

Prognose und Handel von Öl-Future-Spreads durch Multi-Layer-Perceptrons und High-Order-Neuronalnetze mit Faun 1.1

Christoph Polus², Hans-Jörg von Mettenheim³ und Michael H. Breitner⁴



¹ Kopien oder eine PDF-Datei sind auf Anfrage erhältlich: Institut für Wirtschaftsinformatik, Leibniz Universität Hannover, Königsworther Platz 1, 30167 Hannover (www.iwi.uni-hannover.de).

² Candidatus Diplom-Ökonom, Leibniz Universität Hannover (polus@iwi.uni-hannover.de).

³ Diplom-Mathematiker, Diplom-Ökonom und Doktorand, Institut für Wirtschaftsinformatik (mettenheim@iwi.uni-hannover.de).

⁴ Professor für Wirtschaftsinformatik und Betriebswirtschaftslehre und Direktor des Instituts für Wirtschaftsinformatik (breitner@iwi.uni-hannover.de).

Inhaltsverzeichnis

ABSTRACT	
1.	EINLEITUNG2
2.	GRUNDLAGEN UND DEFINITIONEN3
2.1	DAS SPREADTRADING3
2.2	KÜNSTLICHE NEURONALE NETZE4
2.2.1	MULTI-LAYER-PERCEPTRON5
2.2.2	HIGH-ORDER-NETZWERK NACH GILES UND MAXWELL6
2.2.3	HIGH-ORDER-NETZWERK SECOND ORDER DATA DELAY.....7
3.	DER NEUROSIMULATOR FAUN 1.19
4.	ZEITREIHENPROGNOSE MIT KÜNSTLICHEN NEURONALEN NETZEN 10
5.	VERWENDETES DATENMATERIAL 11
6.	METHODOLOGIE 13
6.1	DATENVORVERARBEITUNG 13
6.2	TRAINING DER NETZE MIT FAUN 1.1..... 14
6.3	PROGNOSEZEITRAUM 15
6.4	TRADINGSTRATEGIEN UND FILTER 16
6.4.1	KORRELATIONSFILTER..... 16
6.4.2	TRANSITIV-FILTER 17
6.5	FEHLERMAßE UND RISIKOKENNZAHLEN 18
6.5.1	ROOT MEAN SQUARE ERROR 18
6.5.2	CALMAR-RATIO 18
6.5.3	SHARPE-RATIO 19
6.6	RICHTUNGSGÜTEMAßE 19
6.6.1	CORRECT DIRECTION 20
6.6.2	CORRECT DIRECTION CHANGE 20
6.6.3	LONG TERM CORRECT DIRECTION 21
7.	NETZEVALUIERUNG UND PROGNOSEDURCHFÜHRUNG 21
7.1	NETZEVALUIERUNG 21
7.2	PROGNOSE MIT MLP- UND HONN-STRUKTUREN 23

7.2.1	MLP-PROGNOSE.....	23
7.2.2	HONN- UND HONN-SODD-PROGNOSE.....	25
8.	AUSWERTUNG UND VERGLEICH DER PROGNOSEERGEBNISSE	27
8.1	BUY AND HOLD-STRATEGIE	28
8.2	KONTINUIERLICHE PORTFOLIO-OPTIMIERUNG.....	29
8.2.1	MLP-TOPOLOGIE.....	29
8.2.2	HONN-TOPOLOGIE.....	32
8.2.3	HONN-SODD-TOPOLOGIE.....	34
9.	FAZIT UND AUSBLICK	36
	QUELLENVERZEICHNIS	38
	ANHANG	40

Abstract

In der vorliegenden Arbeit wird die Prognose und der Handel eines Portfolios, bestehend aus sechs Öl-Futures-Spreads, untersucht. Für die Erstellung der Prognosen werden Neuronale Netze verwendet, welche mit Hilfe des Neurosimulators FAUN 1.1 simuliert werden. Zur Anwendung kommen die drei Topologien Multi-Layer-Perceptron, High-Order Neural Network und High-Order Neural Network mit Second Order Data Delay.

Es wird für jeden der sechs Spreads auf Basis der einzelnen Netztopologien eine Prognose erstellt. Weiterhin werden verschiedene Filtertechniken mit der Absicht implementiert, die Prognosequalität zu optimieren und die Handelsentscheidungen zu erleichtern. Abschließend werden die einzelnen Modelle gegenübergestellt und die Ergebnisse im Hinblick auf Profitabilität und Prognosegüte verglichen.

Bei Betrachtung der Ergebnisse wird deutlich, dass die High-Order-Netzarchitekturen dem Multi-Layer-Perceptron überlegen sind. Dies zeigt sich sowohl anhand der erzielbaren Renditen, als auch anhand der Prognosequalität der einzelnen Netze.

1 Einleitung

Vor allem die gestiegene Volatilität zeichnet die Entwicklung der Rohstoffmärkte der letzten zehn Jahre aus. Besonders der Markt für Rohöl und veredelte Ölprodukte spiegelt diesen Verlauf sehr anschaulich wieder. Die Gründe finden sich zum einen in der Erkenntnis der Knappheit fossiler Brennstoffe, im gestiegenen Umweltbewusstsein, der Rohstoffhausse der vergangenen fünf Jahre und nicht zuletzt durch eine gewisse Abkopplung der Finanzmärkte von der Realwirtschaft, was schließlich einer der Gründe für die anhaltende Finanz- und Wirtschaftskrise ist. Die gestiegene Schwankungsbreite an den Märkten hat einerseits ein erhöhtes Preisrisiko zur Folge, andererseits bietet der Markt durch die entstandene Bewegung aussichtsreiche Handelsmöglichkeiten. Es stellt sich die Frage, eventuelle Marktbewegungen zu identifizieren, im Zuge dessen an ihnen zu partizipieren und Handelsgewinne zu generieren.

Das vorliegende Paper geht dieser Fragestellung nach und beschäftigt sich mit dem Handel von Öl-Futures-Spreads und deren Prognose mit Hilfe von Neuronalen Netzen.

Die Motivation basiert ferner auf den Erkenntnissen von Dunis et al. (2006), „Trading Future Spread Portfolios: Application of Higher Order and Recurrent Networks“. In ihrer Arbeit beschreiben die Autoren die Modellierung und den Handel eines Portfolios bestehend aus sechs Öl-Futureskontrakten. Von diesen werden mit Hilfe verschiedener Anwendungen Prognosen erstellt und hinsichtlich ihrer Qualität und Profitabilität verglichen. Im Speziellen werden Neuronale Netze zur Prognose der Zeitreihen verwendet. Die wichtigsten sind das Multi-Layer-Perceptron und High-Order-Netzwerke. Überdies hinaus kommen verschiedene Filtertechniken mit der Intention zum Einsatz die Prognosequalität zu steigern und deutlichere Handelssignale zu liefern.

Ziel ist es nun die Prognosen und den Handelserfolg mit Futures-Spreads durch Multi-Layer-Perceptrons und High-Order-Neuronale Netze, unter Anwendung des Faun 1.1 Neurosimulators durchzuführen und die Ergebnisse zu vergleichen.

Zu Beginn werden die Grundlagen, die wichtigsten Begriffe definiert und der Neurosimulator Faun 1.1 vorgestellt. Im Anschluss wird Bezug auf das verwendete Datenmaterial und die Bearbeitungsmethodik genommen. Im darauffolgenden Abschnitt wird auf die verwendeten Prognosemodelle und die Filtermethoden eingegangen. Schließlich werden in Abschnitt sieben die Prognosen analysiert und im achten Abschnitt die Renditen der einzelnen Modelle verglichen, gefolgt von einem Fazit und Ausblick. Weiterhin wird angenommen, dass der Leser dieser Arbeit mit den Grundkenntnissen des Wertpapier- und Terminhandels sowie Neuronaler Netze vertraut ist. Eine vollständige Ausführung würde den Rahmen dieser Arbeit sprengen. In den betreffenden Kapiteln wird zudem auf weiterführende Literatur verwiesen.

2 Grundlagen und Definitionen

2.1 Das Spreadtrading

Der Handel von Öl wird fast ausschließlich über die Futuresmärkte getätigt. Lediglich ein bis drei Prozent der gehandelten Kontrakte führen zu einer physischen Lieferung.⁵ Besonders der Markt für Futureskontrakte ist im Gegensatz zum Spotmarkt für den Handel geeignet, da dieser neben weiteren Vorteilen einen sehr hohen Grad an Liquidität aufweist.

Die konventionelle Variante an einer Preisänderung am Ölmarkt zu partizipieren ist Long auf eine Preissteigerung oder Short auf einen Preisverfall zu spekulieren und die Kontrakte vor dem Verfallszeitpunkt glattzustellen. Dieses Vorgehen birgt jedoch ein hohes Preisrisiko, da die Möglichkeit besteht, sich auf der „falschen“ Marktseite positioniert zu haben und der Kurs in die entgegengesetzte Richtung tendiert.

Das Spread-Trading stellt eine Alternative des Handels von Futureskontrakten dar. Nach Ross ist ein Spread wie folgt definiert. "...the sale of one or more futures contracts and the purchase of one or more offsetting futures contracts."⁶ Demnach die Differenz zwischen zwei artverwandten Finanzwerten, die sich hinsichtlich einer oder mehrerer Eigenschaft unterscheiden. Die Ausprägung der unterscheidenden Eigenschaft determiniert wiederum auch die Art des Spreads. Werden beispielsweise zwei Futurekontrakte auf das gleiche Underlying betrachtet, die jedoch unterschiedliche Liefermonate aufweisen, handelt es sich um einen Intramarketspread. Ist wiederum der Liefermonat und Underlying identisch und die Kontrakte werden an verschiedenen Börsen gehandelt, wird von einem Interbörsenspread gesprochen. Als Intermarketspread wird schließlich die Differenz zweier Kontrakte mit unterschiedlichem Underlying bezeichnet. Der Spread-Trader platziert sich zwischen Hedgern und Spekulanten in dem er Long auf der einen Seite und Short auf der gegenübergestellten Seite des Spreads positioniert ist. Er handelt somit die Preisdifferenz der jeweiligen Werte und kombiniert Vor- und Nachteile beider Marktseiten. Zum einen wird das Preisrisiko, verglichen zur Spekulation, deutlich gemindert und damit gehen ebenfalls reduzierte Marginkosten einher, die aus der Risikoneutralisation der beiden Kontrakte resultiert. Andererseits ist die Rendite auf die maximale Veränderung der Kursdifferenz beschränkt und zudem fallen durch den Kauf zweier Kontrakte höhere Transaktionskosten an. Für eine nähere und weiterführende Betrachtung des Futures- und Spreadhandels wird auf die angegebene Literatur verwiesen.⁷

⁵ CFTC Staff-Report September 2008

⁶ Vgl. www.spread-trading.com/what-is-spread-trading.htm

⁷ Vgl. Melamed (1981), vgl. wissen.godmode-trader.de – was sind Spreads, vgl. www.spread-trading.com/what-is-spread-trading.htm, vgl. Hull, J. C. (2005)

2.2 Künstliche Neuronale Netze

Bei Künstlichen Neuronalen Netzen handelt es sich um informationsverarbeitende Systeme, die in ihrer Grundstruktur biologischen Nervensystemen nachempfunden sind. Es ist nicht das Ziel den Aufbau und die Funktionsweise eines Gehirns nachzubilden, sondern erfolgreiche Funktionalitäten biologischer Neuronalnetze zu nutzen.

Analog zum biologischen Vorbild bestehen KNN aus vielen einzelnen Neuronen, welche untereinander durch gerichtete und gewichtete Verbindungen vernetzt sind durch die eine Informationsverarbeitung stattfinden kann. Aus mathematischer Sichtweise wird ein Neuron j durch einen variablen Aktivierungszustand $a_j(t)$ zum Zeitpunkt t definiert.⁸ Der Aktivierungszustand wird meist durch eine nichtlineare Aktivierungsfunktion wie den Tangens Hyperbolicus ausgegeben. Ein Blick auf die nachstehende Abbildung zeigt, dass speziell für den Tangens Hyperbolicus eine Neuronenausgabe im Intervall $-1;+1$ erfolgt. Die Verwendung des Tangens Hyperbolicus bietet sich zum einen auf Grund seines Wertebereichs für die Finanzzeitreihenprognose an, da Zeiträume mit negativer Rendite genau so wahrscheinlich sind wie positive Rendite und diese optimal abgebildet werden können. Zum anderen bietet der Funktionstyp einige weitere Vorteile wie zum Beispiel die Eigenschaften der Ableitung, welche notwendig für den Lernprozess des Neuronalen Netzes sind.




Abbildung 1: Tangens Hyperbolicus

$$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}; \mathbb{D} = \{x \in \mathbb{R} : -10 \leq x \leq 10\} \quad (1)$$

Die Verbindung zwischen zwei Neuronen wird durch eine weitere Variable w_{ij} repräsentiert, die auch als Gewicht von Neuron i nach Neuron j bezeichnet wird. Das Gewicht gibt die Stärke der Verbindung zwischen zwei Nervenzellen an. Verbindungen mit einem großen Gewichtswert sind demnach wichtiger zur Abbildung einer bestimmten Struktur als Verbindungen mit geringeren Gewichtswerten. Ein neuronales Netz kann somit auch als ein gerichteter und gewichte-

⁸ Vgl. Breitner (2003)

ter Graph bezeichnet werden. Auf Grund dieser Konstruktion ist es möglich, durch KNN sehr komplexe Eingabe- Ausgabe-Relationen abzubilden.

Die Vielzahl von Neuronen eines Neuronalen Netzes werden in der Regel in getrennten Schichten angeordnet und anhand einer vorgegebenen Struktur untereinander verbunden. Bei den Schichten eines KNN unterscheidet man zwischen Inputschicht, verborgener Schicht und Outputschicht.

Die Neuronen der Inputschicht dienen als Schnittstelle für die Inputdaten des KNN. Da es für jede Inputgröße ein eigenes Input-Neuron geben muss, ist durch die Dimension des Eingabevektors auch die Anzahl der in der Inputschicht befindlichen Neuronen festgelegt. Die einzelnen Datenmuster der zu approximierenden Problemstruktur werden an den Input-Neuron angelegt. Diese leiten die Signale an alle direkt verbundenen Neuronen weiter. Dementsprechend erzeugen die Neuronen der Outputschicht, den Output des KNN. Jedes Output-Neuron erzeugt dabei einen eigenen Wert. Die Anzahl der Output-Neuronen wird folglich durch die erforderliche Anzahl an Outputsignalen determiniert. Die eigentliche Informationsverarbeitung findet in den verborgenen Schichten statt. Hierbei handelt es sich um eine beliebige Anzahl von Schichten, die zwischen der Input- und der Outputschicht angeordnet werden. Die Anzahl der verborgenen Schichten sowie die Anzahl der Neuronen jeder dieser Schichten sind dabei freie Parameter eines neuronalen Netzes und werden der Komplexität eines Optimierungsproblems jeweils angepasst.

