Manche halten Neuronale Netze für eine Wunderwaffe, für andere sind sie eher Teufelszeug. Aber diese Technik ist längst kein Hirngespinst mehr, sondern hat Einzug in viele Anwendungsbereiche gefunden. Was dahinter steckt und wie Neuronale Netze konkret für das Trading eingesetzt werden können, zeigt der folgende Artikel.

Neuronale Netze im praktischen Einsatz

VON ANDREAS KNÖPFEL

Neuronale Netze (NN) sind eine sehr vielfältig einsetzbare Technik zur Datenverarbeitung. Wussten Sie zum Beispiel, dass Siemens NN zur Steuerung von Elekrostahlwerken einsetzt und damit den Energieverbrauch senkt? In Hautarztpraxen arbeiten NN schon seit 1997 für die Früherkennung von Melanomen und so mancher Fondmanager will auf sein Neuronales Netz auch nicht mehr verzichten.

Neuronale Netze finden heute auch Anwendung bei der Steuerung von Robotern, in der Biometrie, bei der Einschätzung der Kreditwürdigkeit von Kunden, in Qualitätprüfungsverfahren, und nicht zuletzt in der Finanzwirtschaft für die Analyse von Daten und bei der Erstellung von Prognosen.

Eine intelligente Technik?

Abstrakt gesagt sind Neuronale Netze Systeme aus einfachen Einheiten, die Informationen über Verbindungen zwischen diesen Einheiten verarbeiten. Ihre Aufgabe besteht darin, aus einem bestimmten Input einen Output zu berechnen. Die Bezeichnung *Neuronale Netze* entstand mit Blick auf das biologische Gehirn, bei dem ebenfalls eine Verarbeitung von Informationen durch hochvernetzte Einheiten erfolgt, nämlich den Nervenzellen. Analog zur Lernfähigkeit des Gehirns lassen sich auch NN für die verschiedensten Aufgaben *trainieren* (siehe auch Kasten *So funktionieren Neuronale Netze*).

Die Geschichte der Neuronalen Netze reicht zurück bis in die Mitte des 20. Jahrhunderts. Einen ersten Boom erlebten sie

So funktionieren Neuronale Netze

Es gibt zahlreiche Typen von Neuronalen Netzen, die sich in ihrer Architektur und in der Art der Verarbeitung der Daten unterscheiden. Gemeinsam ist allen Typen der Aufbau aus einzelnen miteinander verbundenen Zellen. Der am meisten eingesetzte Netztyp ist das Feedforward-Netz, bei dem die Zellen in Schichten angeordnet sind. Die Zellen können vollständig oder auch nur teilweise vernetzt sein.

B1) Vollständig vernetztes Feedforward-Netz

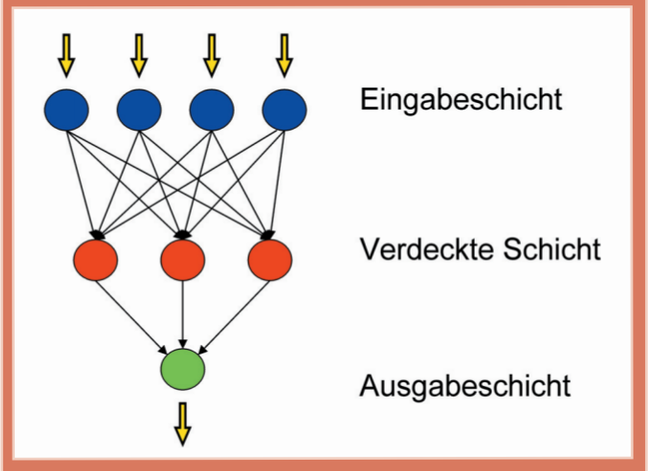

Die schematische Darstellung zeigt ein vollständig vernetztes dreischichtiges Feedforward-Netz. Die in die vier Inputzellen eingespeisten Daten werden in der verdeckten Schicht weiter verarbeitet. In der Ausgabeschicht wird der berechnete Output ausgelesen. Die Verarbeitung erfolgt in einer Richtung vom Input bis zum Output (feed forward). Ausgespart sind in diesem vereinfachten Schema Details wie die sogenannten Bias-Zellen, die zur Unterstützung des Trainings einen Schwellenwert simulieren.

