhof	BASF	Siemens	PWA	Didier	KHD
EinfReg $a = 0$	0,21%	0,19%	0,43%	-0,13%	0,07%	0,09%
ProgReg	1,43%	1,52%	2,74%	2,96%	2,56%	2,83%
MultReg	5,41%	23,61%	32,82%	2,16%	2,09%	1,76%
KNN 1	0,10%	-0,13%	-0,23%	1,00%	1,29%	-0,73%
KNN 2	-31,78%	-0,63%	-41,52%	1,04%	-9,76%	-13,84%
KNN 3	1,36%	3,31%	6,34%	3,98%	2,38%	1,82%
KNN 4	5,26%	21,78%	32,61%	6,78%	5,47%	6,73%
KNN 5	7,78%	21,85%	31,08%	12,14%	6,51%	6,80%
KNN 6	8,69%	21,82%	31,82%	14,98%	6,74%	9,75%

Die Zusammenfassung der Ergebnisse der einzelnen MAD-Werte führt zu Tabelle 4.
Die Tabellen 3 und 4 deuten auf eine Überlegenheit einiger KNN-Verfahren gegenüber bestimmten Regressionsansätzen hin. Um einen genaueren Einblick in die quantitativen Unterschiede zwischen den Prognosefehlern der EinfReg und denjenigen der übrigen Verfahren zu erhalten, werden die prozentualen Unterschiede zwischen den Prognosefehlern der einzelnen Verfahren für jedes Jahr relativ zur einfachen linearen Regression berechnet und danach zu einem Durchschnittswert gemittelt (vgl. Tabelle 5). Die Prozentwerte geben an, um wieviel besser als die lineare Einfachregression die jeweiligen Verfahren sind, also um wieviel Prozent die jeweilige SQR geringer ist als die SQR der linearen Einfachregression.

5. Analyse der Ergebnisse und weitergehende Betrachtungen

Setzt man die Gültigkeit des Marktmodells nach Sharpe und eine längerfristige Stabilität der Betafaktoren voraus, so müsste erwartungsgemäss das ProgReg Verfahren die fehlerminimalen und somit besten Schätzwerte für die Aktienrendite im Vergleich zu allen betrachteten Verfahren liefern. Diese Erwartung wird jedoch durch die hier vorliegenden Ergebnisse nicht bestätigt. Stattdessen wurden die durchschnittlich genauesten Schätzungen, gemessen an MAD und SQR, mit Hilfe des KNN6-Modelles erzielt. Die prozentualen MAD-Unterschiede zur linearen Einfachregression sind in Abbildung 3 dargestellt.
Beim Vergleich der untersuchten univariaten Regressionsanalysen EinfReg und EinfReg $a = 0$ zeigt sich, dass eine geringfügige durchschnittliche Verbesserung der Schätzungen erreicht wird, wenn man den Regressionskoeffizienten a gleich Null setzt und die Prognosen nur auf b stützt. Derartige Schätzungen führen definitionsgemäß jedoch zu höheren SQR-Fehlern als die Benchmark ProgReg, da die Regressionskoeffizienten anhand der Daten des Vorjahres geschätzt und nicht anhand der Daten des Prognosejahres berechnet werden [21].
Die KNN-Verfahren 1 und 2 basieren auf vergleichbaren modelltheoretischen Grundlagen (univariate Beziehungen), da sie als Eingangswert nur jeweils eine Tagesrendite des Marktportefeuilles zur Verfügung haben. KNN1 liefert durchschnittlich mit geringeren Fehlern behaftete Renditeprognosen als die Regressionsverfahren EinfReg und EinfReg $a = 0$. Bei den DAX-Werten ist KNN1, gemessen an der SQR, allerdings geringfügig schlechter als die linearen Einfachregressionen.
KNN2 schneidet bei Betrachtung von sowohl MAD als auch SQR deutlich als schlechtestes Verfahren von allen ab. Eine mögliche Begründung hierfür könnte darin liegen, dass entweder das hier verwendete automatische Lernverfahren nicht optimal auf solche vierschichtigen KNN abgestimmt ist oder aber die untersuchte Problemstellung eine für solch ein vierschichtiges KNN zu geringe Komplexität