2.2.1 Multi-Layer Perceptron (MLP)

Bei Multi-Layer Perceptrons (MLP) handelt es sich um ein sogenanntes Feedforward-Netz mit mindestens einer verborgenen Schicht. Feedforward bedeutet hier, dass keine Rückkopplungen zwischen den einzelnen Neuronen-schichten vorhanden sind sondern lediglich Verbindungen in Richtung Output-schicht bestehen. Dieser Netztyp wird oftmals als das Standardnetz angesehen. Meist besteht ein MLP aus drei maximal vier Schichten. Der Input-, einer oder zwei Hidden- und der Outputschicht. Die Anzahl der Neuronen in der Hiddenschicht sind maßgeblich für die Komplexität eines Problems mit der ein Neuronales Netz konfrontiert werden kann. Zusätzlich enthalten die Input- und Hiddenschicht ein Bias-Neuron. Dieses erleichtert die Arbeit mit einem neuronalen Netzwerk signifikant, da es mit einer konstanten Ausgabe von 0,5 den Schwellenwert θ eines jeden Neurons ersetzt und dieser nicht immer für jedes Neuron explizit eingegeben werden muss.⁹

⁹ Vgl. Breitner (2003)

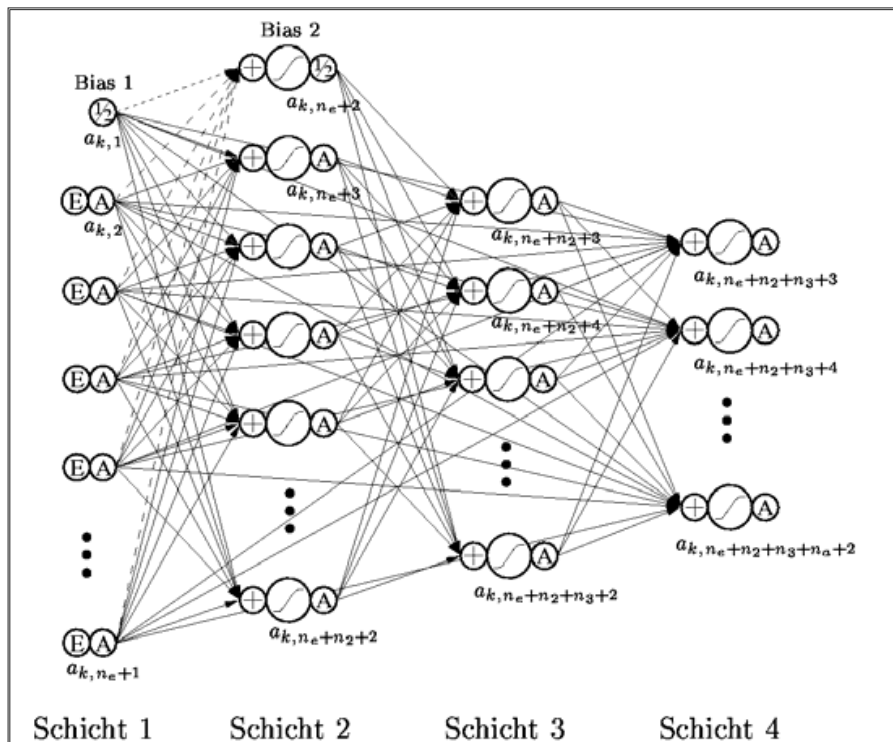


Abbildung 2: vierlagiges Perzeptron mit Shortcutverbindungen
 Quelle: Breitner (2003)

2.2.2 High-Order-Netzwerke nach Giles und Maxwell (HONN)

High-Order-Neuronalnetze (im weiteren Verlauf HONN) werden auf die Arbeit von Giles und Maxwell (1987) zurückgeführt und sind auch als sogenannte „Tensor-Netze“ bekannt. Die Besonderheit von High-Order-Netzen ist die modifizierte Inputstruktur. Dies wird an einem Beispiel der Zeitreihenprognose sehr deutlich. Werden der Gegenwartswert x_t und die beiden Vergangenheitswerte x_{t-1} , x_{t-2} einer Reihe herangezogen, um den zukünftigen Wert x_{t+1} zu bestimmen, gehen diese nicht nur als Einzeleingaben wie beim MLP in die Prognose ein, sondern werden diese miteinander multipliziert, sodass bei einem Netzwerk zweiter Ordnung aus drei Datenpunkten sechs Inputgrößen resultieren. Dies wird anhand der folgenden Abbildung deutlich.

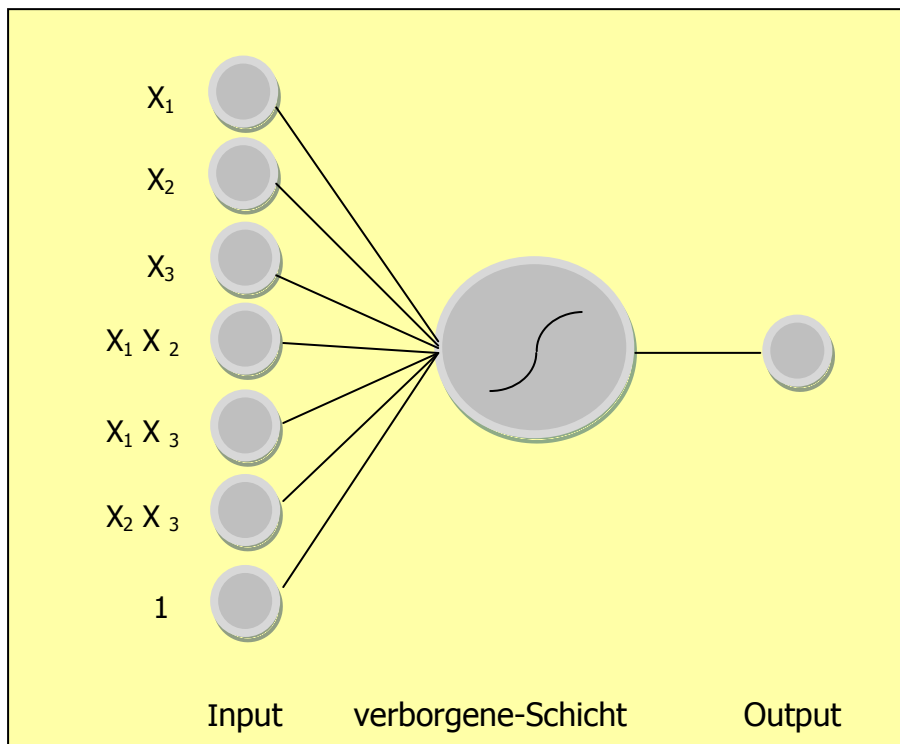


Abbildung 3: High-Order-Netzwerk

Desweiteren nutzen High-Order-Netze eine gemeinsame Aktivierungsfunktion, was die Anzahl der anfangs frei zu wählenden Gewichte reduziert und somit das Training des Netzes beschleunigt. Die Zeitersparnis hängt jedoch auch vom Grad der Ordnung eines Netzes und der Anzahl der eingehenden Zeitreihenwerte ab, da die zu verarbeitende Datenmenge mit der Erhöhung beider Größen stetig wächst. Aus diesem Grund finden Netze mit vierter Ordnung oder höher wenig Anwendung.¹⁰ Ein weiterer Vorteil der durch die Reduktion von Gewichten entsteht, ist die Vermeidung eines Overfittings des Netzes. Dies bedeutet, dass sich das Netz hervorragend an die Trainingsmuster anpasst, jedoch bei unbekanntem Strukturen sehr schlechte Ergebnisse liefert. Weiterhin sind die verwendeten Funktionen des HONN identisch mit denen des MLPs. Dies dient auch der Vergleichbarkeit beider Modelle.

2.2.3 HONN mit modifiziertem Trainingsdateninput- (HONN-SODD)

Ergänzend zu den Prognosemodellen aus Dunis et. al. (2006) soll zuletzt eine High-Order-Netzstruktur mit modifiziertem Trainingsansatz nach Breitner et al. verwendet werden. Die Topologie des Netzes ist mit der aus Abschnitt 2.2.2 identisch. Der Unterschied besteht in der Eingabestruktur der Trainings- und Validierungsdaten. Während das HONN nach Giles und Maxwell die multiplizierten Trainingsdaten „blockweise“ verarbeitet, werden diese bei der modifizierten Variante dem Netz mit einem sogenannten Sliding-Window präsentiert. Die folgende Abbildung soll diese Technik verdeutlichen.

¹⁰ Knowels et al. (2005)

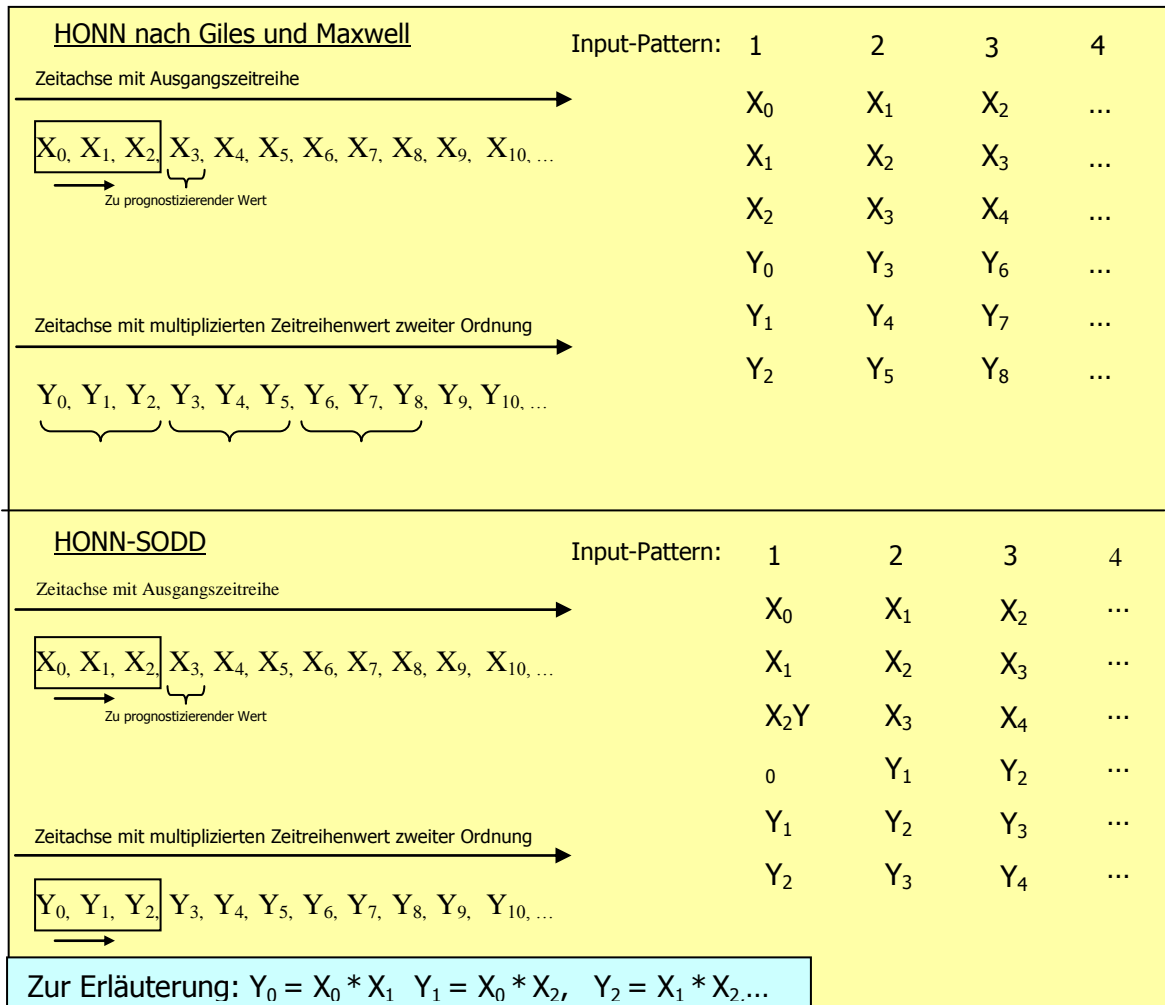


Abbildung 4: High-Order-Netzwerk mit Second Order Data Delay

Auf der linken Seite der Abbildung sind die Zeitreihendaten in der Ursprungs- und in multiplizierter Form jeweils auf zwei Zeitachsen für jeden Netztyp abgetragen. Die rechte Seite zeigt die letztendlichen Input-Muster für das Training der High-Order-Netze, die aus der Kombination der jeweiligen Datenpunkte bei der Zeitreihen hervorgehen. Der Unterschied zwischen beiden Ansätzen wird bei der Betrachtung der Zeitachsen mit den multiplizierten Zeitreihenwerten deutlich.

Während im Modell nach Giles und Maxwell die Zeitreihendaten höherer Ordnung in vordefinierten, drei-Werte-umfassenden Datenblöcken in das Netztraining einfließen, werden die Daten im modifizierten Ansatz mit Hilfe eines Sliding Windows, welches pro Input Pattern einen Datenpunkt in der Zeitreihe voranschreitet, erfasst und dem Netz präsentiert. Die Daten höherer Ordnung werden auf diese Weise, im Gegensatz zur üblichen HONN-Datenaufbereitung, während des Trainings, verzögert eingelesen. Daher die Bezeichnung HONN-Second-Order-Data-Delay (HONN-SODD). Die Anwendung dieser Technik hat die Absicht, dem Netz ein längeres „Datengedächtnis“ anzutrainieren und auf diese Weise eine robustere Generalisierungsfähigkeit zu erzielen.

3 Der Neurosimulator Faun 1.1

FAUN 1.1¹¹ ist ein Neurosimulationsprogramm, welches in der Lage ist durch überwachtes Lernen künstliche Neuronale Netze zu trainieren und somit Lösungen für nichtlineare Probleme zu approximieren. Überwachtes Lernen bedeutet, dass Ein-/Ausgabezusammenhänge mit Input und Soll-Output, aus einem Musterdatensatz gegeben sind, für die eine „möglichst gute Approximationsfunktion berechnet werden soll. Dabei müssen die Muster problemgerecht auf den Trainingsdatensatz und den Validierungsdatensatz aufgeteilt werden. Weiterhin wird der Berechnungsvorgang beaufsichtigt und bei Abweichungen vom gewünschten Ergebnis modifiziert.

Die Auswahl einer geeigneten neuronalen Netztopologie ist problemspezifisch. Die zur Verfügung stehenden Netztypen von FAUN sind drei- und vierlagige Perceptrons oder Radial-Basis-Netze unter Verwendung der Transferfunktion Tangens Hyperbolicus und optional mit oder ohne Direktverbindungen. Unter Direktverbindungen werden Verknüpfungen zwischen der Eingabeschicht und der Ausgabeschicht verstanden, welche die Approximation von linearen Abhängigkeiten in den Ein- und Ausgabezusammenhängen erleichtern und in den meisten Fällen die Prognosequalität erhöhen. Damit die Abbildung von linearen Einflüssen gewährleistet ist, muss die Aktivierungsfunktion in der Outputschicht die Identität oder eine andere lineare Funktion sein. FAUN trainiert Netze sehr schnell und konvergiert, durch eine globale Optimierung, sehr zuverlässig.¹²

Weiterhin ist die Implementierung eines mathematisch definierten Trainingsstoppkriteriums von sehr großem Nutzen. Auf diese Weise unterliegt der Trainingsabbruch von Netzstrukturen zum einen keinen subjektiven Einflüssen, das Training muss nicht manuell unterbrochen werden und zudem wird ein optimaler Stoppzeitpunkt bestimmt. FAUN 1.1 kann entweder über eine graphische Benutzeroberfläche unter Microsoft Windows und LINUX oder direkt über die jeweilige Shell ausgeführt werden. Ferner bietet die grafische Benutzeroberfläche diverse Kennzahlendiagramme durch die das Training der neuronalen Netze in Echtzeit gesteuert und überwacht werden kann. Schließlich ist es möglich die erfolgreich trainierten Netze auszuwählen und durch Bereitstellung des Quellcodes verschiedenster Programmiersprachen zu exportieren und zu evaluieren.