Die Verarbeitung der Daten durch das Neuronale Netz erfolgt dadurch, dass die Verbindungen zwischen den Zellen ein unterschiedliches Gewicht erhalten. Damit das Netz die gewünschten Outputs liefert, müssen daher diese Verbindungsgewichte in einem Trainingsvorgang adjustiert werden. Mehrschichtige Feedforward-Netze verwenden dazu das sogenannte Backpropagation-Verfahren.

Bei diesem Verfahren wird das Neuronale Netz zunächst in einen zufälligen Anfangszustand gebracht. Danach werden die Trainingsbeispiele einzeln in das NN eingespeist und gemessen, welchen Fehler das NN in der Ausgabeschicht für das jeweilige Beispiel produziert. Anhand dieses Fehlerwertes können dann die Verbindungsgewichte korrigiert werden.

Bei näherem Interesse an der Technik finden sich weitere Informationen auf den im Kasten *Links* angegebenen Seiten.

Quelle: www.investox.de

ab 1986, als leistungsfähige Algorithmen für NN bekannt wurden. Die dadurch ausgelöste Euphorie mit sehr hochgesteckten Erwartungen führte fast zwangsläufig zu einer Enttäuschung. Während sich die breitere Öffentlichkeit dann recht schnell wieder von der neuen Technik verabschiedete, wurde sie von Forschern und Firmen stetig weiterentwickelt und findet seitdem Verwendung in immer mehr Gebieten und zahlreichen Produkten.

Neuronale Netze werden oft als so genannte *Künstliche Intelligenz* eingestuft. Dieser Begriff kann zu Missverständnissen führen, da er dem Wortlaut nach *Einsichtsfähigkeit* voraussetzt. Diese Fähigkeit wäre natürlich eine wichtige Voraussetzung für das Entwickeln von Theorien oder gar von Kreativität. An diesen hoch gesteckten Vorgaben scheitern aber alle bekannten Techniken, so auch NN. Auch diese sind nur dazu in der Lage, Daten auf eine im Prinzip genau festgelegte Art und Weise zu verarbeiten, wenn auch sehr effizient.

Stärken und Schwächen

Der Grund für das doch starke Interesse von Forschung und Industrie an Neuronalen Netzen sind deren besondere Eigenschaften, gerade auch mit Blick auf den Einsatz in der Finanzwirtschaft.

Ein Neuronales Netz kann mit beliebigen Daten gefüttert und auf die unterschiedlichsten Prognosen angesetzt werden. Durch die selbständige Lernfähigkeit ist es möglich, auch komplexe Zusammenhänge für eine Prognose dienstbar zu machen, ohne für diese Zusammenhänge selbst Regeln finden zu müssen. Ein gut trainiertes NN hat die Fähigkeit zur Generalisierung und kann auch in bisher unbekannten Situationen eingesetzt werden. Auch wenn die Daten unscharf, verrauscht oder gar fehlerhaft sind, das NN wird daraus dennoch immer einen Output berechnen.

Dem gegenüber stehen natürlich auch Nachteile. Aus einem Neuronalen Netz lassen sich keine Regeln ableiten, da es mehr oder weniger als Black-Box agiert. Die interne Verarbeitung der Daten durch das NN ist nicht transparent, wenngleich sie sich bei nicht allzu großen Netzen mit einigem Aufwand nachvollziehen lässt. Ein anderer Aspekt ist die Gefahr der Überoptimierung: Wenn ein NN zu mächtig ausgelegt wird, funktioniert es zwar sehr gut mit den trainierten Daten, umso schlechter jedoch im Realeinsatz mit bisher unbekannten Daten.

