

Kroll, Anne

Working Paper

Wettervorhersage mit vorwärts gerichteten neuronalen Netzen

Wismarer Diskussionspapiere, No. 03/2009

Provided in Cooperation with:

Hochschule Wismar, Wismar Business School

Suggested Citation: Kroll, Anne (2009) : Wettervorhersage mit vorwärts gerichteten neuronalen Netzen, Wismarer Diskussionspapiere, No. 03/2009, ISBN 978-3-939159-63-6, Hochschule Wismar, Fakultät für Wirtschaftswissenschaften, Wismar

This Version is available at:

<https://hdl.handle.net/10419/39182>

Standard-Nutzungsbedingungen:

Die Dokumente auf EconStor dürfen zu eigenen wissenschaftlichen Zwecken und zum Privatgebrauch gespeichert und kopiert werden.

Sie dürfen die Dokumente nicht für öffentliche oder kommerzielle Zwecke vervielfältigen, öffentlich ausstellen, öffentlich zugänglich machen, vertreiben oder anderweitig nutzen.

Sofern die Verfasser die Dokumente unter Open-Content-Lizenzen (insbesondere CC-Lizenzen) zur Verfügung gestellt haben sollten, gelten abweichend von diesen Nutzungsbedingungen die in der dort genannten Lizenz gewährten Nutzungsrechte.

Terms of use:

Documents in EconStor may be saved and copied for your personal and scholarly purposes.

You are not to copy documents for public or commercial purposes, to exhibit the documents publicly, to make them publicly available on the internet, or to distribute or otherwise use the documents in public.

If the documents have been made available under an Open Content Licence (especially Creative Commons Licences), you may exercise further usage rights as specified in the indicated licence.




Fakultät für Wirtschaftswissenschaften
Wismar Business School

Anne Kroll

Wettervorhersage
mit vorwärts gerichteten neuronalen Netzen

Heft 03 / 2009



Wismarer Diskussionspapiere / Wismar Discussion Papers

Die Fakultät für Wirtschaftswissenschaften der Hochschule Wismar, University of Technology, Business and Design bietet die Präsenzstudiengänge Betriebswirtschaft, Management sozialer Dienstleistungen, Wirtschaftsinformatik und Wirtschaftsrecht sowie die Fernstudiengänge Betriebswirtschaft, Business Consulting, Business Systems, Facility Management, Quality Management, Sales and Marketing und Wirtschaftsinformatik an. Gegenstand der Ausbildung sind die verschiedenen Aspekte des Wirtschaftens in der Unternehmung, der modernen Verwaltungstätigkeit im sozialen Bereich, der Verbindung von angewandter Informatik und Wirtschaftswissenschaften sowie des Rechts im Bereich der Wirtschaft.

Nähere Informationen zu Studienangebot, Forschung und Ansprechpartnern finden Sie auf unserer Homepage im World Wide Web (WWW): <http://www.wi.hs-wismar.de/>.

Die Wismarer Diskussionspapiere/Wismar Discussion Papers sind urheberrechtlich geschützt. Eine Vervielfältigung ganz oder in Teilen, ihre Speicherung sowie jede Form der Weiterverbreitung bedürfen der vorherigen Genehmigung durch den Herausgeber.

Herausgeber: Prof. Dr. Jost W. Kramer
Fakultät für Wirtschaftswissenschaften
Hochschule Wismar
University of Technology, Business and Design
Philipp-Müller-Straße
Postfach 12 10
D – 23966 Wismar
Telefon: ++49/(0)3841/753 441
Fax: ++49/(0)3841/753 131
E-Mail: jost.kramer@hs-wismar.de

Vertrieb: HWS-Hochschule Wismar Service GmbH
Phillipp-Müller-Straße
Postfach 12 10
23952 Wismar
Telefon:++49/(0)3841/753-574
Fax: ++49/(0) 3841/753-575
E-Mail: info@hws-wismar.de
Homepage: <http://cms.hws-wismar.de/service/wismarer-diskussions-brpapiere.html>

ISSN 1612-0884

ISBN 978-3-939159-63-6

JEL-Klassifikation C10

Alle Rechte vorbehalten.

© Hochschule Wismar, Fakultät für Wirtschaftswissenschaften, 2009.