¹¹ Vgl. Faun Entwicklungsteam Urversion 0.1 1996 Michael H. Breitner

¹² Vgl. Breitner (2003)

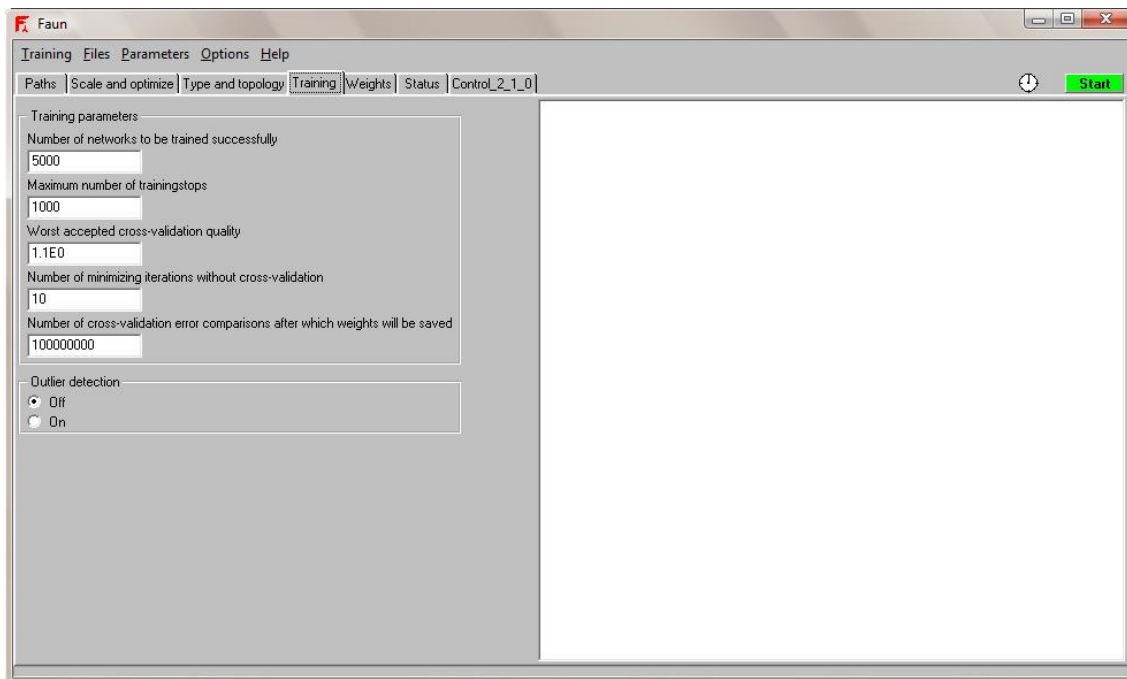


Abbildung 5: Faun-GUI, Eingabefenster für Trainingsparameter

4 Zeitreihenprognose mittels Künstlicher Neuronaler Netze

Eine genaue Vorhersage der Zukunft ist wohl in den meisten Fällen nicht möglich, jedoch kann durch die Anwendung verschiedenster, meist statistischer, Verfahren die Entwicklungen zumindest einigermaßen genau prognostiziert werden. Bei der Erstellung von Prognosen auf mathematischer Basis werden üblicherweise Vergangenheitswerte einer Zeitreihe genutzt, um aus ihnen Rückschlüsse auf die zukünftigen Werte der Reihe zu ziehen. Diese Vorgehensweise wird von Künstlichen Neuronalen Netzen ebenfalls aufgegriffen, welche seit den sechziger Jahren¹³ zunehmend für die Prognose von Zeitreihen eingesetzt werden und sich als ebenbürtige Konkurrenz zu den etablierten statistischen Verfahren, wie beispielsweise ARMA und ARIMA-Modelle entwickelt haben. Jedoch existiert beim Einsatz von KNN zur Prognose von Zeitreihen keine einheitliche Vorgehensweise, welche in jeder Hinsicht überlegen scheint. Stattdessen werden die einzelnen Methoden oft beliebig ausgewählt und die Parameter der jeweiligen Methoden in der Regel jedes Mal neu durch einen mehr oder weniger aufwändigen „Trial and Error“-Prozess bestimmt.

Es gibt einige Argumente, die für den Einsatz von KNN zur Prognose von Zeitreihen sprechen. Dabei handelt es sich insbesondere um Eigenschaften, die KNN generell charakterisieren und sich zudem positiv auf die Prognose auswirken. KNN sind Funktionsapproximatoren, die jede stetige Funktion zu einem gewissen Grad nachbilden können. Durch nichtlineare Aktivierungsfunktionen können Neuronale Netze zudem nichtlineare Relationen abbilden, die die zu prognostizierenden Zeitreihen oftmals bestimmen. Desweiteren können Neuronale Netze sehr universell eingesetzt werden, da sie keine spezifischen Informa-

¹³ Zhang, Patuwo, Hu, (1998)

tionen, Verteilungsannahmen und keine formalen Spezifikationen benötigen. Weiterhin ist es möglich, das Training während der eigentlichen Prognose fortzuführen um so die sich über den Zeitablauf ändernden Zusammenhänge abzubilden. Zudem ist der Umgang mit verrauschten Datenstrukturen für Neuronale Netze unproblematisch, was bei den meisten Zeitreihen notwendig ist.

Andererseits gibt es jedoch auch einige Nachteile, die gegen eine Verwendung von KNN sprechen oder diese nur bedingt empfehlen. Der Trainingsvorgang eines neuronalen Netzes stellt generell einen sehr zeitaufwändiges Verfahren dar. Die Implementierung bekannter Zusammenhänge ist im Voraus nicht möglich. Ferner gestaltet sich die Ableitung der zu Grunde liegenden kausalen Zusammenhänge aus einem trainierten Netz, welche die resultierende Abbildung ergeben, als sehr schwierig (Black-Box-Ansatz). Neben der Tatsache, dass bereits viele Parameter eines KNN durch die jeweilige Anwendungssituation determiniert werden, gibt es immer eine Vielzahl von weiteren Parametern, die noch festgelegt werden müssen. Überwiegend gibt es für die Bestimmung dieser Werte meist keine Heuristiken, und somit kann deren Ermittlung einen zeitaufwändigen Prozess darstellen. Nichtsdestotrotz überwiegen die Vorteile bei der Zeitreihenprognose neuronale Netze einzusetzen und zudem besteht immer die Chance, mit einem optimal spezifizierten Netz Prognosen von einer beachtlichen Güte zu erstellen. Es sollte also bei der Wahl einer Methodik zur Prognose von Zeitreihen die Anwendung von neuronalen Netzen grundsätzlich in Betracht gezogen werden.

5 Verwendetes Datenmaterial

Bei den zu prognostizierenden Zeitreihen handelt es sich um Spreads, gebildet aus Öl-Futureskontrakten. Der Untersuchungszeitraum wurde von 01.01.1995 – 03.01.2005 in Anlehnung an die Arbeit von Dunis et al. gewählt, um eine Vergleichbarkeit der Ergebnisse zu gewährleisten. Die Daten wurden zum einen von dem Online-Anbieter Datastream¹⁴ und zum überwiegenden Teil aus der Datenbank der Energy – Information- Administration (EIA)¹⁵ bezogen, welche über die Homepage der Institution zugänglich ist. Bis auf den WTI und Brent Futureskontrakt sind keine weiteren Datenreihen über Datastream zugänglich gewesen. Ein Unterschied beider Quellen findet sich in der Anzahl der Börsentage pro Jahr. Während Dunis et al. Datenreihen mit 261 Börsentagen pro Jahr verwenden, enthalten die Zeitreihen der EIA lediglich 251 Börsentage. Für das weitere Vorgehen wurden alle Zeitreihen auf 251 Börsentage normiert. Zudem ist wichtig, dass die einzelnen Futureskontrakte in einheitlicher Währung vorliegen und dass die Feststellung der einzelnen Tageskurse zur selben Uhrzeit geschieht, oder ein Tagesmittelwert vorliegt. Es werden vier Futureswerte herangezogen und daraus sechs Spreads gebildet. Aus diesen wird ein Portfolio erstellt in welches jeder Spread mit einer Gewichtung von 1/6 eingeht. In der

¹⁴ www.thomsonreuters.com

¹⁵ www.EIA.doe.gov/

nachstehenden Tabelle sind die verwendeten Underlyings der Terminkontrakte dargestellt.

Futurekontrakt	Währung	Handelsplatz
WTI Crude	US\$	NYMEX
Brent Crude	US\$	IPE
Unleaded Gasoline	US\$	NYMEX
Heating Oil	US\$	NYMEX

Tabelle 1: Futureskontrakte

Aus den Zeitreihen der obenstehenden Futuresreihen werden nun folgende Spreads gebildet:

Brent Crude	Vs.	WTI Crude
Brent Crude	Vs.	Unleaded Gasoline
Brent Crude	Vs.	Heating Oil
WTI Crude	Vs.	Unleaded Gasoline
WTI Crude	Vs.	Heating Oil
Unleaded Gasoline	Vs.	Heating Oil

Ferner muss ein weiteres Kriterium beim Handel von Futureskontrakten beachtet werden. Bei einem Futures handelt es sich um eine nichtkontinuierliche Zeitreihe, da dieser zu einem festgelegten Fälligkeitsdatum verfällt. Betrachtet man einen langfristig orientierten Investor, muss dieser nun in den nächstliegenden Kontrakt investieren. Dieser Vorgang wird als sogenanntes Rollen der Verträge bezeichnet. Die Problematik die dabei entsteht ist, dass die Kontrakte eines Spreads mit unterschiedlichen Fälligkeitszeitpunkten auch eine unerwünschte Preisrelation aufweisen. Dieser Effekt ist auf die Cost of Carry (Verfügbarkeitsrente) zurückzuführen. Die sich mehr oder weniger auf den Kurs eines Futures auswirken. Je nachdem wie sich das Verhältnis von Angebot und Nachfrage zum Fälligkeitszeitpunkt einstellt.

Um den Einfluss dieses Effekts hinreichend zu mindern ist es wichtig beide Kontrakte eines Spreads zum selben Zeitpunkt zu rollen. Weiterhin ist es sinnvoll zwei Underlyings zu wählen, die annähernd identische Cost of Carry aufweisen. Auf diese Weise heben sich diese bei der Bildung des Spreads nahezu auf. Weiterhin müssen bei der Berechnung der erwirtschafteten Renditen durch das Trading eines Spreads die Transaktionskosten abgezogen werden. Bei den Transaktionskosten handelt es sich um die Geld/Brief-Spanne, also der Differenz zwischen Nachfragepreis des Marktes und Angebotspreis des Verkäufers eines Wertpapiers. Dieser Kostenfaktor tritt beim Spreadtrading, durch den Kauf beziehungsweise Verkauf zweier Kontrakte, doppelt auf. Diese sogenannten Roundtrip-Kosten ergeben sich durch Addition der Transaktionskosten der jeweiligen Futureskontrakte mit denen eine Spreadposition eingegangen wird

Transaktionskosten pro Kontrakt	
WTI Crude	0,0960%
Brent Crude	0,0560%
Unleaded Gasoline	0,1004%
Heating Oil	0,001241

Tabelle 2: Transaktionskosten, Quelle: www.sucden.co.uk

Transaktionskosten pro Roundtrip	
Brent-Gasoline	0,16%
Brent-Heating Oil	0,18%
Brent-WTI	0,15%
Gasoline-Heating Oil	0,22%
WTI-Gasoline	0,20%
WTI-Heating Oil	0,22%

Tabelle 3: Transaktionskosten pro Roundtrip, Quelle: www.sucden.co.uk

6 Methodologie

6.1 Datenvorverarbeitung

Bevor das Training der neuronalen Netze begonnen werden kann, sind die Input-Daten in geeigneter Weise aufzubereiten. Die Wahl der Vorverarbeitungsmaßnahmen ist einer der wichtigsten Schritte bei der Erstellung von Prognosen, da diese unmittelbar Einfluss auf den benötigten Zeitaufwand des Trainings, die Konvergenz bei der Fehlerminimierung und nicht zuletzt auf die Qualität der Prognose selbst ausüben. Von Bedeutung sind hier vor allem Methoden zur Trendbereinigung bzw. Stationarisierung der Zeitreihe sowie Eliminierung von Ausreißern und Varianzheterogenität. Ebenfalls führt auch Thiesing an, dass die Eingabe der Rohdaten bei Zeitreihen mit signifikanter Trendbehaftung zu einer schlechten Performance führt, weshalb zumindest eine Trendbereinigung als vorverarbeitende Maßnahme der Eingabedaten anzuwenden ist.¹⁶

¹⁶ Vgl. Thiesing (1998)

Als Inputmuster eignet sich besonders die prozentuale Änderung der Zeitreihe, da ein neuronales Netz die relativen Änderungen besser verarbeiten kann als Absolutwerte¹⁷, zudem die Zeitreihe ebenfalls trendbereinigt wird und um Null schwankt. Infolgedessen ist es zudem möglich auf direkte Weise die annualisierten Renditen zu bestimmen und eine gute Vergleichsbasis der verwendeten Handelsmodelle zu generieren. Der Spread berechnet sich wie folgt:

$$Rendite_{Spread} = \left[\frac{Kontrakt_{1,t} - Kontrakt_{1,t-1}}{Kontrakt_{1,t-1}} \right] - \left[\frac{Kontrakt_{2,t} - Kontrakt_{2,t-1}}{Kontrakt_{2,t-1}} \right] \quad (2)$$

Zur Trendbereinigung und Glättung der Daten wurde letztendlich ein gleitender Durchschnitt von 15 Tagen der ursprünglichen Futureszeitreihen gewählt.

6.2 Training der Netze mit FAUN 1.1

Das Training der Netze ist neben der Vorverarbeitung der Inputdaten die zweite Komponente, die für eine erfolgreiche Prognose von hoher Bedeutung ist.

Zunächst ist es erforderlich den zu Grunde gelegten Beobachtungszeitraum in einen Interpolations- und Extrapolationsbereich aufzugliedern. Der Interpolationsbereich wird weiterhin in die zwei Kategorien Trainings- und Validierungsdaten unterteilt mit Hilfe derer die Netzkalibrierung vorgenommen wird. Anhand des Extrapolationsbereichs wird die Generalisierungsfähigkeit des so konfigurierten Netzes getestet. Diese Maßnahme dient vor allem der Anpassungsfähigkeit des Netzes an die Datenstruktur und verhindert durch ein definiertes Trainingsabbruchkriterium eine mögliche Überanpassung an den Musterdatensatz. In diesem Fall speichert das Netz die Trainingsmuster vollständig in den Gewichten und lernt die Werte „auswendig“. Dadurch ist das Netz zwar in der Lage die Trainingsdaten korrekt wiederzugeben, liefert jedoch bei unbekanntem Daten eine schlechte Performance.