Abbildung 3: Prozentuale MAD-Unterschiede zur linearen Einfachregression

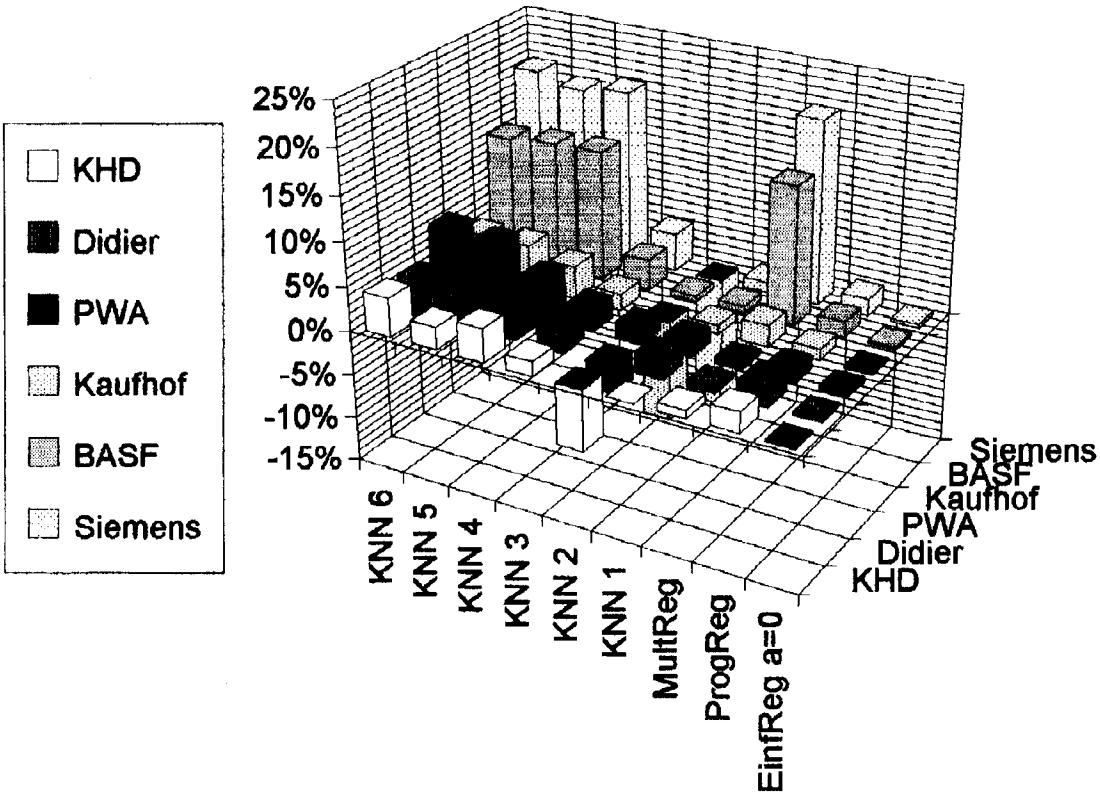

bzw. ein zu geringes Mass an Nichtlinearität aufweist [22].

Dass die Benchmark ProgReg nicht die fehlerminimalen Schätzungen aller Verfahren, sondern nur die der univariaten lieferte, deutet darauf hin, dass das unterstellte Marktmodell von Sharpe die Wirklichkeit nicht exakt abbilden kann.

Das mit einem "Gedächtnis" ausgestattete KNN3 liefert im Mittel bessere Ergebnisse zur Prognose der unbekannten Datenreihen als eine lineare Einfachregression über die zu prognostizierenden Daten. Dieses lässt den Schluss zu, dass das KNN innerhalb der Daten autoregressive Zusammenhänge erkannt hat und diese zur Verbesserung der Schätzungen nutzt.

Wenn nun die Schätzungen sich durch das Hinzufügen eines "Gedächtnisses" bereits verbessern, dann ist zu vermuten, dass auch das Zur-Verfügung-Stellen weiterer Eingangsdaten die Renditeschätzung verbessern könnte. Diese Vermutung wurde mittels KNN4 und KNN5 überprüft. Deutlich zeigt sich, dass die Einbeziehung von weiteren Indizes (F/M-Index & WestLB-Index), welche aus Sicht eines menschlichen Betrachters redundant erscheinen, doch zu deutlich besseren Schätzungen - sowohl gemessen anhand von SQR als auch MAD - führt als alle vormals betrachteten Verfahren. Eine weitere Verbesserung der Schätzungen konnte durch Hinzuziehung des logarithmierten Aktienumsatzes zu den bisherigen Eingangswerten erzielt werden. Diese Rangfolge ist konsistent über DAX- und Nicht-DAX-Werte und über SQR und MAD.

Die geringsten Fehler SQR und MAD ergeben sich bei KNN6, es führt im Vergleich zu allen getesteten Verfahren zu den besten Schätzungen bezüglich der Aktienrendite. Als Kontrollverfahren kann MultReg, eine multiple lineare Regression über die Eingangswerte von KNN6, gesehen werden. Renditeschätzungen mittels MultReg ergaben, wie in den Tabellen ersichtlich, dass so ermittelte Schät-

zungen konsistent besser sind als die der Einfachregressionen, allerdings durchschnittlich schlechter als die der KNN mit mehreren Eingangsdaten. Nur bezogen auf die DAX-Werte schneidet KNN4 schlechter ab als die Mehrfachregression. Bezogen auf die Nicht-DAX-Werte resultiert hieraus, dass ein KNN aus weniger Informationen in diesem Fall bessere Schätzungen erzielen kann als eine lineare Mehrfachregression mit mehr Eingangsdaten.