Der Zeitaufwand für die Entwicklung eines Neuronalen Netzes ist relativ hoch, da sinnvolle Einstellungen für das NN nur heuristisch durch Probieren ermittelt werden können. Dem gegenüber steht aber, dass dabei Modelle entstehen, deren Entwicklung mit herkömmlicher Formelsprache ebenfalls sehr aufwendig ist oder sogar gar nicht lösbar wäre.

Neuronale Netze (ein-)schätzen lernen

Ein Neuronales Netz ist kein Wundermittel, sondern ein Werkzeug, mit dem man erfolgreich arbeiten oder auch scheitern kann. Seine individuelle Gestalt erhält es beim Training anhand der zur Verfügung gestellten Musterdaten. Daher kann es auch seine Prognosen nur auf der Basis der trainierten Daten treffen. Dies verdeutlicht das folgende einfache Beispiel, bei dem

B2) Vergleich VW vs. US$

Die grau hinterlegten Rechtecke markieren einen Zeitbereich, in dem sich die VW-Aktie und der US$ gegenläufig entwickelt haben. In diesem Bereich tut sich das Neuronale Netz auf der Basis des US$ schwer, während das NN mit „prediktiver Korrelation“ als zusätzlichem Input besser abschneidet.

Quelle: www.investox.de

ein NN als Prognose ausgeben soll, wie sich der Kurs der Volkswagen-Aktie auf Sicht von 10 Tagen entwickelt.

Wir gehen in unserem Modell davon aus, dass der US$ für einen exportorientierten Titel wie VW eine wichtige Einflussgröße darstellt. Die Prognose soll daher zunächst ausschließlich aus der vergangenen Entwicklung des Wechselkurses US$/Euro abgeleitet werden. Als einzigen Input erhält das NN die prozentuale Kursänderung (Rate of Change) des US$ in den vergangenen 30 Tagen.

Das Neuronale Netz wird mit diesen Daten auf Tagesbasis ab 1987 trainiert. Dabei werden die Verbindungsgewichte zwischen dem Input (Kursänderung von US$) und dem Output (Kursänderung der Volkswagen-Aktie in 10 Tagen) so adjustiert, dass über den gesamten trainierten Zeitraum betrachtet der Outputfehler möglichst gering wird.

Im trainierten Zeitraum hat sich VW in der überwiegenden Anzahl der Tage analog zum Dollarkurs verhalten, ist also mit diesem gestiegen und gefallen. Das fertig trainierte NN wird nun genau auf dieser Basis auch die Prognosen treffen – VW wird bei starkem US$ steigen und umgekehrt. In der Wirklichkeit können sich diese Zusammenhänge natürlich jederzeit ändern und die Prognosen des Neuronalen Netzes werden fehlerhafter.

Um dem zu begegnen, können wir dem Neuronalen Netz natürlich weitere Inputdaten zur Verfügung stellen, damit es in der Lage ist, variabler auf die Umstände zu reagieren. Ein sinnvoller zusätzlicher Input in unserem Beispiel ist die so genannte *prediktive Korrelation*. Diese besagt, wie stark die Kursentwicklung von Volkswagen mit der Kursentwicklung des US$ zusammenhängt. Je stärker diese Korrelation ist, desto stärker wirkt sich die momentane Kursentwicklung des US$ auf den Kurs von VW aus.

Das NN erhält mit anderen Worten ein Maß dafür, welchen prognostischen Wert der US$ für VW zu einem bestimmten Zeitpunkt hatte. Wie Bild 2 zeigt, kann das so trainierte Neuronale Netz besser damit umgehen, wenn sich der Zusammenhang zwischen der VW-Aktie und dem US$ ändert.

Mit genügend vielen, gut ausgewählten Inputs lässt sich die Kapitalkurve des Handelssystems eines NN fast nach Belieben glätten. Dies ist allerdings eine Gratwanderung: Verwendet das NN zu wenige Inputs, sind die produzierten Drawdowns für einen praktischen Einsatz im Handel vielleicht zu groß und von zu langer Dauer. Verwendet man aber zu viele Inputs, wird das NN voraussichtlich durch das Training überoptimiert. Es arbeitet dann nicht mehr nach Zusammenhängen wie zum Beispiel „steigen-

Pivotberechnung

Alle Berechnungen beruhen auf den Kursen des vorigen Tages.