Im Gegenteil dazu ist die Generalisierungsfähigkeit zu erwähnen, bei der das neuronale Netz wiederkehrende Muster speichert und auf diese Weise auch bei unbekanntem Daten eine gute Performance liefert. Offensichtlich stehen diese beiden Eigenschaften meist konträr zueinander. Daher ist es wichtig, nicht nur eine gute Performance auf den Trainingsdaten zu erzielen, sondern auch die Generalisierungsfähigkeit des Netzes für unbekannte Muster zu optimieren. Dazu werden dem Trainingsbereich ca. 70 Prozent und dem Validierungs- bzw. Generalisierungsbereich jeweils 15 Prozent der Zeitreihenwerte zugeteilt.

Eine weitere notwendig Modifizierung der Daten ist die Skalierung auf den vorgegebenen Wertebereich der Transferfunktion Tangens Hyperbolicus. Während der Wertebereich der Eingabedaten unbegrenzt ist, ist die Ausgabe des Netzes auf das Intervall [-1, +1] beschränkt (siehe Abbildung 1 auf Seite 4). Daher müssen die Ausgabemuster geeignet skaliert werden. Es empfiehlt sich jedoch eine genauere Anpassung auf die Grenzen [-0.95, +0.95], da die hier verwen-

¹⁷ htw-dresden.de/~iwe/Belege/Elsner/Zeitreihenanalyse.pdf

dete Transferfunktion im Bereich der Ränder stark an Sensitivität verliert. Dies dient ebenfalls dazu Ausreißern die Gewichtung zu nehmen.

6.3 Prognosezeitraum

Zur Erstellung einer Zeitreihenprognose mit Hilfe von Künstlichen Neuronalen Netzen ist es, wie bereits erwähnt, notwendig den Untersuchungszeitraum in einen Trainings- Validierungs- und Generalisierungsabschnitt zu untergliedern. Die Trainings- und Validierungszeiträume dienen als In-Sample-Daten zur Erstellung einer gut approximierenden und verallgemeinernden Netzstruktur. Mit den sogenannten Out-of-Sample-Daten, dem Generalisierungsdatensatz, wird überprüft, ob diese Eigenschaften auch tatsächlich vorliegen. Der verwendete Untersuchungszeitraum enthält 2501 auf Tagesschlusskurs basierende Zeitreihenwerte der einzelnen Futureskontrakte. Folglich wurden 250 Handelstage pro Jahr betrachtet. In der nachstehenden Tabelle ist die Untergliederung des Datensatzes in die einzelnen Teilabschnitte ersichtlich.

Die Prognose der Zeitreihe basiert auf Vergangenheitswerten. Dunis et al. verwenden den tagesaktuellen und neun Vergangenheitswerte, $x_t - x_{t-9}$, zur Prognose des zukünftigen Wertes x_{t+1} .

Um mit FAUN das Training der Netze beginnen zu können, müssen die Daten dem Programm in bestimmten Mustern präsentiert werden. Durch die festgelegte Lag-Struktur ergeben sich die folgenden Anzahlen an Lernmustern. Die MLP-Netze werden 167 Muster für das Training 42 für die Validierung und bei den HO-Netzen 1941 Trainings- und 483 Validierungsmuster verwendet. In der nachfolgenden Tabelle sind nochmals alle relevanten Zeiträume abgetragen.

Datensatz	Funktion	Zeithorizont	Datenpunkte
Training	Modellinitialisierung und Optimierung	03.01.95 - 23.08.01	1667
Validierung	Modelloptimierung	24.08.01 - 01.05.03	417
Generalisierung	Test des Modells	02.05.03 - 03.01.05	417

Tabelle 4: Datensätze

6.4 Tradingstrategien und Filter

Um Handelssignale und somit Entscheidungen über einen Ein- oder Ausstieg exakter bestimmen zu können, werden die Netzausgaben zusätzlich mit speziellen Filtermethoden bearbeitet. Im Anschluss soll ein Performancevergleich und Evaluation der ungefilterten und der gefilterten Netzausgaben stattfinden. Im Folgenden werden die verwendeten Filtermethoden vorgestellt.

6.4.1 Korrelationsfilter

Der von Dunis et al.¹⁸ gezeigte Korrelationsfilter generiert Handelsentscheidungen anhand der sinkenden Korrelation zwischen zwei Futureskontrakten, die zur Bildung eines Spreads herangezogen werden.

Die Minderung der Korrelation ist ein Zeichen für eine sinkende, gegenseitige Abhängigkeit der Futureskontrakte. Ist beispielsweise die Korrelation zwischen zwei bestimmten Zeitreihen sehr hoch, das heißt ein Wert in der Nähe von eins, ist dies ein Nachweis dafür, dass die Bewegung der einen Zeitreihen mit derselben Bewegung der anderen Reihe einhergeht. Schwankt die Korrelation um Null, verhalten sich die beiden Reihen sehr wahrscheinlich unabhängig voneinander. Bei einem negativen Wert nahe minus eins, ist von einem gegensätzlichen Verhalten auszugehen.

Die Intention des Korrelationsfilters ist, dass durch die sinkende Korrelation mehr Bewegung im Markt entsteht und sich die Differenz der Futurekontrakte vorteilhaft verringert oder vergrößert. Je nachdem, welche Position am Markt eingenommen werden soll. Der Korrelationsfilter wird durch eine gleitende 30-Tage-Korrelation der betreffenden Kontrakte eines Spreads gebildet. Ziel ist die Netzausgaben mit diesem Filter zu optimieren, um eventuell deutlichere und profitablere Handelsentscheidungen treffen zu können. Die Vorgehensweise des Korrelationsfilters ist in der nachstehenden Abbildung verdeutlicht.

Gezeigt wird der Verlauf eines Spreads und die Korrelation der beiden dazugehörigen Futureskontrakte. Es erfolgt ein Markteinstieg einen Tag nachdem die Korrelation gefallen ist. Diese Position wird so lange gehalten, bis die Korrelation wieder ansteigt. Einen Tag nach Anstieg der Korrelation wird die Position glattgestellt. Optional legt ein Grenzwert fest, wie streng dieser Filter angewendet wird. Der Grenzwert kann beispielsweise bei 0.5 gesetzt werden. Folglich ist erst in den Markt einzusteigen, wenn die Korrelation unter 0.5 fällt.

¹⁸ Dunis et al. (2005)

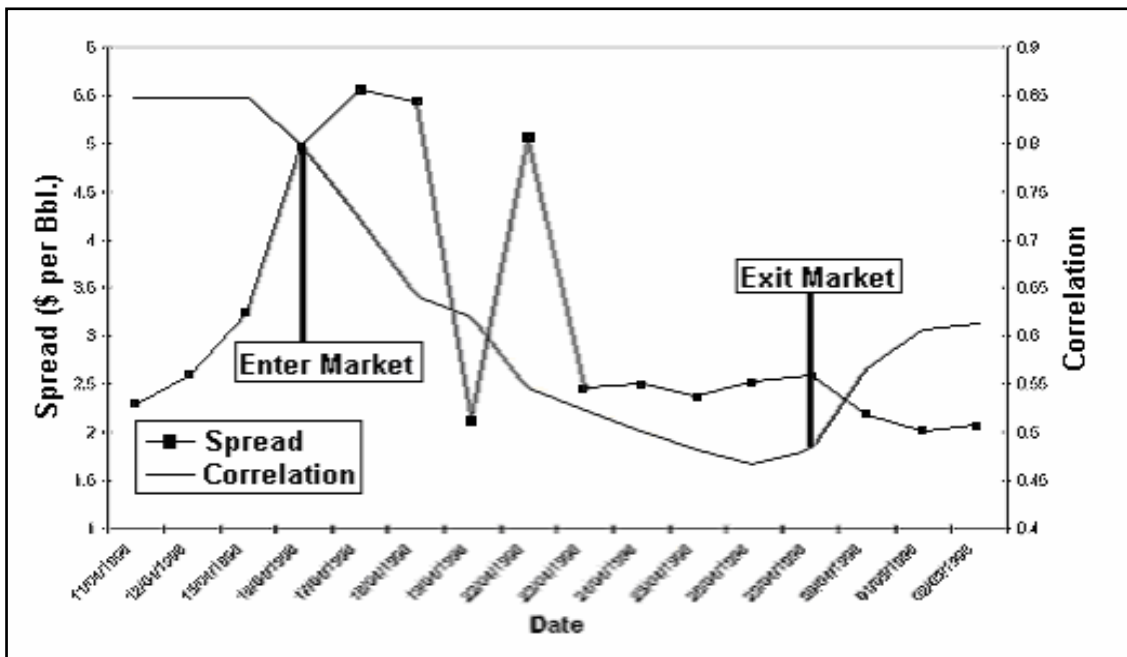


Abbildung 6: Korrelationsfilter, Quelle: Dunis et al.

6.4.2 Transitiv Filter

Der Transitiv-Filter geht auf die Arbeit von Guégan und Huck¹⁹ zurück. Dieser Filter unterscheidet zwischen sogenannten konsistenten oder inkonsistenten Prognosen eines Futures-Spreads. Das bedeutet in diesem Fall, dass ein Spread als konsistent gilt, wenn die Prognose des Futureskontrakts der einen Seite des Spreads höher ausfällt als alle anderen möglichen Prognosen der Kontrakte mit denen ein Spread gebildet werden kann. Zudem muss gelten, dass die Prognose des Futureskontrakts der Gegenseite des Spreads die geringste Performance im Vergleich zu allen anderen betrachteten Kontrakten aufweist. Treffen diese Merkmale nicht zu, gilt die Prognose des Spreads als inkonsistent. Das folgende Beispiel und Abbildung (7) sollen diesen Zusammenhang näher veranschaulichen.

Gegeben sind die prognostizierten Werte von Spreadpositionen zu einem beliebigen Zeitpunkt t , welche aus den Futureskontrakten A, B und C gebildet werden. Hat die Prognose nun zum Ergebnis, dass A stärker steigen wird als B, B stärker steigt als C und A dementsprechend stärker als C, liegt eine transitive Prognose vor, welche das Eingehen einer Long-Position in Kontrakt A und einer Short-Position in Kontrakt C induziert.

Liegt im entgegengesetzten Fall eine Prognose vor, die für den Zeitpunkt t einen ansteigenden Spread A-B und B-C zeigt jedoch einen fallenden Spread A-C, handelt es sich um eine nichttransitive Prognose und die Handelsentscheidung aus dem Zeitpunkt $t-1$ wird fortgeführt.

¹⁹ Guégan und Huck (2004)

transitive Prognose			nicht-transitive Prognose		
Prognose Spread A-B	Prognose Spread A-B	Prognose Spread B-C	Prognose Spread A-B	Prognose Spread B-C	Prognose Spread A-C
Up	Up	Up	Up	Up	Down

Abbildung 7: Transitiv-Filter

6.5 Fehlermaße und Risikokennzahlen

Um die Güte der Prognose bestimmen zu können, geben der Trainingsfehler und die Gesamtkrümmung erste Anhaltspunkte. Auch ist eine grafische Auswertung sehr hilfreich und lässt eine erste Aussage über die Anpassung an die Generalisierungsdaten zu. Jedoch erhält man ein fundiertes und repräsentatives Qualitätsmaß eher über eine statistische Gütekennzahl um dann einen Vergleich der einzelnen Netze und Topologien vornehmen zu können.

6.5.1 Root Mean Square Error (RMSE)

Im Folgenden dient zur Bewertung des Prognosefehlers die Wurzel aus dem mittleren quadratischen Fehler (Root Mean Square Error = RMSE). Dieser wird wie folgt berechnet:²⁰

$$\text{RMSE} = \sqrt{\frac{1}{n} * \sum (\text{Sollgröße}_t - \text{Netzoutput}_t)^2} \quad (3)$$

mit n = Gesamtzahl der Prognosen, Sollgröße_t = Zielgröße des t -ten Prognosewerts und Netzoutput_t = die t -te Prognosegröße. Es gibt noch einige weitere Gütemaße wie MSE = mittleren quadratischen Fehler. Der Vorteil gegenüber dem mittleren quadratischen Fehler ist, dass der RSME die gleiche Dimension wie die Sollgröße und die Prognosegröße aufweist.

6.5.2 Calmar Ratio

Die Calmar Ratio ist eine Risiko-/Ertragskennzahl. Es wird die annualisierte Rendite durch den Absolutwert des „Maximum Drawdown“ dividiert. Der Maximum Drawdown wiederum (MaxDD) ist hier definiert als die maximale, prozentuale Verlusthöhe, die nach einem Allzeithoch jemals aufgetreten ist.²¹ Die Calmar Ratio definiert, im Gegensatz zu anderen Kennzahlen, Risiko als den maximal möglichen Verlust und ist auf diese Weise ein geeignetes Maß für die Evaluierung risikoadjustierter Rendite. Der Maximum Drawdown und die Calmar-

²⁰ Vgl. Mertens (2004)

²¹ Vgl. Futures Magazin für technisches Trading (2006)

Ratio stellen sich in formaler Schreibweise wie folgt dar. ΔS_t steht hier für die prozentuale Veränderung des betrachteten Underlyings.

$$\text{MaxDD} = \text{Min}[\Delta S_t - \text{Max}(\sum_{t=1}^n \Delta S_t)] \quad (4)$$

$$\text{Calmar Ratio} = \frac{\text{Annualisierte Rendite}}{\text{MaxDD}} \quad (5)$$

6.5.3 Sharpe Ratio

Die Sharpe Ratio ist eine weitverbreitete Risiko-/Ertragskennzahl, der viel Beachtung geschenkt wird, die sich in diesem Fall jedoch aus folgenden Gründen als ungeeignet erweist.

Es liegen hier keine normalverteilten Renditen vor, sondern eher Schiefe Verteilungen mit Fat-Tails, und Excess Kurtosis.

Die Sharpe Ratio, die als Risikomaß die Varianz beziehungsweise Standardabweichung einsetzt, lehnt also Investments die nicht normalverteilte Rendite aufweisen als zu risikoreich ab, egal ob es sich um einen positive oder negative Ausschlag handelt. Jedoch sind in diesem Fall gerade die größeren Bewegungen von Bedeutung. Desweiteren sind die Mittelwerte der annualisierten Renditen und die Volatilitäten der einzelnen Spreadpositionen derart unterschiedlich, dass eine zusätzliche Verzerrung beim Vergleich der einzelnen Spreads die Folge wäre.

6.6 Richtungsgütemaße

Die Wurzel des mittleren quadratischen Fehlers vermittelt einen ersten Eindruck über die globale Anpassungsstruktur der Netzausgaben an die Generalisierungsdaten und es kann eine (Vor-) Selektion von erfolgreich trainierten Netzen getroffen werden.

Ist nun jedoch das Ziel eine Prognose zu erstellen, welche geeignet erscheint entscheidungsrelevante Informationen für das Spreadtrading auf Tagesbasis zu liefern, müssen Gütemaße mit einer höheren Sensitivität eingesetzt werden. Stimmt beispielsweise die allgemeine Richtungsprognose der Netzausgabe mit den Generalisierungsdaten überein und ist jedoch die komplette Netzausgabe um einen oder wenige Tage verzögert prognostiziert, sind die Informationen für den Anwender von keinem großen Wert. Die Genauigkeit der Richtungswechselprognose des Spreads ist entscheidend, da der Nutzer für jeden nicht korrekt prognostizierten Tag falsch am Markt platziert ist und so Geld verliert.