Der Versuch, mit Hilfe einer schrittweisen Elimination die wichtigsten Einflussfaktoren zu ermitteln, führte nur zu geringen Verbesserungen der Schätzungen. Hierbei ist anzumerken, dass fast ausnahmslos zuerst die logarithmierten Aktienumsätze als nicht signifikant erkannt und aus der Mehrfachregression eliminiert wurden, obwohl die Fehlerwerte von KNN4 und KNN5 darauf hinzuweisen scheinen, dass die logarithmierten Aktienumsätze sehr wohl einen Zusammenhang zur Aktienrendite aufweisen, vermutlich aber einen nichtlinearen.

Bei den kleineren nicht im DAX enthaltenen Werten erscheint aufgrund der hier ermittelten Ergebnisse der Vorteil des Einsatzes von KNN mit mehreren Eingangswerten am ausgeprägtesten, während bei den DAX-Werten auch Mehrfachregressionen zu sehr guten Ergebnissen führen können.

Diese Ergebnisse legen insgesamt den Schluss nahe, dass nichtlineare Zusammenhänge zwischen verschiedenen am Kapitalmarkt beobachtbaren Grössen und der täglichen Aktienkursrendite bestehen und dass diese Beziehungen mit einem KNN deutlich besser modelliert und zu Prognosen des Zusammenhangs zwischen der Rendite und verschiedenen Einflussgrössen genutzt werden können als mit vergleichbaren Regressionstechniken.

Zur näheren Analyse der unterschiedlichen Schätzfähigkeiten wurden die mittels KNN1 und der Einfachregression EinfReg $a = 0$ erstellten Schätzungen der Aktienrenditen einander gegenübergestellt (vgl. Abbildung 4). Hierzu wurden auf der X-Achse des Diagramms hypothetische DAX-Indexrenditen im Bereich von {-3,75% bis +3,75%} abgetragen und auf der Y-Achse die vom jeweiligen Verfahren geschätzten Aktienrenditen, am Beispiel der PWA-Aktien im Jahr 1984. In Abbildung 4 wird ein wesentlicher Unterschied zwischen den Schätzungen des KNN1 und denen der linearen Einfachregression deutlich; die Regression prognostiziert gemäss ihrer Prämissen einen linearen Zusammenhang zwischen Marktportefeuillerendite und Aktienrendite, während das KNN1 einen nichtlinearen Zusammenhang prognostiziert. Bei relativ hohen absoluten Marktportefeuillerenditen prognostiziert das KNN1 geringere absolute Veränderungen der Aktienrendite als bei geringeren absoluten Marktportefeuillerenditen.

Die Abbildung 5 zeigt die in 1984 real zu beobachtenden Aktien- und Indexrenditen, die den obigen Schätzungen zugrunde lagen. Bezogen auf die Fehlermasse scheint das KNN1-Modell den wirklichen Zusammenhängen am Kapitalmarkt näher zu kommen als das Regressionsmodell.

Da die erweiterten KNN-Modelle noch geringere durchschnittliche MAD- und SQR-Fehler aufweisen, liegt der Schluss nahe, dass sie eine noch genauere Modellierung der Realität ermöglichen und somit die Annahme eines einfachen linearen Zusammenhangs für das Kapitalmarktmodell eine zu starke Vereinfachung der Realität darstellt.

Einen um die logarithmierten Aktienumsätze erweiterten Ansatz benutzen KNN5 und KNN6 zur Prognose der Zusammenhänge am Kapitalmarkt, die die Aktienrendite bestimmen. Die dargestellten Ergebnisse zeigen, dass durch die Miteinbeziehung des Aktienumsatzes die Schätzungen der Aktienrenditen verbessert werden können. Zur Untersuchung des Einflusses der Aktienumsätze wurde ein neues KNN-Modell erstellt und mit der Marktportefeuillerendite und den logarithmierten Aktienumsätzen der KHD-Aktien von 1983 trainiert. Nach beendetem Training wurden dem KNN verschiedene hypothetische logarithmierte Aktienumsätze und Marktportefeuillerenditen vorgegeben, um jeweils die zu erwartende Aktienrendite zu schätzen. Die so ermittelten hypothetischen Aktienrenditen sind als Ebene in der Abbildung 6 ersichtlich.

In Abbildung 6 erkennt man, dass für das KNN die DAX-Rendite die Haupteinflussgrösse darstellt, da durch ihre Variation mit Abstand die grössten