Printed in Germany

Inhaltsverzeichnis

1.	Einleitung	5
1.1.	Motivation	5
1.2.	Zielsetzung	5
2.	Grundlagen	6
2.1.	Numerische Wettervorhersage	6
2.1.1.	Ablauf	6
2.1.2.	Datengewinnung	7
2.1.3.	Wettervorhersagemodelle	8
2.1.4.	Verifikation von Wettervorhersagen	10
2.1.5.	Grenzen der Wettervorhersagen	13
2.2.	Künstliche neuronale Netze	13
2.2.1.	Biologisches Vorbild	14
2.2.2.	Eigenschaften	15
2.2.3.	Anwendungen	16
2.2.4.	Bestandteile	16
2.2.5.	Architekturen	18
2.2.6.	Lernverfahren	20
2.2.6.1.	Hebbsche Lernregel	21
2.2.6.2.	Delta-Regel	21
2.2.6.3.	Backpropagation	22
2.2.6.4.	Backpropagation-Momentum	23
2.2.6.5.	Quickprop	24
2.2.6.6.	Resilient Propagation	24
3.	Wettervorhersage mit vorwärts gerichteten neuronalen Netzen	24
3.1.	Statistische Analyse der Daten des DWD	25
3.1.1.	Häufigkeitsverteilungen	26
3.1.2.	Korrelationen	29
3.2.	Datenvorverarbeitung	30
3.2.1.	Auswahl ein- und mehrdimensionaler Datenmengen	30
3.2.2.	Klassifizierung der Daten	33
3.2.3.	Codierung der Daten	33
3.2.4.	Trainings- und Testdatensätze für verschiedene Netzarchitekturen	35
3.3.	Aufbau verschiedener Netzarchitekturen	36
3.4.	Implementierung Fehlerermittlung	39
3.5.	Netzentwicklung	41
3.5.1.	Minimierung des Netzfehlers durch Änderung der Netzparameter	42

4		
3.5.2.	Minimierung des Netzfehlers durch Variation der Codierung	44
3.5.3.	Minimierung des Netzfehlers durch Variation der Netzarchitektur	46
3.6.	Auswertung der Experimente	46
4.	Schlussbemerkungen	50
5.	Ausblick	52
	Literaturverzeichnis	52
	Autorenangaben	53

1. Einleitung

1.1. Motivation

„Mecklenburg-Vorpommern ist ... das beliebteste Urlaubsreiseziel der Deutschen im Inland. Vor allem dem Sommerwetter und dem "goldenen Herbst" sei diese Entwicklung zu verdanken. ... Demnach reisten in diesem Sommer 21 Prozent der deutschen Urlauber, die im Inland Ferien machten, nach Mecklenburg-Vorpommern. ... Am deutlichsten profitierten davon Rostock, Wismar und Stralsund“.¹

Aussagen wie diese belegen die wirtschaftliche Rolle des Tourismus für Mecklenburg-Vorpommern. Neben dem maritimen Sektor, der Landwirtschaft sowie der daraus resultierenden Lebensmittelindustrie und der Gesundheitswirtschaft nimmt auch die immer deutlicher regenerativ geprägte Energiewirtschaft im Land zu. Hierbei fällt der Focus auf die Windenergie, welche durch die küstennahe und somit windreiche Lage an der Ostsee mittlerweile über ein Drittel des Strombedarfs Mecklenburg-Vorpommerns decken kann.²

Alle aufgeführten Wirtschaftszweige profitieren wegen ihrer Abhängigkeit vom Wetter von einer möglichst genauen und standortspezifischen Wettervorhersage.

„Der typische Urlauber in Mecklenburg-Vorpommern ... erwartet ... Sonne ..., möchte sich aktiv betätigen (baden, wandern, radeln)“³. Die Kapazitäten der touristischen Angebote des Landes könnten durch entsprechend spezielle Wettervorhersagen zeitnah angepasst werden. Vorstellbar ist an dieser Stelle beispielsweise die Verlagerung der gastronomischen Aktivitäten ins Freie, sobald das Wetter dementsprechend prognostiziert wird. Auch eine wetterspezifische Warenpräsentation und -auswahl ist denkbar.

Landwirten wäre es möglich, Saat- und Erntetermine speziell für ihren Standort zu planen und somit Ernteerträge zu steigern. Auch die Energieeffizienz von Windkraftanlagen kann durch passende Wetterprognose insbesondere der Windstärke und -richtung speziell im sehr kurzfristigen Bereich angehoben werden.⁴

1.2. Zielsetzung

Im Rahmen dieser Arbeit wird die Möglichkeit einer individuellen, das heißt

¹ http://www.welt.de/reise/article96292/Mecklenburg_Vorpommern_ist_beliebtestes_Urlandsziel_im_Inland.html (Zugriff: 20.09.2008; Welt online).

² http://service.mvnet.de/_php/download.php?datei_id=3087 (Zugriff: 20.09.2008; Ministerium für Arbeit, Bau und Landesentwicklung MV).