Im Folgenden sollen nun drei Messgrößen vorgestellt werden, die die Netzausgabe hinsichtlich des Timings und der Prognoserichtung beurteilen.

6.6.1 Correct Direction

Das Maß der Correct Direction ist eine prozentuale Kennzahl, die den Anteil der korrekt prognostizierten Richtungsänderungen des Spreads angibt. Im Fokus stehen hier die Datenpunkte der Prognose und des Generalisierungsdatensatzes, die sich im Bereich von Null aufhalten und bei denen es im weiteren Verlauf zu einem Vorzeichenwechsel kommt. Dies bedeutet ferner eine Änderung von positiver zu negativer Rendite oder von negativer zu positiver Rendite. Mit anderen Worten vollzieht sich also ein Richtungswechsel des Spreads. Hinsichtlich der Prognose von Futureszeitreihen ist diese Kennzahl unerlässlich, da die Gefahr besteht bei einem nicht korrekt prognostizierten Richtungswechsel falsch am Markt positioniert zu sein. Die Correct Direction wird berechnet, indem alle Richtungswechsel der Out-of-Sample Daten bestimmt und zu den korrekt prognostizierten Richtungswechsel ins Verhältnis gesetzt werden.

$$CD = \frac{1}{N} \sum_{k=1}^N \delta_{t_k p_k} \quad (6)$$

Hierbei repräsentiert N die Anzahl der Richtungswechsel vom positiven zum negativen Bereich und vice versa. t_i und p_i stehen für den jeweiligen Richtungswechsel i der Zeitreihe beziehungsweise der Prognose. Schließlich stellt $\delta_{i,j}$ eine Binärvariable dar, die gleich Eins, wenn $i = j$ und sonst Null ist. Entsprechend ist die Qualität der Prognose umso höher, je größer der Wert der Kennzahl ist.

6.6.2 Correct Direction Change

Die Kennzahl des Correct Direction Change ist ebenfalls eine relative Kennzahl und gibt den Anteil der Prognosewerte an, welche eine gewisse Zeit in die korrekte Richtung der Ursprungszeitreihe verlaufen, jedoch anschließend die Richtung, verglichen mit den Generalisierungsdaten zu früh oder zu spät ändern. Falls also die Originalzeitreihe sowie die Prognose eine steigende Tendenz aufweisen und die Prognose ab einem bestimmten Punkt die Richtung ändert, jedoch die Ursprungszeitreihe weiterhin einen steigenden Verlauf aufzeigt, liegt ein verfrühter Richtungswechsel vor. Die Prognose wird ungenau und es wird in diesem Fall eine zu geringe Rendite vorhergesagt. Es wird der Anteil aller richtungsabweichenden Datenpunkte von den gesamten zu prognostizierenden Werten berechnet. Formal stellt sich diese Kennzahl wie folgt dar.

$$CDC = \frac{\sum_{t=1}^q \text{deviating Datapoints}_p}{\sum_{t=1}^n \text{total Datapoints}_g} \quad (7)$$

Der Dividend des CDC ergibt sich aus der Summe der abweichenden Datenpunkte der Prognose. Die abweichenden Datenpunkte werden mit Hilfe eines

Schwellwerts bestimmt, welcher durch eine Heuristik individuell bei jedem Spread ermittelt wurde.

Der Divisor setzt sich aus der Summe aller Werte der Generalisierungszeitreihe zusammen. Folglich ist die Netzausgabe umso genauer, je kleiner der Quotient ist.

6.6.3 Correct Long-Term Trend

Als letzte Kennzahl misst der Correct Long-term Trend inwiefern die Netzausgabe den langfristigen Trend der Zeitreihe abbildet. Der Langfristtrend der Zeitreihe wird durch ihre lokalen und globalen Extremstellen repräsentiert. Die Kennzahl drückt nun den prozentualen Anteil der korrekt prognostizierten Extremstellen aus.

$$\text{CLTT} = \frac{1}{N} \sum_{k=1}^N \delta_{t_k p_k} \quad (8)$$

Hierbei repräsentiert N die Anzahl der positiven sowie negativen Extremstellen der Originalzeitreihe. t_i und p_i stehen für die jeweilige Extremstelle i der Zeitreihe beziehungsweise der Prognose. Schließlich stellt $\delta_{i,j}$ eine Binärvariable dar, die gleich Eins, wenn $i = j$ und sonst Null ist.

7 Netzevaluierung, Prognosedurchführung

7.1 Netzevaluierung

Die Zehn besten und erfolgreich trainierten Netze der FAUN-Simulation wurden für jeden Futures-Spread und Netztopologie ausgewertet, anschließend mittels Quellcode exportiert und schließlich mit den Generalisierungsdaten konfrontiert. Die Evaluierung der Netze erfolgte gleichermaßen anhand des Trainingsfehlers und der Netzkrümmung. In seltenen Fällen war das Netz mit dem geringsten Trainingsfehler auch gleichzeitig dasjenige mit der kleinsten Krümmung und umgekehrt. Beide Parameter müssen jedoch gleichwertig berücksichtigt werden, da zum einen die Spannweite der Trainingsfehler vom besten zum schlechtesten noch akzeptierten Netz sehr groß ist und somit ein deutlicher qualitativer Unterschied vorliegt. Zum anderen weisen Netze mit geringem Trainingsfehler, jedoch zu hohen Krümmungswerten, ebenfalls eine schlechte Anpassung auf. Die Ergebnisse des Trainings sind in der nachfolgenden Tabelle aufgelistet.

FAUN-Trainingsergebnisse						
Spread MLP	Initialisierte Netze	Verworfenene Netze Prozent	Erfolgreich zu trainierende Netze	Trainingsfehler des besten Netzes	Krümmung des besten Netzes	Gesamte Berechnungszeit
Brent-Gasoline	29318	82.95%	5000	14.6381	1.14515E+05	791.4 Sek.
Brent - Heating	220278	97.73%	5000	10.7296	1.46297E+04	12075.7 Sek.
Brent-WTI	57356	87.8%	7000	18.6417	6.5570E+04	1382.4 Sek.
Gas Heating	16662	63.99%	6000	13.2913	1.94615E+05	604.0 Sek.
WTI-Gas	9448	47.08%	5000	12.0132	5.84712E+04	278.6 Sek.
WTI-Heating	1521	34.25%	1000	13.1000	2.75872E+03	20.0 Sek.
Spread HONN	Initialisierte Netze	Verworfenene Netze Prozent	Erfolgreich zu trainierende Netze	Trainingsfehler des besten Netzes	Krümmung des besten Netzes	Gesamte Berechnungszeit
Brent-Gasoline	5079	1.56%	5000	110.3053	1.59572E+04	965.0 Sek.
Brent - Heating	5189	3.64%	5000	133.6503	2.77033E+03	687.0 Sek.
Brent-WTI	25844	92.26%	2000	159.8148	1.01994E+05	5598.9 Sek.
Gas Heating	16455	81.77%	3000	138.3770	1.86310E+02	1578.4 Sek.
WTI-Gas	1468	31.88%	1000	125.3628	5.28492E+04	138.2 Sek.
WTI-Heating	5023	0.46%	5000	145.7761	5.28247E+03	1440.5 Sek.
Spread HONN-SODD	Initialisierte Netze	Verworfenene Netze Prozent	Erfolgreich zu trainierende Netze	Trainingsfehler des besten Netzes	Krümmung des besten Netzes	Gesamte Berechnungszeit
Brent – Gasoline	5045	0.89%	5000	89.5315	9.1338E+02	633.1 Sek.
Brent-Heating	5024	0.48%	5000	111.4251	3.8252E+02	1077.3 Sek.
Brent-WTI	24082	79.24%	5000	122.8319	1.4780E+04	3770.0 Sek.
Gas Heating	10513	23.9%	8000	102.4276	5.2069E+04	1032.7 Sek.
WTI-Gas	1834	45.47%	1000	104.5454	2.1814E+04	156.6 Sek.
WTI-Heating	7101	29.59%	5000	117.9643	1.9031E+02	922.9 Sek.

Tabelle 5: erfolgreich trainierte Netze

Dabei wird zeilenweise zwischen den verschiedenen Topologien MLP, HONN und HONN-SODD und deren jeweilige Futures-Spreads differenziert. Die Spalten enthalten die wichtigsten Trainingsdaten der Netze. Angefangen mit der Zahl initialisierter Netze, prozentualer Anteil verworfener Netze, gefolgt von der Anzahl erfolgreich trainierter Netze, dem Trainingsfehler und der Krümmung des besten Netzes und schließlich die Gesamtberechnungszeit des Trainings. Bei genauer Betrachtung fällt zum einen auf, dass sich die einzelnen Topologien in

den Punkten „Anzahl verworfener Netze“, Trainingsfehler und Krümmung unterscheiden. Die Anzahl der verworfenen Netze der MLP-Topologie, scheinen im Vergleich zu den HONN-Strukturen relativ hoch zu liegen. Während die Werte bei den MLP-Netzen nicht unter 34 Prozent fallen, erstrecken sich die HONN-Ergebnisse von 0,4 bis 92 Prozent. Ebenfalls sind die Krümmungswerte der MLP-Topologie durchgehend höher als die der HONN-Topologien.

Bei den Trainingsfehlern fällt auf, dass diese bei den Perzeptrons am niedrigsten ausfallen, während die Fehlerraten der HO-Netze um ein Vielfaches höher liegen. Weiterhin ist zu bemerken, dass die Trainingsfehler der HONN-SODD-Struktur durchschnittlich um 20 Prozent unter den Fehlern der HONN-Struktur liegen. Hinsichtlich der einzelnen Spread-Positionen ist der Brent-WTI-Spread sehr auffällig. Dieser weist über alle Topologien hinweg, die höchsten Trainingsfehler, die längste Berechnungszeit sowie die Anzahl verworfener Netze auf.

7.2 Prognose mit MLP und HONN-Strukturen

Die Generalisierungsfähigkeit und das Prognoseresultat der Topologien sollen nun im folgenden Abschnitt evaluiert und erläutert werden.

Die Netzausgaben sind durchgehend um einen positiven oder negativen Mittelwertsbias verschoben und weisen überwiegend eine andere Skalierung als die Zielwerte auf. Um einen Vergleich zwischen Ist- und Solloutput zu ermöglichen, ist eine Normierung der Netzausgabe auf den selben Mittelwert des Generalisierungsdatensatzes notwendig, sowie eine Reskalierung auf die Spannweite des Zieldatensatzes. Die Reskalierung erfolgt mit der nachstehenden Formel:

$$\text{Reskalierung} = \frac{\text{Spannweite}_{\text{Gen}}}{\text{Spannweite}_{\text{Net}}} * \text{Netzoutput}_i, \quad i = 1,2,3\dots n \quad (9)$$

Dabei steht $\text{Spannweite}_{\text{Gen}}$ für die Spannweite des Generalisierungsdatensatzes und $\text{Spannweite}_{\text{Net}}$ für die des Netzoutputs. Dieser Quotient wird schließlich mit den einzelnen Outputwerten 1- n multipliziert.

7.2.1 MLP-Prognose

Wie die Daten der FAUN-Simulation bereits erkennen ließen, erweist sich das Training der Netz-Topologien als sehr heterogen. So auch die Prognoseergebnisse der sechs verschiedenen Futures-Spread-Positionen.

Eine Gemeinsamkeit aller MLP-Prognosen ist, dass die Netzausgabe die globale Struktur der Generalisierungszeitreihe und somit die Richtung erfasst, jedoch dem Zieldatensatz, je nach Spread, um ein bestimmtes Lag voraneilt. Wie in Abbildung (8) zu sehen, reicht das Ausmaß der Prognosenvorwegnahme von zwei bis vier Tagen. Einzig der WTI-Heating-Oil Spread wurde ohne zeitliches Delay prognostiziert. Nun ist es möglich die gesamte Netzausgabe um das jeweilige Lag zu verzögern und so eine Rechtsverschiebung der Struktur durchzuführen. Nach Beseitigung des zeitlichen Lags liegen die Prognosen gut in den

Zieldaten. Dies zeigt auch die Berechnung des RSME, welcher sich in allen Fällen signifikant verbessert.

Der Grund für die intensive manuelle Anpassung des Datenoutputs sind die lediglich akzeptablen Trainingsergebnisse und die dadurch erzielte Güte der Netze. Ein Unterschied zwischen den jeweiligen Prognosen ist die Anpassungsfähigkeit an kleine Ausschläge. Während die großen Extremwerte der Zieldaten ausnahmslos antizipiert werden, ist die Trefferquote für geringere Schwankungen von Prognose zu Prognose unterschiedlich. Wie aus Abbildung (9) ersichtlich, ist im Falle des Brent-Gasoline-Spreads die Approximation von Ausschlägen jeglicher Größenordnung hinreichend genau. Im Gegensatz dazu, werden kleine Schwankungen beim Brent Heating-Oil-Spread (Abbildungen 10 und 11) eher mäßig bis gar nicht prognostiziert. Teilweise verläuft die Prognose wie eine gemittelte Datenreihe. Trotz alledem wird die Globale Richtung der Spreads durchgängig erkannt.




Abbildung 8: MLP-Prognose Brent-Gasoline-Spread




Abbildung 9: Delayed MLP-Prognose Brent-Gasoline-Spread

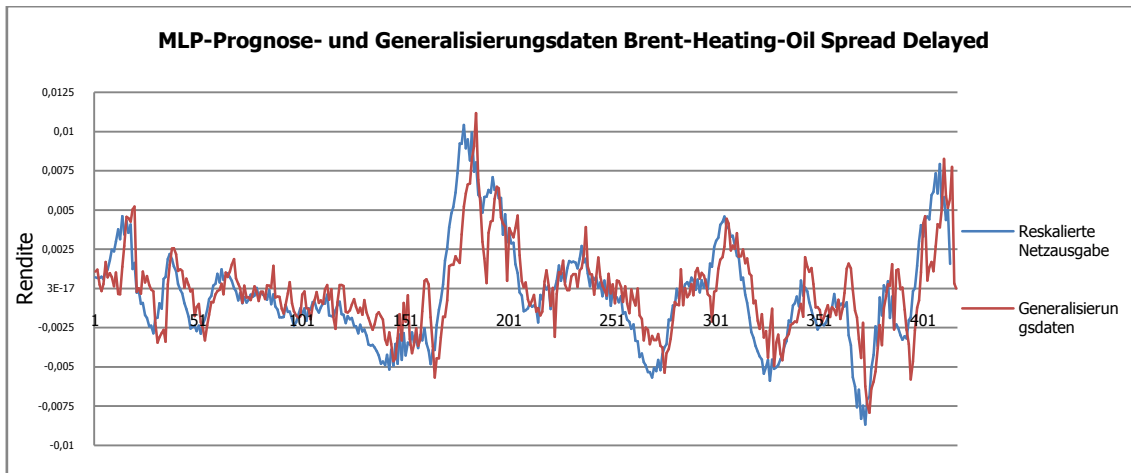


Abbildung 10: MLP-Prognose Brent Heating Oil-Spread




Abbildung 11: Delayed MLP-Prognose Brent Heating Oil-Spread

7.4.2 HONN-und HONN-SODD-Prognose

Im Vergleich zur MLP-Topologie ist die Anpassungsgüte beider HONN-Strukturen nicht zeitverzögert. Zudem werden die Zieldaten durch die Prognose sehr zuverlässig bestimmt wie in Abbildung (12) deutlich wird. Ein erster Anhaltspunkt für die qualitative Steigerung ist bereits an den Ergebnissen der Trainingsverläufe abzulesen. Die Trainingsfehler der MLP-Architektur sind zwar erheblich niedriger als die der High-Order-Netzwerke, jedoch kommt hier die Bedeutung der Krümmung zum tragen. Diese liegt in den meisten Fällen unter den Werten der MLPs.