Abbildung 4: Vergleich der geschätzten Renditen der PWA-Aktie für 1984

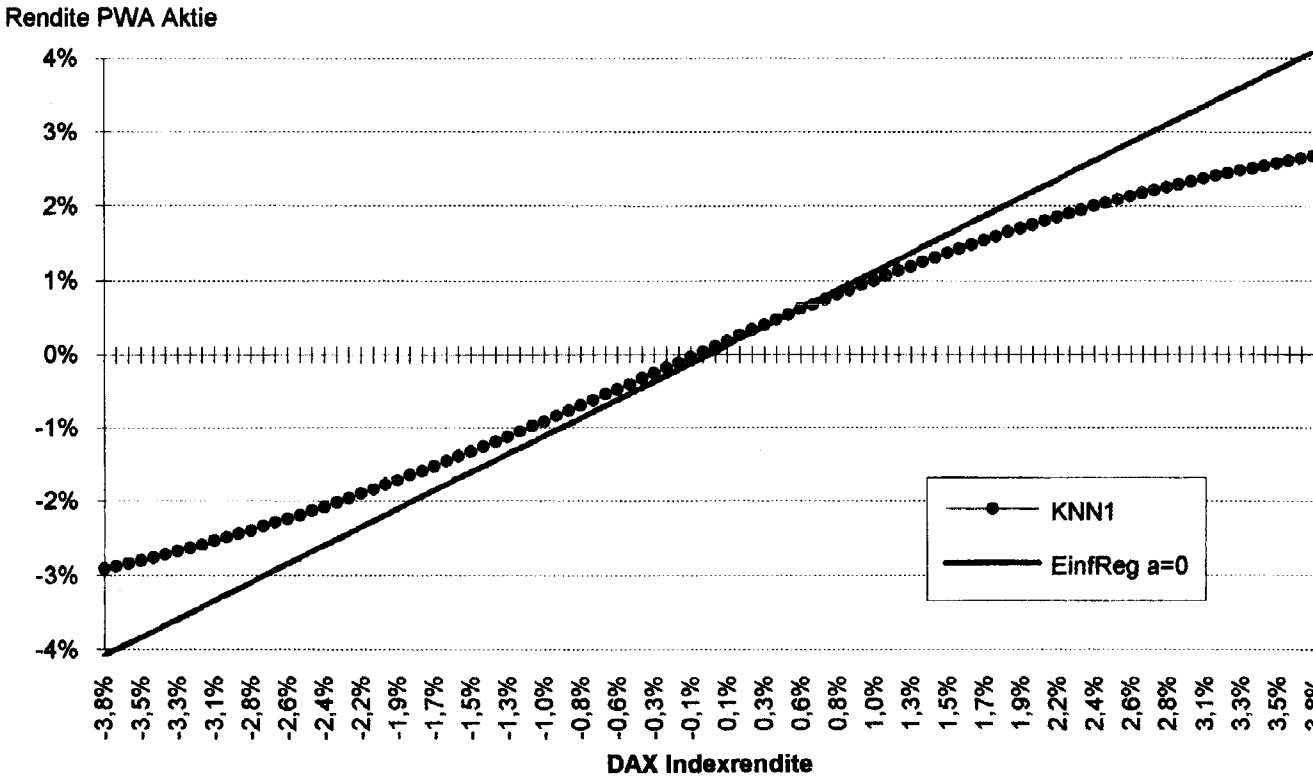

Abbildung 5: Renditen der PWA-Aktie in Abhängigkeit von der DAX-Rendite in 1984

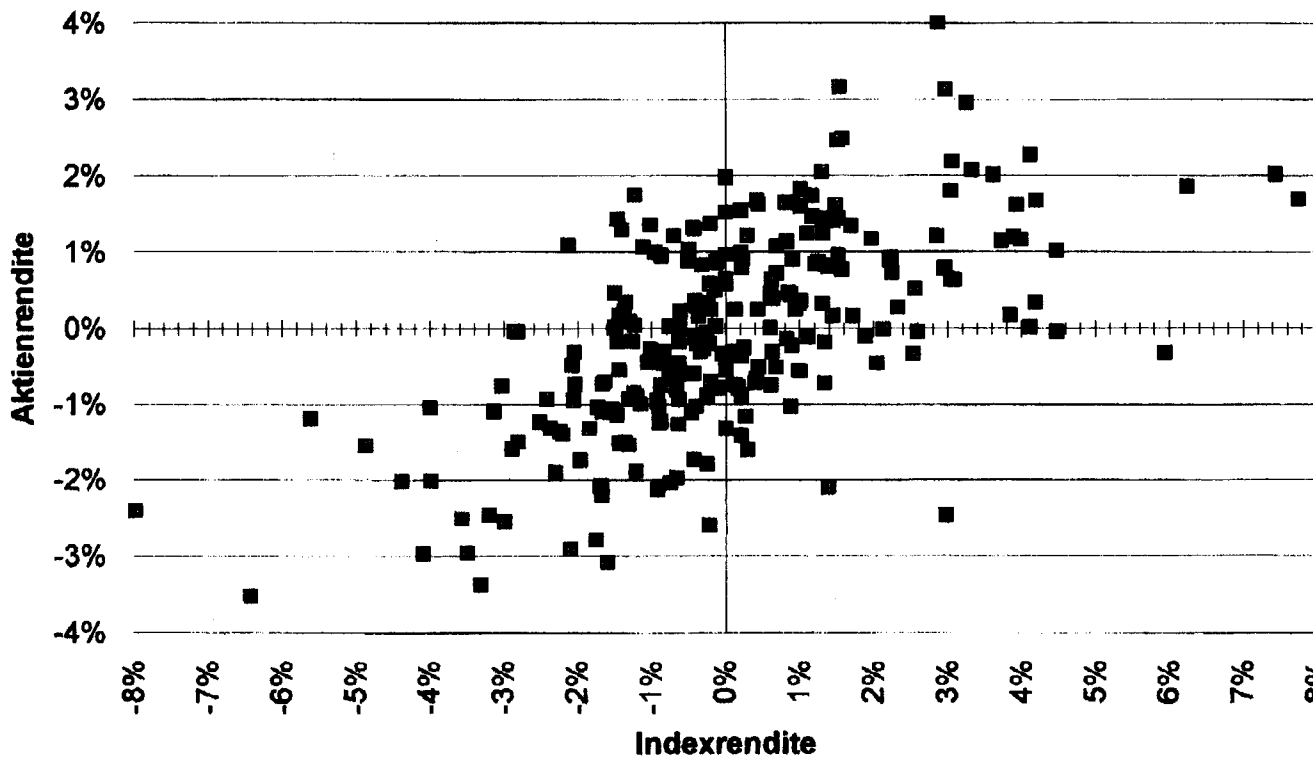

Abbildung 6: Hypothetische Aktienrenditen in Abhängigkeit von Aktienumsatz und DAX-Rendite

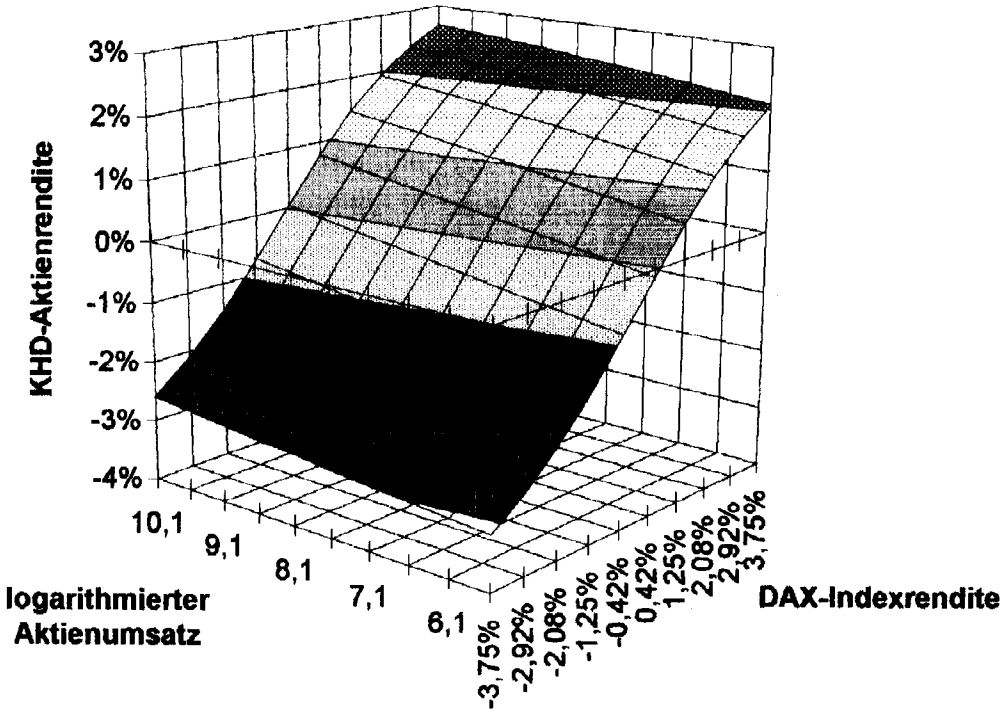

Veränderungen bezüglich der Aktienrendite entstehen. Auf der anderen Seite ist aber auch ein deutlich geringerer Einfluss des Aktienumsatzes erkennbar. Die Ebene der Aktienrenditen fällt mit abnehmenden Aktienumsätzen ab; dieses bedeutet, dass das KNN bei höheren Umsätzen tendenziell auch höhere Aktienrenditen prognostiziert. Dieses theoretisch unerwartete Resultat liess sich auch für andere Aktien und andere Zeitabschnitte reproduzieren.
Eine grafische Darstellung von mehr als zwei Einflussfaktoren auf die Aktienrendite, wie sie bei den KNN3 bis KNN6 vorliegen, erweist sich als äusserst problematisch und eine isolierte Betrachtung von nur einem Teil der Einflussgrössen eines KNN führt zu nicht besonders aussagekräftigen Ergebnissen, da hierdurch den nichtlinearen Verknüpfungen der Eingangswerte innerhalb des KNN nicht Rechnung getragen würde.