Pivotpunkt (PP):	(Close+High+Low) / 3
Widerstand 1:	2 * PP – Low
Widerstand 2:	PP + (High - Low)
Unterstützung 1:	2 * PP - High
Unterstüztung 2:	PP - (High - Low)

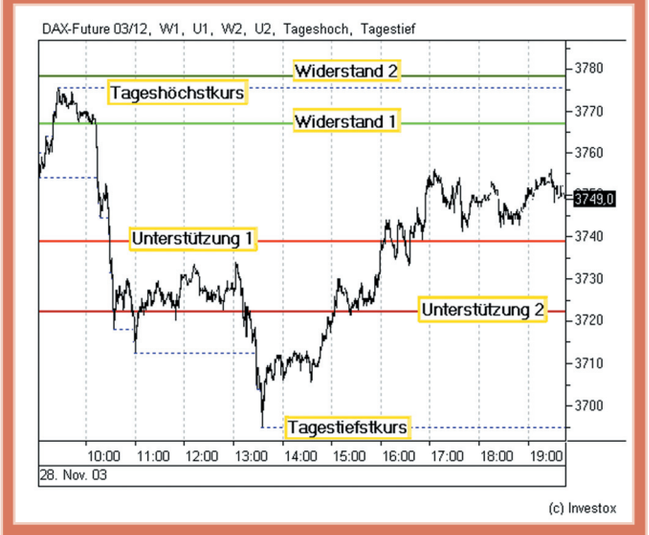

Der Tageschart zeigt die vom Neuronalen Netz als Inputs verwendeten Pivotlevels und das Tageshoch bzw. Tagestief. Letztere dienen dem NN als zusätzliche Orientierungshilfe.

Quelle: www.investox.de

B3) Pivotanalyse

Das Schaubild zeigt das gesamte Neuronale Netz zur Pivotanalyse nach dem Training. Die acht Inputs zuzüglich der sogenannten Bias werden zunächst in der verdeckten Schicht von den drei Hidden-Zellen verarbeitet. Die Gewichtematrix enthält entsprechend 9*3 = 27 Werte. Die Endverarbeitung erfolgt dann in der Ausgabeschicht durch die drei Verbindungsgewichte der einzigen Outputzelle (auch hier zuzüglich einer Biaszelle).

Inputs	Hidden 1	Hidden 2	Hidden 3
1: Abstand zu Pivot-W1	0,04739	0,14383	-0,17030
2: Abstand zu Pivot-U1	-0,27444	-0,31223	0,57790
3: Abstand zu Pivot-W2	-0,12036	-0,54471	0,20976
4: Abstand zu Pivot-U2	0,16290	-2,19668	1,25398
5: Abstand zum Tageshoch	-0,11071	-0,06433	0,13303
6: Abstand zum Tagestief	-0,11328	0,17487	0,11813
7: Kursänderung 10 min.	0,43000	-0,87031	-0,08584
8: Momentum 1200 min.	-0,01994	-0,05284	-0,20545
(Bias)	-0,19894	-0,37705	-0,25750

			(Bias)
-0,70746	-0,20018	-0,29972	-0,06136

Output

Quelle: www.investox.de

der US$ bringt steigenden VW-Kurs mit sich“, sondern speichert einfach die Einzelfälle ab. Wird ein solches NN dann mit unbekannten Daten eingesetzt, sind instabile Prognosen die Folge. Die Kunst beim Design eines NN liegt daher in der Wahl des geeigneten Mittelwegs: so viele Inputs wie nötig, aber so wenige wie möglich.

Ein Neuronales Netz analysiert Pivots

Eine etwas komplexere Anwendung für den Intraday-Handel soll nun noch ein Beispiel dafür geben, wie man ein Neuronales Netz für Handelsstrategien einsetzen kann.