³ http://www.tmv.de/site/24_48/48.html (Zugriff: 20.09.2008; Tourismusverband Mecklenburg-Vorpommern).

⁴ http://www.daserste.de/wwiewissen/beitrag_dyn~uid,ms2cxysyz7uk7sol~cm.asp (Zugriff: 20.09.2008; Heinz Greuling).

standortabhängigen und kenngrößenspezifischen Wettervorhersage demonstriert. Dabei werden aber nicht die komplexen mathematischen Modelle der aktuellen Wettervorhersagen zu Grunde gelegt, sondern die Voraussage erfolgt mit Hilfe von künstlichen neuronalen Netzen. Diese bieten die Möglichkeit, Prognosen auch ohne die Kenntnis der umfangreichen atmosphärischen Zusammenhänge zu erstellen.

Durchgeführt werden die Untersuchungen repräsentativ für den Standort Rostock-Warnemünde mit den vom Deutschen Wetterdienst online zur Verfügung gestellten Daten. Dafür erfolgt eine Auswertung der Wetterdaten der Vergangenheit mit der Zielsetzung, ein neuronales Netz zu finden, das eine möglichst hohe Trefferquote bei der Vorhersage erzielt. Erreicht wird diese Absicht durch eine Variation der Eingabedatenmenge und dem daraus resultierenden Vergleich von ein- und mehrdimensionalen Prognoseverfahren. Am Beispiel verschiedener Netzarchitekturen und Datencodierungen wird die Lernfähigkeit neuronaler Netze genutzt, um kurz- und mittelfristige Wettervorhersagen zu treffen.