6. Zusammenfassung

In der hier dargestellten Untersuchung werden zunächst verschiedene KNN und Regressionsverfahren zur Schätzung des Zusammenhangs zwischen ausgewählten Einflussgrössen und der Rendite einzelner Aktien eingesetzt. Die so ermittelten Modelle des Renditegenerierungsprozesses werden dann zur Schätzung der Aktienrendite im jeweils darauffolgenden Jahr verwendet. Ein Vergleich der Genauigkeit der verschiedenen Renditeschätzungen deutet darauf hin, dass die Annahme eines nichtlinearen Zusammenhangs zwischen der Rendite des Marktindexes und der Aktienrendite eine bessere Abbildung des zukünftigen Marktindexrendite-Aktienrendite-Zusammenhangs ermöglicht als die Annahme eines marktmodellkonformen linearen Zusammenhangs. Eine weitere Verbesserung der KNN-Renditeschätzungen liess sich durch die Hinzunahme redundant erscheinender zusätzlicher Aktienindexrenditen und des logarithmierten Aktienumsatzes erzielen. Hierbei zeigte sich, dass

bei den KNN höhere Aktienumsätze zu c.p. höheren Aktienrenditeschätzungen führen. Weiterhin konnte durch den Einsatz von recurrent-KNN, welche in der Lage sind, einfache autoregressive Zusammenhänge in den Daten zu erkennen und zu modellieren, eine Erhöhung der Schätzqualität der KNN erreicht werden.

Diese Untersuchung zeigt, dass die Annahme eines einfachen Marktmodells der Realität nicht gerecht wird und der Einsatz statistischer Verfahren, insbesondere Regressionsanalysen, zur Ermittlung der Parameter eines solchen Marktmodells zu unbefriedigenden Ergebnissen führt. Die Modellierung der die Aktienrendite bestimmenden Zusammenhänge auf dem Kapitalmarkt kann entscheidend verbessert werden, wenn das Modell weitere Einflussfaktoren, zeitliche Abhängigkeiten und die Berücksichtigung nichtlinearer Beziehungen zwischen den betrachteten Grössen beinhaltet. Es muss jedoch damit gerechnet werden, dass die Parameter solcher komplexer Modelle nicht stabil sind und auch die Art der Beziehungen zwischen den Einflussfaktoren im Zeitablauf variieren kann.

Aufgrund dieser Bedingungen bietet sich der Einsatz künstlicher neuronaler Netzwerke zur Approximation dieser Zusammenhänge an. KNN können, basierend auf den jeweils aktuell vorliegenden Daten, ein internes Modell über die Beziehungen der Einflussgrössen auf die Aktienrendite am Kapitalmarkt aufbauen und dieses automatisch an veränderte Kapitalmarktbeziehungen anpassen. Sie ermöglichen so eine genauere Modellierung dieser Zusammenhänge und erlauben präzisere Schätzungen der erwarteten Aktienrendite.

Fussnoten

[1] Den erfolgreichen Einsatz von KNN beschreiben z.B.: ROMANIUK/HALL (1990), KRAUSE (1993), ERXLEBEN et al (1992), REHKUGLER/PODDIG (1992a), COATS/FANT (1992), BAILEY/THOMPSON/FEINSTEIN(1988), KOSAKA et al (1991), DUTTA/SHEKHAR (1988) und KAMIJO/TANIGAWA (1990).

[2] Vgl. SHARPE (1963).

[3] Vgl. BODIE/KANE/MARCUS (1989), pp. 264f..

[4] Vgl. zum CAPM PERRIDON/STEINER (1993), p. 252, sowie zur empirischen Überprüfung des Kapitalmarktmodells PERRIDON/STEINER (1993), p. 258.

[5] Zur Problematik der Berechnung von Renditen vgl. BAUER (1992), pp. 13ff. und pp. 120f..

[6] Es existiert eine Vielzahl weitere grundverschiedener Netzwerktypen, ein Einblick hierzu wird zum Beispiel gegeben bei HERTZ/KROGH/PALMER (1991) und WASSERMANN (1989).

[7] Der Backpropagation-Trainingsalgorithmus wird ausführlich dargestellt bei RUMELHART/MCCLELLAND (1986).

[8] Eine detailliertere Beschreibung des KNN-Trainings illustriert an einem Beispiel geben STEINER/WITTKEMPER (1993).

[9] Grundsätzlich können dreischichtige KNN jede beliebige stetige Funktion sowie ihre Ableitung anhand von Beispieldaten appoximieren, vgl. HORNIK/STICHCOMBE/WHITE (1989) sowie CARDALIAGUET/EUVRARD (1992).

[10] Die in dieser Untersuchung eingesetzten recurrent-KNN werden detaillierter beschrieben bei JORDAN (1989). Eine Vergleich der Leistungsfähigkeit verschiedener alternativer recurrent-KNN gibt MOZER (1993). Gemäss der Taxanomie von Mozer handelt es sich bei den in dieser Untersuchung verwendeten recurrent-KNN um "static, delay line, Input/Output-Memories".