Des Weiteren ist ein Qualitätssprung zwischen HONN- und HONN-SODD-Struktur zu erkennen. Zum einen liegt der Trainingsfehler der HONN-SODD durchschnittlich um 20 Prozent und zum anderen die Krümmung im Mittel um 95 Prozent unter den jeweiligen Werten der HONN-Topologie. Dies macht sich schließlich auch in der Approximationsgüte der HONN-SODD-Prognosen bemerkbar. Diese sind ausnahmslos hochwertiger als die der HONN- und MLP-Ausgaben. Der Blick auf die Richtungsgütemaße und den RMSE macht den Un-

terschied zwischen den verschiedenen Topolgen ebenfalls sehr deutlich. Teilweise ist die Generalisierungsfähigkeit derart hoch und die Prognosewerte liegen so exakt in den Daten, dass zwischen der Originalzeitreihe und der Netzausgabe nahezu keine Unterschiede auszumachen sind und jede kleinste Bewegung prognostiziert wird. Dies spricht für eine sehr robuste und anpassungsfähige Netzarchitektur.




Abbildung 12: HONN-Prognose Gasoline-Heating-Oil-Spread

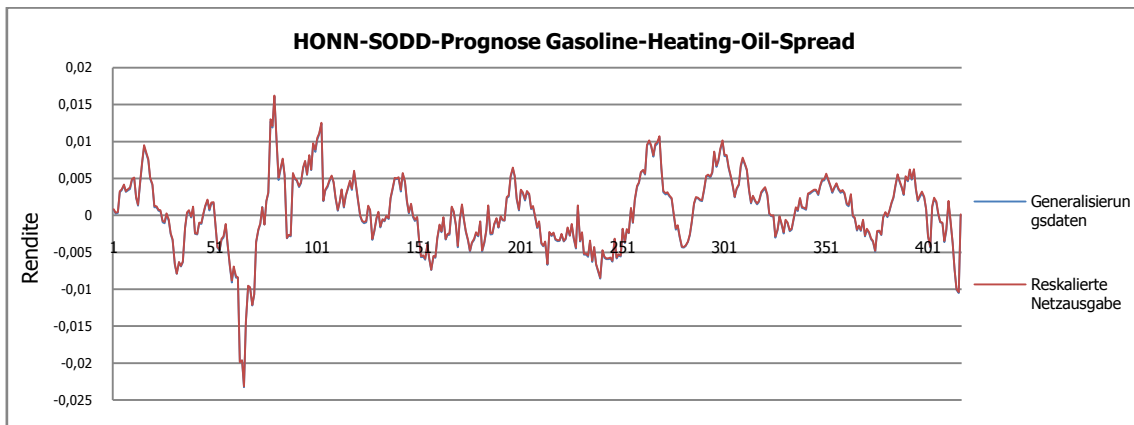


Abbildung 13: HONN-SODD-Prognose Gasoline-Heating-Oil-Spread




Abbildung 14: HONN-SODD-Prognose Brent Gasoline-Spread

Um das Potential dieses Netztyps noch weiter zu veranschaulichen, wurde ein erfolgreich trainiertes HONN-SODD mit den Rohdaten des Generalisierungszeitraums, ohne verzerrenden gleitenden Durchschnitt, konfrontiert. Das Netz selbst wurde jedoch mit einer geglätteten Zeitreihe (gleitender Durchschnitt von 15 Tagen) trainiert. Was bedeutet, dass die Trainingsdaten weniger Rauschen enthalten und es auf diese Weise für das Netz umso schwieriger ist eine korrekte Prognose zu liefern.

Wie in Abbildung (15) zu erkennen ist, zeichnet sich diese Netzausgabe der Rohdaten mit ähnlich hoher, wenn nicht sogar besserer Qualität aus. Dies ist ein sehr bemerkenswertes Ergebnis. Die blaue Linie der Generalisierungsreihe ist kaum zu sehen, da die rote Prognosereihe nahezu deckungsgleich über ihr liegt, selten kommt es zu minimalen Abweichungen.




Abbildung 15: HONN-SODD-Prognose Rohdaten Gasoline-Heating-Oil-Spread

8 Auswertung und Vergleich der Prognoseergebnisse

Anhand der erstellten Prognosen und Gütekennzahlen der Netze sollen nun Handelssignale bzw. Entscheidungen abgeleitet und die erzielten Renditen der einzelnen Modelle verglichen werden. Zudem wird eine Performancemessung zwischen einer Buy and Hold-Strategie und einer kontinuierlichen Portfoliooptimierung vorgenommen. Betrachtet wird ausschließlich der Out-of-Sample-Bereich, welcher sich vom 02.05.2003 bis zum 03.01.2005 erstreckt. Um einen Performancevergleich der einzelnen Prognosemodelle durchführen zu können, wurden die Renditen aller Trades kumuliert und auf den vorliegenden Zeitraum annualisiert. Die annualisierten Renditen sind jeweils am Ende der entsprechenden Spalte abgetragen. Die Annualisierung erfolgt durch die nachstehende Formel.

$$AR = \left[\left(\frac{\text{kumulierte Renditen}}{\text{Betrzeitraum}} \right) + 1 \left(\frac{\text{Anzahl Handelstage pro Jahr}}{\text{Handelstage des Betrachtungszeitraums}} \right) \right] - 1 \quad (10)$$

Weiterhin sind die Ergebnisse der verschiedenen Prognosemodelle tabellarisch aufbereitet. Zum Vergleich der Endergebnisse wurden die annualisierten Renditen jedes Spreads für das entsprechende Prognosemodell in einem Portfolio zusammengefasst. Jeder Spread erhält die Gewichtung von 1/6. Die Portfoliorenditen sind in der letzten Zeile der jeweiligen Tabelle abgetragen.

8.1 Buy and Hold Strategie

Bei Betrachtung der Renditen erweist sich die gewichtete MLP-Prognose mit 6,68 Prozent als beste Näherung zur tatsächlich aufgetretenen Rendite von 5,69 Prozent. Es muss jedoch beachtet werden, dass dieses Ergebnis lediglich durch Zufall generiert wurde, da es sich bei den MLP-Netzausgaben teilweise um Mean-Preserving-Spreads handelt. Dies bedeutet, dass der Mittelwert der Prognose dem der Generalisierungszeitreihe entspricht, jedoch ist die Streuung der Prognosewerte eine andere und es werden z.B. stark positive Ausschläge durch stark negative Ausschläge kompensiert.

Die Qualität der Mustererkennung ist bei weitem nicht so hoch wie die der HONN-Topologien. Dies wird aus den Tabellen (11) und (14) anhand der Fitting- und Richtungsgütemaße deutlich erkennbar. Auch verweisen der Maximum Drawdown mit 22,52 Prozent, sowie die Calmar- Ratio von 2,9037 auf die HONN-SODD-Struktur.

Desweiteren ist anzumerken, dass der Einbezug von Transaktionskosten eine wichtige Rolle spielt. Erscheint es ohne deren Berücksichtigung noch lohnenswert, den Brent-WTI-Spread im Portfolio zu belassen, ist diese Entscheidung nach Abzug der Kosten nicht mehr vertretbar. Die Transaktionsgebühren sind höher, als die erwirtschaftete Rendite, so dass ein negativer Saldo entsteht. Einen Ausreißer stellt dabei auch der Gasoline Heating-Oil-Spread dar. Dieser wird von den HONN-Strukturen zu hoch und von der MLP-Topologie zu niedrig prognostiziert.

Zusammenfassend lässt sich feststellen, dass die Richtung aller Zeitreihen korrekt erfasst wurde. Lediglich die erzielbare Rendite ist bei einer Buy and Hold-Strategie sehr begrenzt und ist sehr vom richtigen Timing und eher Glück als Berechnung abhängig.

Annualisierte Renditen abzüglich Transaktionskosten				
	Ungefiltert MLP	Ungefiltert HONN-SODD	Ungefiltert HONN	Ungefiltert Rendite Generalisierungsreihe
Brent Gas	16,97%	16,81%	16,64%	8,90%
Brent Heating	8,34%	5,46%	8,06%	2,75%
Brent WTI	-0,56%	-0,44%	-0,04%	-0,97%
Gas Heating	2,12%	23,68%	27,11%	12,68%
WTI Gas	3,25%	10,66%	14,91%	7,70%
WTI Heating	9,93%	6,47%	9,88%	3,09%
Portfolio 1/6	6,68%	10,44%	12,76%	5,69%

Tabelle 6: Renditen abzüglich Transaktionskosten

Risikomaße							
	Max-DD-MLP	Max-DD HONN-SODD	Max-DD HONN	Max-DD Generalisierung	Calmar-Ratio-MLP	Calmar-Ratio HONN-SODD	Calmar-Ratio HONN
Brent Gas	25,25%	16,93%	23,32%	23,45%	2,9464	4,5302	3,2370
Brent Heating	23,97%	16,25%	17,93%	13,91%	1,5223	2,3891	2,0435
Brent WTI	8,54%	4,73%	6,07%	5,44%	2,0707	3,6186	2,9253
Gas Heating	35,29%	56,70%	64,73%	48,99%	1,9248	1,4258	1,2412
WTI Gas	22,64%	20,22%	19,42%	21,69%	3,1378	3,5491	3,6912
WTI Heating	25,23%	20,29%	22,24%	18,07%	1,5446	1,9098	1,7286
Portfolio (1/6)	23,49%	22,52%	25,62%	21,93%	2,1911	2,9037	2,4778

Tabelle 7: Risikomaße

8.2 Kontinuierliche Portfolio-Optimierung

Bei Anwendung dieser Strategie werden nun die Handelssignale der Prognose auf täglicher Basis ausgewertet und ausgeführt. Zudem werden die einzelnen Filter-Techniken angewendet und beobachtet, inwiefern klare Signale bzw. eine höhere Rendite erzielt werden.

8.2.1 MLP-Topologie

Bei der MLP-Struktur werden nun ausschließlich die, um das jeweilige Lag, verzögerten Netzausgaben und ihre Erträge betrachtet. Dies bedeutet für die Handelsentscheidungen, welche auf Grund der Prognosen getätigt werden, dass diese um das jeweilige Lag in die Zukunft verlagert werden müssen. Die Han-

delsentscheidung, die für x_t prognostiziert wird, sollte also erst an x_{t+lag} ausgeführt werden.

Im Gegensatz zur Buy and Hold-Strategie lässt sich bereits bei einem ersten Blick auf die Renditen abzüglich Transaktionskosten in Tabelle (8) eine deutliche Steigerung feststellen. Die durchschnittliche Rendite des Futures-Portfolios ist bei der ungefilterten Prognose um fast das Neunfache höher als die der Buy and Hold-Strategie. Weiterhin ist zu sehen, dass nun auch der Brent-WTI-Spread mit einer annualisierten Rendite von 17,69 Prozent im positiven Bereich notiert.

MLP-Renditen abzüglich Transaktionskosten			
	Ungefiltert	Korrelationsfilter	Transitiv gefilterte Trades
Brent Gas	74,38%	45,64%	73,19%
Brent Heating	36,49%	25,06%	35,14%
Brent WTI	17,69%	11,51%	18,10%
Gas Heating	67,92%	46,10%	68,90%
WTI Gas	71,04%	38,14%	70,88%
WTI Heating	38,96%	24,49%	39,27%
Portfolio 1/6	51,08%	31,82%	50,91%

Tabelle 8: Rendite MLP- mit Transaktionskosten

Bei der Betrachtung der verschiedenen Filter-Methoden ist jedoch keine weitere Ertragssteigerung erkennbar. Die Prognose ist von so einer Qualität, dass wenig Spielraum für eine Renditezunahme vorhanden ist. Es ist viel mehr das Gegenteil der Fall. Die erzielten Renditen liegen, bei Anwendung des Korrelationsfilters, ca. 40 Prozent unter den Werten der ungefilterten Prognose. Das Ergebnis des Korrelationsfilters ist jedoch von mehreren Variablen abhängig. Zum einen ist entscheidend, wie der Korrelations-Schwellwert gesetzt wird, welcher unterschritten werden muss, damit es zu einem Markteintritt kommt. Je niedriger dieser gewählt wird, desto weniger Handelspositionen werden eingegangen. In dieser Arbeit wurde ein Schwellwert von Null verwendet. Sobald also die Korrelation sinkt, wird die, zu diesem Zeitpunkt, prognostizierte Spread-Position eingegangen.

Ein weiteres Kriterium, welches die erzielbare Rendite beeinflusst ist der Marktaustritt. Die von Dunis et al. vorgeschlagene Anwendung des Korrelationsfilters sieht einen Marktaustritt vor, sobald die Korrelation wieder ansteigt. Vor allem bei großen Marktbewegungen und somit bei starkem Abfall der Korrelation ist jedoch feststellbar, dass durchaus beim Wiederanstieg der Korrelation eine positive Rendite erzielt werden kann. Nichtsdestotrotz ist es kaum möglich mit dem Korrelationsfilter die Rendite gegenüber der ungefilterten Prognose zu steigern, da die Netzprognose auch an den Handelstagen sehr zuverlässig ist, an denen der Korrelationsfilter keinen Markteintritt signalisiert. Diese zusätzliche Rendite ist es, welche die ungefilterte Prognose gewinnbringender gestaltet als die Anwendung des Korrelationsfilters.

Im Vergleich dazu erweist sich der Transitiv-Filter, bei Betrachtung der Renditen ohne Abzug der Transaktionskosten, profitabler als die ungefilterte Prognose. Sobald die Transaktionskosten jedoch berücksichtigt werden, reduziert sich die Rendite der Transitiv-Handelsregel stärker als die ungefilterte Alternative. Der Grund liegt in der größeren Anzahl an Transaktionen die auf Grund der Filter-signale getätigt werden.

MLP-Annualisierte Renditen ohne Transaktionskosten					
	Ungefil- tert	Korrelationsfil- ter	General- isierungsdaten	Transitiv gefilterte Trades	Ungefiltert Rendite Generalisierungs- reihe
Brent Gas	75,94%	46,44%	47,12%	75,86%	79,44%
Brent Heating	38,51%	26,46%	28,74%	38,66%	42,89%
Brent WTI	21,15%	13,00%	14,48%	21,56%	24,35%
Gas Heating	74,38%	48,72%	53,24%	75,33%	84,26%
WTI Gas	73,51%	39,37%	40,32%	73,35%	75,96%
WTI Heating	42,30%	26,45%	26,80%	42,61%	43,46%
Portfolio 1/6	54,30%	33,41%	35,12%	54,56%	58,39%

Tabelle 9: Rendite MLP- ohne Transaktionskosten

Des Weiteren verlieren die Risikokennzahlen des Maximum Drawdown und die Calmar-Ratio in Tabelle (10) an Aussagekraft, da die Prognosen relativ zuverlässig sind und so kaum die Chance besteht sich langfristig falsch zu positionieren.