Beim Erstellen einer Prognose kommt es öfters vor, dass man verschiedene Einflussfaktoren für relevant hält, jedoch keinen starren Zusammenhang zwischen diesen Faktoren kennt und verwenden möchte. In solchen Fällen kann der Einsatz eines NN sinnvoll sein.

Ein Beispiel hierfür sind die bei Tradern beliebten Pivot-Punkte. Diese Widerstands- und Unterstützungslinien werden im Intraday-Chart aus den Kursen des Vortages berechnet (siehe Kasten *Pivotberechnung,* Seite 15). Beim diskretionären Handeln orientieren sich viele Trader an diesen Levels, um mögliche Kursziele zu setzen. Die Umsetzung in ein mechanisches Handelssystem ist aber eher kompliziert, da viele verschiedene Fälle des typischen Verhaltens der Kurse zu unterscheiden sind, je nachdem welche Levels in welchem Umfeld auf welche Weise berührt oder aber auch nur angezielt werden.

Anstatt zu versuchen, diese Fälle mit einem Regelwerk zu erfassen und daraus eine profitable Strategie zu bilden, kann man diese Arbeit auch einem Neuronalen Netz übertragen. Wir trainieren dazu ein Neuronales Netz mit dem Dezemberkontrakt 2003 des FDAX auf 1-Minuten-Basis. Das Neuronale Netz soll eine Prognose der Kursänderung der nächsten 10 Minuten abgeben (unter *www.investox.de/anwendungen/nnpivot.htm* finden Sie ein Video, mit dem Sie den Aufbau des folgenen NN bequem nachvollziehen können).

Als Input erhält das Neuronale Netz den Abstand des aktuellen Tageskurses zu den Unterstützungs- und Widerstandslinien sowie die Kursänderung der vergangenen 10 Minuten und das Momentum über 20 Stunden. Wir verwenden ein Feedforward-Netz mit einer verdeckten Schicht aus drei Hiddenzellen (siehe Bild 3). Auf der Basis dieser Daten werden im Trainingsvorgang die Verbindungsgewichte so adjustiert, dass der Output über alle Trainingsdaten hinweg betrachtet einen möglichst geringen Fehler produziert.

Bei einem Neuronalen Netz für den Intradaybereich ist zu beachten, dass die Intraday-Kursschwankungen in der Regel viel geringer ausfallen als der Kurssprung vom Close zum Open. Das Overnight-Gap würde daher die meiste Aufmerksamkeit des NN beim Training auf sich ziehen und das Training der anderen Datenbereiche beeinträchtigen. Daher trainieren wir das NN nur jeweils mit Daten zwischen 9:10 und 13:00 Uhr und sparen damit sowohl das Overnight-Gap aus wie auch den Nachmittag, bei dem oftmals Nachrichten aus Übersee verstärkt ihren Einfluss ausüben.

Nach dem Training, das mit entsprechender Software nur wenige Minuten dauert, produziert das Neuronale Netz dann Outputwerte, die um die 0-Linie herum oszillieren – entsprechend der gelernten Prognose der Kursänderung über 10 Perioden (siehe Bild 4).

B4) Beispielhandelstag

Beispiel eines Handelstages mit dem Neuronalen Netz und der Kapitalkurve. Signale werden nur erzeugt, wenn der Output des Neuronalen Netzes das eingestellte Limit (hier 0,1 / -0,1) über- bzw. unterschreitet.

Quelle: www.investox.de

Testergebnisse

Testergebnisse für das Handelssystem mit Pivot-NN

FDAX Märzkontrakt 2004 (das NN wurde mit Daten bis 11.12.2003 trainiert), 4€ Kosten pro Trade eingerechnet.