[11] Eine feedback-Schicht könnte z.B. in einer autoregressiven Gleichung der Form $R_{i,t} = a+b*R_{i,t-1}+c*R_M$ das für den vorangegangenen Zeitpunkt t-1 vom KNN prognostizierte $R_{i,t-1}$ speichern und der Berechnung des Ri,t zum gegenwärtigen Zeitpunkt zuzuführen. Im Gegensatz zu den relativ einfachen in dieser Untersuchung verwendeten recurrent-KNN können komplexere, mehrschichtige, vollständig vernetzte recurrent-KNN auch zur Modellierung von NARMA-Prozessen sowie zur Approximation beliebiger dynamischer Systeme eingesetzt werden, vgl. DOYA (1993) und CONNOR/ATLAS/MARTIN (1992).

[12] Man beachte, dass es sich bei den $R_{i,t-j}$-Werten der feedback-Schichten nicht um exogen vorgegebene beobachtete Ri,t-j-Werte sondern um die Schätzwerte des KNN für die $R_{i,t-j}$-Werte handelt. Ein Kontrollversuch

mit einem ähnlich aufgebautem KNN mit exogener Vorgabe von $R_{M,t}$, $R_{M,t-1}$, $R_{M,t-2}$, $R_{i,t-1}$ und $R_{i,t-2}$ ohne feedback-Schichten führte im Vergleich zu KNN3 zu leicht ungenaueren Renditeschätzungen gemessen an MAD und SQR.

[13] Es handelte sich hierbei um eine andere Variante der recurrent-KNN, vgl. ELMAN (1990).

[14] Vgl. RUMELHART/MCCLELLAND (1986).

[15] Es handelt sich hierbei um ein Verfahren, welches im Hause SIEMENS entwickelt wurde. Es basiert darauf, auf statistischem Wege die Signifikanz der einzelnen Gewichte im KNN zu ermitteln, vgl. FINNOFF/ZIMMERMANN (1991), FINNOFF/HERGERT/ZIMMERMANN (1993) und REHKUGLER/PODDIG (1992b), pp. 16ff..

[16] Unter Overtraining oder Overfitting versteht man den Vorgang, dass der Schätzfehler des KNN, bezogen auf die Trainingsdaten mit fortschreitendem Training zunehmend abnimmt, während er, bezogen auf unbekannte Daten, ab einer gewissen Trainingsdauer beginnt anzusteigen, vgl. MORGAN/BOURLARD (1990).

[17] Vgl. TAM/KIANG (1990).

[18] Vgl. REHKUGLER/PODDIG (1992b), p. 24.

[19] Die Anwendung dieses Schätzverfahrens setzt eine Normalverteilung der Renditen voraus, daher empfiehlt es sich, wöchentliche Renditen zu verwenden, da diese eher als normal verteilt gelten können als tägliche Renditen, vgl. BAUER (1992), p. 121. Das Ziel der verschiedenen Verfahren in dieser Untersuchung ist es, die tatsächlichen täglichen Aktienrenditen möglichst genau zu schätzen. Zu diesem Zweck wurden im Rahmen eines Vorversuches auch Betafaktoren auf Basis wöchentlicher Renditen ermittelt und zur Schätzung der täglichen Renditen im folgenden Jahr eingesetzt. Diese Verfahren führten zu deutlich höheren Schätzfehlern als die auf Tagesrenditen basierenden Verfahren, daher wird in dieser Untersuchung nur mit Tagesrenditen gearbeitet.

[20] Der Vorversuch legte diesen Schluss nahe, da die a-Koeffizienten gemäß eines t-Tests sich nicht signifikant von 0 unterschieden.

[21] Dieses gilt nicht für das Fehlermass MAD (vgl. Tabelle 2, MAD 1984), da die Regression nach dem Kleinste-Quadrate-Verfahren nicht unbedingt zu der Regressionsgeraden führt, die den MAD-Wert minimiert.

[22] Unsere Erfahrungen, sowie die der SIEMENS-Forschungsgruppe ZFE IS INF 23 und die von Rehkugler und Poddig deuten darauf hin, daß für wirtschaftswissenschaftliche Aufgabenstellungen KNN mit nur einer Zwischenschicht auszureichen scheinen, vgl. REHKUGLER/PODDIG (1992b), p. 15.

Literatur

BAILEY, D.B., D.M. THOMPSON and J.L. FEINSTEIN (1988): "Option Trading Using Neural Networks", in: HERAULT, J. and N. GIAMISASI (Eds.): "Proceedings of the International Workshop, Neural Networks and their Applications", Neuro-Nimes, November 1988, pp. 395-402.

BAUER, C. (1992): "Das Risiko von Aktienanlagen", Köln.

BODIE, Z., A. KANE and A. MARCUS (1989): "Investments", Boston (Massachussets).

CARDALIAGUET, P. and G. EUVRARD (1992): "Approximation of a Function and its Derivative with a Neural Network", Neural Networks 5, pp. 207-220.

COATS, P.K. and L.F. FANT (1992): "A Neural Network Approach to Forecasting Financial Distress", Journal of Business Forecasting 10, Winter 91/92, pp. 9-12.