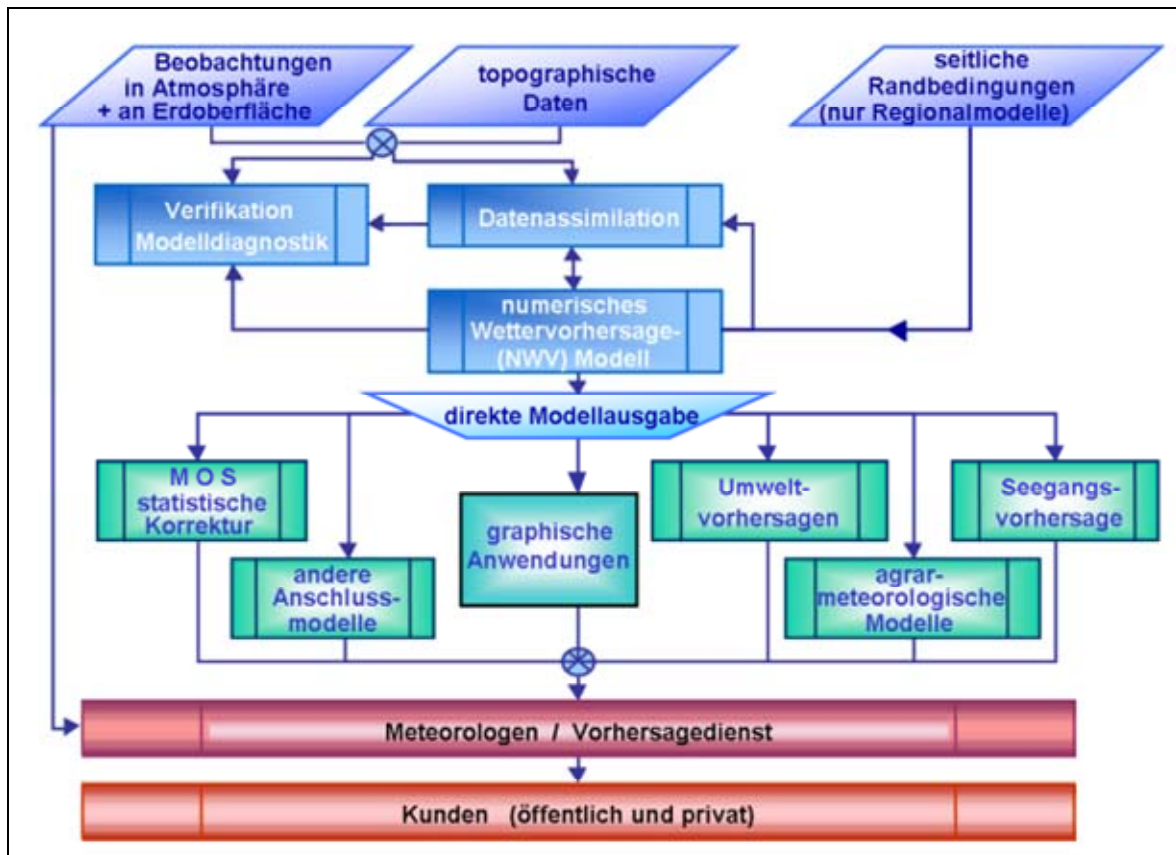
2. Grundlagen

2.1. Numerische Wettervorhersage

2.1.1. Ablauf

Die aktuellen numerischen Wettervorhersagen bilden auf der Grundlage der vergangenen und gegenwärtigen Wetterdaten durch die Simulation in unterschiedlichen Modellen die physikalischen und chemischen Zusammenhänge in der Atmosphäre und an der Erdoberfläche ab. Mit Hilfe von Differentialgleichungen wird anschließend näherungsweise für ausgewählte Standorte eine Vorhersage getroffen. Diese wird dann von Meteorologen interpretiert und in kundenspezifischen Karten oder Berichten wiedergegeben. Dabei entstehen beispielsweise Vorhersagen für Hochwasser und zu erwartenden Seegang oder für die Agrarwirtschaft. Diese Vorhersagen ebenso wie eventuelle Warnungen vor Unwetter können dann in den verschiedenen Medien abgerufen werden. Im Anschluss an eine Vorhersage erfolgt immer ein Vergleich mit dem tatsächlich eingetretenen Wetter, um die Modelle zu überprüfen und eventuell anzupassen. Abbildung 1 zeigt die Komponenten und den Ablauf der numerischen Wettervorhersage.

Abbildung 1: Komponenten eines numerischen Wettervorhersagesystems



Quelle: Deutscher Wetterdienst (http://www.dwd.de/bvbw/appmanager/bvbw/dwdwww/Desktop?_nfpb=true&_pageLabel=_dwdwww_spezielle_nutzer_hobbymeteorologen_vorhersage&T43402827281174304681546gsbDocumentPath=Content%2FOeffentlichkeit%2FKU%2FKUPK%2FHobbymet%2FVorhersagemodelle%2FAllgemein_teaser.html&_state=maximized&_windowLabel=T43402827281174304681546&lastPageLabel=_dwdwww_spezielle_nutzer_hobbymeteorologen_vorhersage (Zugriff: 20.09.2008)).

2.1.2. Datengewinnung

Zur Gewinnung der für die Simulation des Wetters benötigten Daten ist ein globales Netzwerk von Messstationen an repräsentativen Standpunkten erforderlich. Um die Dreidimensionalität des Vorhersagemodells zu ermöglichen, erfolgt die Messung und Beobachtung der physikalischen Größen und Wetterereignisse am und im Erdboden sowie in unterschiedlichen Höhen. Erfasst werden solche Messwerte durch den Einsatz von automatisierten Messstationen, mit Personal besetzten Wetterwarten, Wetterballons und geostationären sowie polarumlaufenden Wettersatelliten. Zusätzliche Daten liefern mit Messtechnik ausgestattete Handelsschiffe, Bojen und Verkehrsflugzeuge.

Das globale Modell setzt sich zum Beispiel aus 368.642 Gitterpunkten mit

je 40 über- und weiteren sieben unterirdischen Messpunkten zusammen.⁵

Zur weltweit einheitlichen Sicherung der Qualität der erfassten Daten, hat die Weltorganisation für Meteorologie Standards für Messverfahren, zum Beispiel Zeitpunkte der Messung, Genauigkeit der Instrumente oder das Datenformat, festgelegt. Nur durch eine solche Regelung ist es möglich, Wetterdaten international nutzen zu können.

2.1.3. Wettervorhersagemodelle

Die derzeitigen numerischen Modelle setzen sich aus drei Modellen mit verschiedener Auflösung zusammen. Zum Einen nutzt man hier das globale Modell, welches den gesamten Erdball mit Messpunkten in unterschiedlichen Höhen umspannt und für längerfristige Prognosen von bis zu sieben Tagen genutzt wird. Bereits eine deutlich höhere Genauigkeit wird mit den regionalen Modellen erreicht. Dabei ist je nach Standort ein anderes Modell, etwa das europäische Modell, zu nennen. Regionale Modelle ermöglichen die mittelfristige Wettervorhersage von zwei bis zu drei Tagen. Die feinste Auflösung wird mit dem jeweiligen Lokalmmodell, zum Beispiel für Deutschland, erzielt. Anhand dieser Modelle können Vorhersagen im kurzfristigen Bereich, das heißt von 24 Stunden getroffen werden.

Für extrem kurze Prognosen von nur einzelnen Stunden, die besonders in den Sommermonaten im Zusammenhang mit kurzen heftigen Gewittern notwendig werden, wird auf eine andere Methode zurückgegriffen. Diese Wetterradarsysteme erfassen, ebenfalls dreidimensional, Regen- oder Hagelechos und ermöglichen damit kurzfristige Unwetterwarnungen.