System Start	12.12.2003 09:00:00
System Ende	19.03.2004 10:36:00
Anzahl aller Trades	289
Perioden mit Trades	34,1%
Profitable Trades	66,44%
Netto-Profit	11.269,00 Euro
Durchschnittlicher Return	38,99 Euro
Median der Returns	58,50 Euro
Sharpe Ratio	5,09
Drawdown	-3.137,00 Euro

Alternative Ergebnisse, wenn Signale erst bei Outputs 0,5 / -0,5 erzeugt werden:

Anzahl aller Trades	61
Perioden mit Trades	25,3%
Profitable Trades (%)	68,85%
Netto-Profit	8.443,50 Euro
Durchschnittlicher Return	138,42 Euro
Median der Returns	96,00 Euro
Sharpe Ratio	4,89
Drawdown	-2.876,50 Euro

Damit wir das Neuronale Netz backtesten können und auch Handelsentscheidungen bekommen, bauen wir es in ein mechanisches Handelssystem ein. Die Regeln des Handelssystems sind sehr einfach: Gehe long, wenn der Output des NN den Wert von 0,1 übersteigt, gehe short, wenn der Output unter -0,1 fällt. Durch ein solches Limit für die Signalerzeugung filtern wir kleinere Schwankungen des Outputs ohne genügend Aussagekraft heraus.

Entsprechend den Trainingsvorgaben des Neuronalen Netzes ist auch das Handelssystem erst nach 9:10 und bis 13:00 aktiv und kommt daher ohne Overnight-Positionen aus. Um zu sehen, ob das NN nicht nur mit den trainierten Daten, sondern auch mit bisher unbekannten Daten vernünftig arbeitet, testen wir das so eingestellte Handelssystem mit dem nächsten FDAX-Kontrakt (siehe Kasten *Testergebnisse*).

Der Charakter des Handelssystems lässt sich durch die Art und Weise beeinflussen, in der das Neuronale Netz im Handelssystem eingesetzt wird. In vielen Fällen, wie auch hier in unserem Pivot-System, gilt: werden höhere Limits an den Output des NN angelegt, so fallen weniger Trades mit höherem durchschnittlichem Return an. Lassen wir in unserem Pivot-Beispiel Signale nur bei Outputwerten 0,5/-0,5 oder stärker zu, so fällt in der Regel nur ein Trade pro Tag an. Die kleineren Bewegungen werden stärker herausgefiltert und die Gewinne können wir laufen lassen.

Links

Einführung in die Technik:
http://wwwmath.uni-muenster.de/SoftComputing/lehre/material/wwwnnscript/startseite.html

Neurosimulator Toolbox für Bastler:
http://www-ra.informatik.uni-tuebingen.de/SNNS/

Software für den Einsatz von NN in Handelsstrategien:
http://www.investox.de

Anwendungsbeispiele für Handelssysteme:
http://www.handelssysteme-online.de

Anwendungen und Schulungen zu NN:
http://www.nrcm.de

Tips zur wenig verbreiteten deutschsprachigen Literatur zu NN:
http://www.investox.de/Links/Literaturtips.htm

Hier findet sich die umfangreiche englischsprachige Literatur zu NN:
http://www.nd.com/nnreference/nnref-finance.htm

Es ist natürlich auch möglich, die Prognosen des Neuronalen Netzes mit der Aussage anderer Indikatoren zu kombinieren. Eine Möglichkeit hierzu ist zum Beispiel, Einstiege nicht gegen einen ausgeprägten Trend zu erlauben. In unserem Pivot-Beispiel könnte dies so aussehen: Gehe nur Long, wenn das 50-Stunden-Momentum über 98 liegt; gehe nur Short, wenn das 50-Stunden-Momentum unter 102 liegt. Eine solche Absicherung gegen den Trend kann die längerfristige Stabilität eines Handelssystems deutlich erhöhen.

Zum Schluss

Die gezeigten Beispiele haben es vielleicht deutlich gemacht: der Einsatz von Neuronalen Netzen für mechanische Handelsstrategien stellt ein Werkzeug unter anderen dar. Es verschafft dem Trader ein mächtiges Mittel, auch komplexe Zusammenhänge in eine Strategie einfließen zu lassen. Zu beachten ist aber auch die Gefahr der Überoptimierung: Kein noch so elegant konstruiertes NN kann garantieren, dass es unter veränderten Marktbedingungen noch funktioniert – eine Einschränkung, die freilich für jede Art von Handelsstrategie gilt.

TRADERS´