CONNOR, J., L.E. ATLAS and D.R. MARTIN (1992): "Recurrent Networks and NARMA Modeling", in: MOODY, J.E., S.J. HANSON and R.P. LIPPMANN (Eds.): "Advances in Neural Information Processing Systems 4", San Mateo, California, pp. 301-308.

DOYA, K. (1993): "Universality of Fully-Connected Recurrent Neural Networks", erscheint in: IEEE Transactions on Neural Networks.

DUTTA, S. and S. SHEKHAR (1988): "Bond-Rating: A Non-Conservative Application of Neural Networks", in: Proceeding of the IEEE International Conference on Neural Networks, Vol. II, San Diego, pp. 443-450.

ELMAN, J.L. (1990): "Finding Structure in Time", Cognitive Science 14, pp. 179-211.

ERXLEBEN, K., J. BAETGE, M. FEIDICKER, H. KOCH, C. KRAUSE, und P. MERTENS (1992): "Klassifikation von Unternehmen", Zeitschrift für Betriebswirtschaft 62, pp. 1237-1262.

FINNOFF, W. and H.G. ZIMMERMANN (1991): "Detecting structure in small datasets by network fitting under complexity constraints", in: Proceedings of the 2nd Annual Workshop Computational Learning Theory and Natural Learning Systems, Berkeley 1991.

FINNOFF, W., F. HERGERT and H.G. ZIMMERMANN (1993): "Improving Model Selection by Nonconvergent Methods", Neural Networks 6, pp. 771-784.

HERTZ, J.A., A.S. KROGH and R.G. PALMER (1991): "Introduction to the Theory of Neural Computation", Redwood City, California.

HORNIK, K., M. STICHCOMBE and H. WHITE (1989): "Multilayer feedforward networks are universal approximators", Neural Networks 2, pp. 359-366.

JORDAN, M.I. (1989): "Serial order: A parallel distributed processing approach", in: ELMAN, J.L. and D.E. RUMELHART (Eds.): "Advances in Connectionist Theory: Speech".

KAMIJO, K. and T. TANIGAWA (1990): "Stock Price Recognition - A Recurrent Neural Network Approach",

Proceedings of the International Joint Conference on Neural Networks, San Diego, Vol. I, pp. 215-221.
KOSAKA, M., H. MIZUNO, T. SASAKI, R. SOMEYA and N. HAMADA (1991): "Applications of Fuzzy logic & Neural network to Securities Trading Decision Support System", Proceedings of the IEEE International Conference on Systems, Man and Cybernetics, October, pp. 1913-1918.
KRAUSE, C. (1993): "Kreditwürdigkeitsprüfung mit Neuronalen Netzen", Düsseldorf.
MORGAN, N. and H. BOURLARD (1992): "Generalization and Parameter Estimation in Feedforward Nets: Some Experiments", in: LIPPMAN, R.P., J.E. MOODY and D.S. TOURETZKY (Eds.): "Advances in Neural Information Processing Systems 3", San Mateo (California), pp. 630-637.
MOZER, M.C. (1993): "Neural Net Architectures for Temporal Sequence Processing", in: WEIGEND, A. and N. GERSHENFELD (Eds.): "Time Series Prediction - Forecasting the Future and Understanding the Past", Reading, Massachusetts, pp. 243-264.
PERRIDON, L. und M. STEINER (1993): "Finanzwirtschaft der Unternehmung", 7. Auflage, München.
REHKUGLER, H. und T. PODDIG (1992b): "Klassifikation von Jahresabschlüssen mittels Multilayer-Perceptrons - Erste Ergebnisse und weiterführende Fragestellungen", Bamberger Betriebswirtschaftliche Beiträge Nr. 87, Bamberg.
REHKUGLER, H. und T. PODDIG (1992a): "Anwendungsperspektiven und Anwendungsprobleme von Künstlichen Neuronalen Netzwerken", Information Management, 2/92, pp. 50-58.
ROMANIUK, S.G. und L.O. HALL (1990): "Decision Making on Creditworthiness Using a Fuzzy Connectionist Expert System Development Tool", International Neural Network Conference, Vol. 1, Paris, pp. 449-452.
RUMELHART, D.E., J.L. MCCLELLAND & the PDP Research Group (1986): "Parallel distributed processing", Vol. 1, Cambridge (Massachussets).
SHARPE, W.F. (1963): "A Simplified Model for Portfolio Analysis", Management Science 9, pp. 277-293.
STEINER, M. und H.G. WITTKEMPER (1993): "Neuronale Netze: Ein Hilfsmittel für betriebswirtschaftliche Probleme", in: Die Betriebswirtschaft, Jg. 53, pp. 447-463.
TAM, K.Y. and M. KIANG (1990): "Predicting Bank Failures: A Neural Network Approach", Applied Artificial Intelligence 4, Oct/Dec, pp. 265-282.
WASSERMANN, P.D. (1989): "Neural Computing - Theory and Practice", New York.