MLP-Risikomaße						
	Korrelations-Filter			Ungefiltert/ Transitiv-Filter		
	Max-DD	Calmar- Ratio	MAX-DD Generalisierung	Max-DD	Calmar-Ratio	Max-DD Gene- raisierung
Brent Gas	17,82%	2,5605	14,77%	25,25%	2,9464	23,45%
Brent Heating	15,20%	1,6486	10,83%	23,97%	1,5223	13,91%
Brent WTI	4,52%	2,5455	3,39%	8,54%	2,0707	5,44%
Gas Heating	15,87%	2,9049	16,48%	35,29%	1,9248	48,99%
WTI Gas	11,63%	3,2792	12,51%	22,64%	3,1378	21,69%
WTI Heating	9,82%	2,4935	10,58%	25,23%	1,5446	18,07%
Portfolio 1/6	12,48%	2,5720	11,43%	23,49%	2,1911	21,92%

Tabelle 10: Risikomaße MLP

MLP-Gütemaße				
	RMSE	Correct Long-Term-Trend	Correct Direction	Correct Direction-Change
Brent Gas	0,23%	89,33%	45,95%	27,58%
Brent Heating	0,15%	85,27%	35,71%	49,40%
Brent WTI	0,08%	84,67%	51,52%	42,21%
Gas Heating	0,32%	80,24%	63,33%	43,41%
WTI Gas	0,13%	91,16%	44,44%	22,54%
WTI Heating	0,07%	99,41%	57,14%	13,91%
Portfolio 1/6	0,00163891	88,35%	49,68%	33,17%

Tabelle 11: MLP Gütemaße

Die Richtungsgütemaße der MLP-Topologien liefern durchwachsene Ergebnisse. Obwohl der RMSE gering und der langfristige Trend zu 88,35 Prozent erkannt wird, ist die Wahrscheinlichkeit des Richtungswechsels zum korrekten Zeitpunkt mit knapp 50 Prozent eher niedrig. Ein Münzwurf erweist sich zur Entscheidungsfindung als gleichwertige Alternative. Es muss jedoch angemerkt werden, dass es sich hier um ein sehr strenges Gütekriterium handelt. Eine Verfehlung um einen bis zwei Tage wird bereits als Fehlprognose gewertet. Von Vorteil wäre hier ein längerer Prognosehorizont über einige Tage mit einem eindeutigen Long/ Short-Signal, um das Risiko der Fehlpositionierung zu vermeiden. Alle Ergebnisse müssen dennoch unter Vorbehalt bewertet werden, da bis auf den WTI-Heating-Oil-Spread, alle Prognosen verzögert wurden. Es ist fraglich, ob unter realen Umständen jederzeit das korrekte Lag bestimmt werden kann.

8.2.2 HONN-Topologie

Die Prognose mit Hilfe der HONN-Architektur liefert bei Betrachtung der Renditen durchgehend höhere Erträge als die MLP-Struktur. Die Filter-Ergebnisse werden hier durch die selben Umstände beeinflusst wie im vorherigen Abschnitt beschrieben. Auffällig ist jedoch, dass die durchschnittliche ungefilterte Netzausgabe nahezu die maximal erzielbare Rendite der Originalzeitreihe prognostiziert. Lediglich mit einer Differenz von 0,39 Prozent. Zudem wird die Datenstruktur ohne zeitliche Verzögerung vorhergesagt, was sich auch anhand der Richtungsgütemaße erkennen lässt. Mit einer Wahrscheinlichkeit von mehr als 98 Prozent wird der korrekte langfristige Trend der Zeitreihe bestimmt. Zudem werden in ca. 80 Prozent der Fälle die Richtungswechsel des Spreads treffend prognostiziert. Auch sind das Maß des Correct Direction Change mit neun Prozent und der RMSE mit einem Wert von 0,000620 gering und sprechen für eine valide Prognosegüte.

HONN-Renditen abzüglich Transaktionskosten			
	Ungefiltert	Korrelationsfilter	Transitiv gefilterte Trades
Brent Gas	75,49%	43,88%	75,54%
Brent Heating	36,64%	25,10%	36,54%
Brent WTI	17,77%	11,18%	17,32%
Gas Heating	80,35%	51,41%	80,26%
WTI Gas	71,68%	37,78%	71,64%
WTI Heating	38,44%	24,42%	38,27%
Portfolio 1/6	53,40%	32,30%	53,26%

Tabelle12: HONN-Renditen abz. Transaktionskosten

HONN-Annualisierte Renditen ohne Transaktionskosten					
	Ungefiltert	Korrelationsfilter	Korrelationsfilter Generalisierung	Transitiv gefilterte Trades	Rendite Generalisierungsreihe
Brent Gas	78,64%	44,76%	47,12%	78,75%	79,44%
Brent Heating	42,74%	28,62%	28,74%	42,63%	42,89%
Brent WTI	23,81%	14,25%	14,48%	23,98%	24,35%
Gas Heating	83,63%	52,74%	53,24%	83,54%	84,26%
WTI Gas	75,86%	40,15%	40,32%	75,81%	75,96%
WTI Heating	43,30%	26,79%	26,80%	43,12%	43,46%
Portfolio 1/6	58,00%	34,55%	35,12%	57,97%	58,39%

Tabelle13: HONN-Renditen ohne Transaktionskosten

HONN-Gütemaße				
	RMSE	Correct Long-Term-Trend	Correct Direction	Correct Direction-Change
Brent Gas	0,10%	96,00%	70,27%	14,63%
Brent Heating	0,03%	99,22%	90,48%	6,00%
Brent WTI	0,03%	99,27%	82,35%	11,27%
Gas Heating	0,12%	99,40%	83,33%	11,51%
WTI Gas	0,05%	100,00%	85,19%	4,32%
WTI Heating	0,04%	100,00%	67,86%	7,43%
Portfolio 1/6	0,000620268	98,98%	79,91%	9,19%

Tabelle 14: HONN-Gütemaße

HONN-Risikomaße						
	Korrelations-Filter			Ungefiltert/ Transitiv-Filter		
	Max-DD	Calmar-Ratio	MAX-DD Generalisierung	Max-DD	Calmar-Ratio	Max-DD Generierung
Brent Gas	14,60%	3,0055	14,77%	23,32%	3,2370	23,45%
Brent Heating	10,25%	2,4488	10,83%	17,93%	2,0435	13,91%
Brent WTI	3,74%	2,9893	3,39%	6,07%	2,9253	5,44%
Gas Heating	17,29%	2,9734	16,48%	64,73%	1,2412	48,99%
WTI Gas	12,66%	2,9842	12,51%	19,42%	3,6912	21,69%
WTI Heating	8,35%	2,9246	10,58%	22,24%	1,7286	18,07%
Portfolio 1/6	11,15%	2,8876	11,43%	25,62%	2,4778	21,92%

Tabelle 15: HONN-Risikokennzahlen

8.2.3 HONN-SODD-Topologie

Eine weitere Steigerung der Prognosequalität ist mit Hilfe der HONN-SODD-Struktur zu beobachten. Zum einen führt, wie bereits bei den Modellen zuvor, die Anwendung der Filter-Modelle aus den genannten Gründen zu keiner Ertragssteigerung gegenüber der ungefilterten Prognose. Dennoch sind die Renditen, wie aus Tabelle (16) hervorgeht, durchgehend höher als im MLP- oder HONN- Ansatz. Die ungefilterte Netzprognose liefert ohne Berücksichtigung der Transaktionskosten eine Rendite von 58,23 Prozent, was nahezu der realisierbaren Rendite der Generalisierungszeitreihe von 58,39 Prozent entspricht.

HONN-SODD-Renditen abzüglich Transaktionskosten			
	Ungefiltert	Korrelationsfilter	Transitiv gefilterte Trades
Brent Gas	76,71%	43,34%	75,70%
Brent Heating	38,83%	25,74%	36,94%
Brent WTI	17,12%	10,90%	17,94%
Gas Heating	80,84%	51,47%	80,84%
WTI Gas	71,77%	38,14%	71,77%
WTI Heating	38,75%	24,27%	38,75%
Portfolio 1/6	54,00	32,31%	53,66%

Tabelle16: HONN-SODD-Renditen abzüglich Transaktionskosten

HONN-SODD-Annualisierte Renditen ohne Transaktionskosten					
	Ungefiltert	Korrelationsfilter	Korrelationsfilter Generalisierung	Transitiv gefilterte Trades	Rendite Generalisierungsreihe
Brent Gas	79,15%	44,96%	47,12%	79,30%	79,44%
Brent Heating	42,84%	28,70%	28,74%	42,84%	42,89%
Brent WTI	24,01%	14,33%	14,48%	24,20%	24,35%
Gas Heating	84,12%	53,21%	53,24%	84,12%	84,26%
WTI Gas	75,95%	40,32%	40,32%	75,95%	75,96%
WTI Heating	43,30%	26,80%	26,80%	43,30%	43,46%
Portfolio 1/6	58,23%	34,72%	35,12%	58,28%	58,39%

Tabelle17: HONN-SODD-Renditen ohne Transaktionskosten

Jedoch wird die Überlegenheit der HONN-SODD-Struktur im Vergleich zu der MLP- und HONN-Topologie erst bei Betrachtung der Richtungsgütemaße deutlich. Die anderen Netztypen weisen zwar eine hohe Rendite aus und bilden sehr verlässlich den langfristigen Trend ab, jedoch besteht vor allem bei den MLP-Netzen die Gefahr sich auf Tagesbasis falsch zu positionieren, was durch das nicht ausreichend hohe Maß der Correct Direction aufgezeigt wird und somit keine eindeutigen Richtungssignale vorliegen. Zudem spricht der teils hohe Wert des Correct Direction Change für ungenaue Prognosen, die zu der Bildung von Mean-Preserving-Spreads führen und auf diese Weise ähnliche gute Gewinne generieren wie das HONN-SODD.

Der Blick auf die Tabelle (18) zeigt eindeutig die Verbesserung der Richtungsgütemaße gegenüber der Standard-HONN-Variante. Das Maß der Correct Direction liegt mit 90,16 Prozent mit mehr als zehn Prozent über dem HONN-Wert. Auch hat sich der RMSE um die Hälfte reduziert und zudem liegt der Correct Direction Change mit 1,52 Prozent acht Prozent unter dem Wert des HONN. Das Ergebnis zeigt, welche Unterschiede in der Prognosequalität erreicht werden können, wenn lediglich die Eingabestruktur der Inputdaten modifiziert wird.

HONN-SODD-Gütemaße				
	RMSE	Correct Long-Term-Trend	Correct Direction	Correct Direction-Change
Brent Gas	0,000603956	96,00%	89,19%	2,88%
Brent Heating	0,000202556	100,00%	97,62%	1,68%
Brent WTI	0,000109158	100,00%	88,24%	2,40%
Gas Heating	0,000515461	100,00%	87,50%	0,96%
WTI Gas	0,000140104	100,00%	96,30%	0,48%
WTI Heating	0,000168	100,00%	82,14%	0,72%
Portfolio 1/6	0,00028987	99,33%	90,16%	1,52%

Tabelle18: HONN-SODD-Gütemaße

HONN-SODD-Risikokennzahlen						
	Korrelations-Filter			Ungefiltert/ Transitiv-Filter		
	Max-DD	Calmar-Ratio	MAX-DD Generalisierung	Max-DD	Calmar-Ratio	Max-DD Generalisierung
Brent Gas	14,60%	2,9685	14,77%	16,93%	4,5302	23,45%
Brent Heating	10,73%	2,3989	10,83%	16,25%	2,3891	13,91%
Brent WTI	3,17%	3,4385	3,39%	4,73%	3,6186	5,44%
Gas Heating	15,40%	3,3422	16,48%	56,70%	1,4258	48,99%
WTI Gas	12,30%	3,1008	12,51%	20,22%	3,5491	21,69%
WTI Heating	9,60%	2,5281	10,58%	20,29%	1,9098	18,07%
Portfolio 1/6	10,97%	2,9628	11,43%	22,52%	2,9037	21,92%

Tabelle19: HONN-SODD-Risikokennzahlen

9 Fazit und Ausblick

In dem vorliegenden Paper wird die Prognose und der Handel von Öl-Futures-Spreads mit verschiedenen neuronalen Netztypen untersucht, welche mit dem Neurosimulationsprogramm FAUN 1.1 simuliert wurden. Die eingesetzten Netzarchitekturen sind Multi-Layer-Perceptrons, Higher-Order-Neural-Networks, sowie Higher Order-Neural-Networks mit Second Order Data-Delay. In Anlehnung an die Arbeit von Dunis et al. „Trading Futures Spread Portfolios: Applications of Higher Order and Recurrent Networks“ sollte diejenige Netzstruktur mit der besten Prognosequalität und somit der höchsten erzielbaren Rendite gefunden werden. Die Ergebnisse von Dunis et al. können jedoch nur teilweise bestätigt werden.

Zum einen führt der Einsatz von Prognose-Filtern nicht zu einer Steigerung der Rendite. Der Ertrag ist beim Korrelationsfilter sehr stark vom jeweiligen Markteinstiegs-/Ausstiegs-Schwellwert abhängig. Die Eignung des Transitiv-Filters hängt von der Anzahl der zusätzlichen Transaktionen gegenüber der ungefilterten Prognose ab. Insgesamt sind, gerade die HONN-(SODD) Prognosen, von so guter Qualität, dass sich der Einsatz von Filtern als nicht notwendig erweist. Auch verliert die Anwendung von Risikokennzahlen wie die Calmer-Ratio an Bedeutung, da es auf Grund der Prognosen, zumindest bei der HONN-SODD-Architektur, theoretisch möglich ist sich überwiegend auf der richtigen Marktseite zu platzieren.

Beim Vergleich aller Modelle, liefert die ungefilterte HONN-SODD-Prognose die höchste Rendite und die besten Generalisierungseigenschaften. Auf Grund der ausgezeichneten Validität des HONN-SODD-Ansatzes bei Verwendung von Rohdaten, wäre einerseits eine nächste Maßnahme die Robustheit der Topologie mit Hilfe anderer Underlyings zu bestätigen. Ein zweiter Schritt ist die Integration der Netzprognose als Entscheidungskriterium in ein automatisiertes Handelssystem um die Performance des Ansatzes unter realen Bedingungen zu testen. Eine mögliche Weiterentwicklung für ein Handelssystem wäre den Prognose-

horizont auf zwei oder mehrere Tage auszuweiten, umso eintägige Handelsentscheidungen zu vermeiden, welche die Transaktionskosten nicht decken. Diese Problematik könnte bei dem bestehenden Prognosesystem jedoch auch mit dem Einsatz eines Schwellwerts gelöst werden, welcher die Transaktionskosten als Mindestwert für prognostizierte Renditen vorgibt, um in den Markt einzusteigen.

Im Hinblick auf die vorliegenden Ergebnisse ist zusammenfassend festzuhalten, dass die Anwendung von Neuronalen Netzen als Hilfsinstrument für die Entscheidungsfindung eine wertvolle Alternative darstellen.

Quellenverzeichnis

- Backhaus, K. und Erichson, B. und Plinke, W.** (2006), *Multivariate Analysemethoden. Eine anwendungsorientierte Einführung: Eine Anwendungsorientierte Einführung*, Springer Verlag, Auflage 11, 831 Seiten
- Bertolini, L. und Grothmann, R. und Schäfer, A. M. und Tietz, Ch. und Zimmermann, H. G.,** *A Technical Trading Indicator Based on Dynamical Consistent Neural Networks*
- Breitner, M. H.** (2003), *Nichtlineare, multivariate Approximation mit Perzeptoren und anderen Funktionen auf verschiedenen Hochleistungsrechnern*, Akademische Verlagsgesellschaft Aka, 520 Seiten
- Burke, S. P. und Hunter J.** (2005), *Modelling Non-Stationary Economic Time Series: A Multivariate Approach*, Palgrave Macmillan, 256 Seiten
- Dagum, E. B. und Cholette P. A.** (2006), *Benchmarking, Temporal Distribution, and Reconciliation Methods for Time Series*, Springer Verlag, 410 Seiten
- Dunis, Ch. L. und Laws, J. und Evans, B.** (2004), *Trading Futures Spreads: An Application of Correlation*, CIBEF and Liverpool John Moores University
- Dunis, Ch. L. und Laws, J. und Evans, B.** (2006), *Applied Financial Economics*, School of Accounting Finance and Economics
- Dunis, Ch. L. und Laws, J. und Evans, B.** (2008), *Trading and Filtering Futures Spread Portfolios: Further Applications of Threshold and Correlation Filters*, CIBEF and Liverpool Business School
- Dunis, Ch. L. und Laws, J. und Sermpinis, G.** (2009), *Modelling and Trading the Realised Volatility of the FTSE100 Futures with Higher Order Neural Networks*, Liverpool Business School, CIBEF Liverpool John Moores University
- Fahrmeir, L. und Künstler, R. und Pigeot I. und Tutz G.** (2002), *Statistik. Der Weg zur Datenanalyse*, Springer Verlag, 592 Seiten
- Futures Magazin für technisches Trading** Dezember 2006 8. Jahrgang
- Franke, J. und Hafner, Ch. M. und Härdle, W.** (2004), *Einführung in die Statistik der Finanzmärkte*, Springer Verlag, Auflage 2, 432 Seiten
- Franses, P. H.** (1998), *Time Series Models for Business and Economic Forecasting*, Cambridge University Press, 292 Seiten
- Giles, L. and Maxwell, T.** (1987), "Learning Invariance and Generalization in High-Order Neural Networks", *Applied Optics*, 26, 23, 4972-4978.
- Guégan, D. and Huck, N.** (2004), "Forecasting Relative Movements Using Transitivity?" *Institutions et Dynamiques Historiques de l'Economie, Working papers*, December 2004
- Hansen, J. V. and Nelson, R. D.** (2003), *Forecasting and Recombining Time-Series Components by Using Neural Networks*, Palgrave Macmillan Journals on behalf of the Operational Research Society
- Hassler, U.** (2000), *Regression trendbehafteter Zeitreihen in der Ökonometrie*, VWF Verlag für Wissenschaft und Forschung, 292 Seiten
- Hill, T. und O'Connor, M. und Remus, W.** (1996), *Neural Network Models for Time Series Forecasts*, INFORMS
- Hull, J. C.** (2005), *Optionen, Futures und andere Derivate*, Pearson Studium, Auflage 6, 945 Seiten
- Kausch, H.** (2007), *Zeitreihenprognose: Entwurf einer Software unter Verwendung Künstlicher Neuronaler Netze*, VDM Verlag Dr. Müller, 84 Seiten

- Lämmel, U. und Cleve, J.** (2001), Lehr- und Übungsbuch Künstliche Intelligenz, Fachbuchverlag Leipzig, 304 Seiten
- Lederman J. und Klein R. A.** (1996), Börsenhandel mit künstlicher Intelligenz, Hoppenstedt Publishing, 442 Seiten
- Lukassek, E. J.** (2005), Künstliche Neuronale Netze zur Prognose ökonomischer Zeitreihen, Shaker, 271 Seiten
- Melamed, L.** (1981), "Futures Market Liquidity and The Technique of Spreading", *Journal of Futures Markets*, 1, 405-411.
- Mertens (2004)** Prognoserechnung, 6 Auflage Springer Verlag 511 Seiten
- Rey, G. D. und Wender, K. F.** (2008), Neuronale Netze: Eine Einführung in die Grundlagen, Anwendungen und Datenauswertung, Huber Verlag, 207 Seiten
- Rinne, H. und Specht, K.** (2002), Zeitreihen: Statistische Modellierung, Schätzung und Prognose, Vahlen Verlag, 603 Seiten
- Stern, H. S.** (1996), Neural Networks in Applied Statistics, American Statistical Association and American Society for Quality
- Thiesing, F. M.** (1998), Analyse und Prognose von Zeitreihen mit Neuronalen Netzen, Shaker Verlag, 275 Seiten
- Tsay, R. S.** (2001), Analysis of Financial Time Series, Wiley-Interscience, 472 Seiten
- Walde, J. F.** (2005), Design künstlicher neuronaler Netze: Ein Leitfaden zur effizienten Handhabung mehrschichtiger Perzeptrone, Gabler Verlag, 159 Seiten
- Wilbert, R.** (1996), Interpretation und Anwendung Neuronaler Netze in den Wirtschaftswissenschaften, Peter Lang Verlag, 382 Seiten
- Zell, A.** (1997), Simulation Neuronaler Netze, Oldenbourg Verlag, 624 Seiten
- Zhang, Patuwo, Hu,** (1998) International Journal of Forecasting Band 14, , S. 35–62.

Anhang

Faun-Parametereinstellungen

Netztopologien und FAUN Parametereinstellungen						
Spread Mlp	Neuronen Hidden-Layer	Worst accepted Crossvalidation	Times without CV	Shortcut-Verbindung	RMSE	Anzahl Gewichte
Brent-Gas	2	1.0	2	ja	0,002253	37
Brent-Heating	2	1.1	10	ja	0,001525	37
Brent-WTI	2	1.1	3	ja	0,000850	37
WTI-Heating	2	1.4	2	ja	0,003188	37
WTI-Gas	2	1.0	2	ja	0,001304	37
Gas-Heating	2	1.1	3	ja	0,003188	37
Spread HONN	Neuronen Hidden-Layer	Worst accepted Crossvalidation	Times without CV	Shortcut-Verbindung	RMSE	Anzahl Gewichte
Brent-Gas	1	1.2	2	ja	0,001045	37
Brent-Heating	1	1.4	2	ja	0,000293	37
Brent-WTI	1	1.1	2	ja	0,000304	37
WTI-Heating	1	1.2	2	ja	0,000402	37
WTI-Gas	1	1.0	2	ja	0,000468	37
Gas-Heating	1	0.75	2	ja	0,001210	37
Spread HONN-SODD	Neuronen Hidden-Layer	Worst accepted Crossvalidation	Times without CV	Shortcut-Verbindung	RMSE	Anzahl Gewichte
Brent-Gas	1	1.2	2	ja	0,000604	37
Brent-Heating	1	1.2	2	ja	0,000203	37
Brent-WTI	1	1.1	5	ja	0,000109	37
WTI-Heating	1	1.1	2	ja	0,000168	37
WTI-Gas	1	1.0	2	ja	0,000140	37
Gas-Heating	1	1.1	2	ja	0,000515	37

MLP-Prognosen




Diagramm 1




Diagramm 2




Diagramm 3




Diagramm 4




Diagramm 5




Diagramm 6

Honn-Prognosen




Diagramm 7




Diagramm 8




Diagramm 9




Diagramm 10




Diagramm 11




Diagramm 12

HONN-SODD-Prognosen




Diagramm 13




Diagramm 14




Diagramm 15




Diagramm 16




Diagramm 17




Diagramm 18

IWI Discussion Paper Series/Diskussionsbeiträge

ISSN 1612-3646

- Michael H. Breitner, *Rufus Philip Isaacs and the Early Years of Differential Games*, 36 p., #1, January 22, 2003.
- Gabriela Hoppe and Michael H. Breitner, *Classification and Sustainability Analysis of e-Learning Applications*, 26 p., #2, February 13, 2003.
- Tobias Brüggemann und Michael H. Breitner, *Preisvergleichsdienste: Alternative Konzepte und Geschäftsmodelle*, 22 S., #3, 14. Februar, 2003.
- Patrick Bartels and Michael H. Breitner, *Automatic Extraction of Derivative Prices from Webpages using a Software Agent*, 32 p., #4, May 20, 2003.
- Michael H. Breitner and Oliver Kubertin, *WARRANT-PRO-2: A GUI-Software for Easy Evaluation, Design and Visualization of European Double-Barrier Options*, 35 p., #5, September 12, 2003.
- Dorothee Bott, Gabriela Hoppe und Michael H. Breitner, *Nutzenanalyse im Rahmen der Evaluation von E-Learning Szenarien*, 14 S., #6, 21. Oktober, 2003.
- Gabriela Hoppe and Michael H. Breitner, *Sustainable Business Models for E-Learning*, 20 p., #7, January 5, 2004.
- Heiko Genath, Tobias Brüggemann und Michael H. Breitner, *Preisvergleichsdienste im internationalen Vergleich*, 40 S., #8, 21. Juni, 2004.
- Dennis Bode und Michael H. Breitner, *Neues digitales BOS-Netz für Deutschland: Analyse der Probleme und mögliche Betriebskonzepte*, 21 S., #9, 5. Juli, 2004.
- Caroline Neufert und Michael H. Breitner, *Mit Zertifizierungen in eine sicherere Informationsgesellschaft*, 19 S., #10, 5. Juli, 2004.
- Marcel Heese, Günter Wohlers and Michael H. Breitner, *Privacy Protection against RFID Spying: Challenges and Countermeasures*, 22 p., #11, July 5, 2004.
- Liina Stotz, Gabriela Hoppe und Michael H. Breitner, *Interaktives Mobile(M)-Learning auf kleinen End-geräten wie PDAs und Smartphones*, 31 S., #12, 18. August, 2004.
- Frank Köller und Michael H. Breitner, *Optimierung von Warteschlangensystemen in Call Centern auf Basis von Kennzahlenapproximationen*, 24 S., #13, 10. Januar, 2005.
- Phillip Maske, Patrick Bartels and Michael H. Breitner, *Interactive M(obile)-Learning with UbiLearn 0.2*, 21 p., #14, April 20, 2005.
- Robert Pomes and Michael H. Breitner, *Strategic Management of Information Security in State-run Organizations*, 18 p., #15, May 5, 2005.
- Simon König, Frank Köller and Michael H. Breitner, *FAUN 1.1 User Manual*, 134 p., #16, August 4, 2005.
- Christian von Spreckelsen, Patrick Bartels und Michael H. Breitner, *Geschäftsprozessorientierte Analyse und Bewertung der Potentiale des Nomadic Computing*, 38 S., #17, 14. Dezember, 2006.
- Stefan Hoyer, Robert Pomes, Günter Wohlers und Michael H. Breitner, *Kritische Erfolgsfaktoren für ein Computer Emergency Response Team (CERT) am Beispiel CERT-Niedersachsen*, 56 S., #18, 14. Dezember, 2006.
- Christian Zietz, Karsten Sohns und Michael H. Breitner, *Konvergenz von Lern-, Wissens- und Personalmanagementssystemen: Anforderungen an Instrumente für integrierte Systeme*, 15 S., #19, 14. Dezember, 2006.
- Christian Zietz und Michael H. Breitner, *Expertenbefragung „Portalbasiertes Wissensmanagement“: Ausgewählte Ergebnisse*, 30 S., #20, 5. Februar, 2008.

IWI Discussion Paper Series/Diskussionsbeiträge

ISSN 1612-3646

Harald Schömburg und Michael H. Breitner, *Elektronische Rechnungsstellung: Prozesse, Einsparpotentiale und kritische Erfolgsfaktoren*, 36 S., #21, 5. Februar, 2008.

Halyna Zakhariya, Frank Köller und Michael H. Breitner, *Personaleinsatzplanung im Echtzeitbetrieb in Call Centern mit Künstlichen Neuronalen Netzen*, 35 S., #22, 5. Februar, 2008.

Jörg Uffen, Robert Pomes, Claudia M. König und Michael H. Breitner, *Entwicklung von Security Awareness Konzepten unter Berücksichtigung ausgewählter Menschenbilder*, 14 S., #23, 5. Mai, 2008.

Johanna Mählmann, Michael H. Breitner und Klaus-Werner Hartmann, *Konzept eines Centers der Informationslogistik im Kontext der Industrialisierung von Finanzdienstleistungen*, 19 S., #24, 5. Mai, 2008.

Jon Sprenger, Christian Zietz und Michael H. Breitner, *Kritische Erfolgsfaktoren für die Einführung und Nutzung von Portalen zum Wissensmanagement*, 44 S., #25, 20. August, 2008.

Finn Breuer und Michael H. Breitner, *„Aufzeichnung und Podcasting akademischer Veranstaltungen in der Region D-A-CH“: Ausgewählte Ergebnisse und Benchmark einer Expertenbefragung*, 30 S., #26, 21. August, 2008.

Harald Schömburg, Gerrit Hoppen und Michael H. Breitner, *Expertenbefragung zur Rechnungseingangsbearbeitung: Status quo und Akzeptanz der elektronischen Rechnung*, 40 S., #27, 15. Oktober, 2008.

Hans-Jörg von Mettenheim, Matthias Paul und Michael H. Breitner, *Akzeptanz von Sicherheitsmaßnahmen: Modellierung, Numerische Simulation und Optimierung*, 30 S., #28, 16. Oktober, 2008.

Markus Neumann, Bernd Hohler und Michael H. Breitner, *Bestimmung der IT-Effektivität und IT-Effizienz service-orientierten IT-Managements*, 20 S., #29, 30. November, 2008.

Matthias Kehlenbeck und Michael H. Breitner, *Strukturierte Literaturrecherche und -klassifizierung zu den Forschungsgebieten Business Intelligence und Data Warehousing*, 10 S., #30, 19. Dezember, 2009.

Michael H. Breitner, Matthias Kehlenbeck, Marc Klages, Harald Schömburg, Jon Sprenger, Jos Töller und Halyna Zakhariya, *Aspekte der Wirtschaftsinformatikforschung 2008*, 128 S., #31, 12. Februar, 2009.

Sebastian Schmidt, Hans-Jörg v. Mettenheim und Michael H. Breitner, *Entwicklung des Hannoveraner Referenzmodells für Sicherheit und Evaluation an Fallbeispielen*, 30 S., #32, 18. Februar, 2009.

Sissi Eklun-Natey, Karsten Sohns und Michael H. Breitner, *Buildung-up Human Capital in Senegal - E-Learning for School drop-outs, Possibilities of Lifelong Learning Vision*, 39 S., #33, July 1, 2009.

Horst-Oliver Hofmann, Hans-Jörg von Mettenheim und Michael H. Breitner, *Prognose und Handel von Derivaten auf Strom mit Künstlichen Neuronalen Netzen*, 34 S., #34, 11. September, 2009.