Repräsentiert werden diese Modelle durch ein System von Differentialgleichungen, die auf Grund ihrer Komplexität nur näherungsweise berechnet werden können. Doch selbst hierfür ist eine Vielzahl an Rechnern nötig, um den enormen Rechenaufwand zu bewältigen.

„Damit das numerische Wettermodell realistische Ergebnisse liefert, muss das Gitterraster sehr feinmaschig sein. Für jeden Rasterpunkt müssen ... viele Näherungsformeln berechnet werden, sonst wäre das Modell zu einfach für die Natur. Die Folge ist: Die Zahl der notwendigen Rechenschritte und der zu verarbeitenden Daten explodiert. Deshalb wächst die Leistungsfähigkeit der „Numerischen Wettervorhersage“ ... mit der Rechenleistung der Supercomputer.“⁶ Zum Beispiel unterhält der Deutsche Wetterdienst in seiner Zentrale alleine 30.000 PCs zusammengefasst zu einem Supercomputer.⁷ Dieser berechnet


⁵ <http://www.deutscher-wetterdienst.de/lexikon/download.php?file=Wettervorhersage.pdf> (Zugriff: 20.09.2008; Deutscher Wetterdienst).

⁶ <http://www.deutscher-wetterdienst.de/lexikon/download.php?file=Wettervorhersage.pdf> (Zugriff: 20.09.2008; Deutscher Wetterdienst).

⁷ <http://www.deutscher-wetterdienst.de/lexikon/download.php?file=Wettervorhersage.pdf> (Zugriff: 20.09.2008; Deutscher Wetterdienst).

„Für jeden Zeitschritt und für jeden Gitterpunkt ... zehn verschiedene Formeln ... - und zwar für jedes der 47 Stockwerke.“⁸ Abbildung 2 veranschaulicht einmal den Unterschied zwischen globalem und regionalem Modellnetzwerk und andererseits den dreidimensionalen Aufbau des Gitternetzes.

Abbildung 2: Das globale Modell mit dem eingebetteten regionalen Modell Europas



Quelle: Deutscher Wetterdienst (<http://www.deutscher-wetterdienst.de/lexikon/download.php?file=Wettersvorhersage.pdf> (Zugriff: 20.09.2008; Deutscher Wetterdienst)).

⁸ <http://www.deutscher-wetterdienst.de/lexikon/download.php?file=Wettersvorhersage.pdf> (Zugriff: 20.09.2008; Deutscher Wetterdienst).

2.1.4. Verifikation von Wettervorhersagen

Im Gegensatz zu den durch die Weltorganisation für Meteorologie standardisierten Messverfahren gibt es für die Verifikation, das heißt dem Abgleich zwischen Vorhersage und tatsächlich eingetretenem Wetter, keinen einheitlichen Standard. Diese Tatsache erschwert einen direkten Vergleich verschiedener Vorhersagemodelle erheblich, so dass Angaben, zum Beispiel zur Trefferquote von Vorhersagen für die kommenden 24 Stunden zwischen 85% und 95%, schwanken, aber trotzdem nicht vergleichbar sind. Dies ist der unterschiedlichen Interpretation des Begriffs „richtige“ Vorhersage geschuldet. Beispielsweise kann eine Maximaltemperaturvorhersage für den nächsten Tag mit einer Abweichung des eingetroffenen Wertes von lediglich zwei Kelvin je nach Festlegung als „richtige“ Prognose oder bereits als „falsch“ gewertet werden.

Einen objektiven Ansatz zur Berechnung zweier Maßzahlen für die Verifikation von Wettervorhersagen verwendet der Deutsche Wetterdienst. Dabei handelt es sich zum einen um den systematischen Fehler, auch bias genannt. Berechnet wird er mit der Formel:

$$\text{bias} = \sum_{i=1}^N d_i \qquad \begin{array}{l} d = \text{Prognosewert} - \text{Beobachtungswert} \\ N = \text{Anzahl der Wertepaare} \end{array}$$

Ein Wert von null entspricht dem Optimum, das heißt, die Vorhersage deckt sich mit der Beobachtung bei den betrachteten Wertepaaren. Da sich bei dieser Maßzahl allerdings positive und negative Abweichungen gegenseitig aufheben können, sind die Vorzeichen entweder zu vernachlässigen ($|d_i|$ an Stelle von d_i) oder die nachfolgende Fehlerermittlung ist zu bevorzugen.

Bei der zweiten objektiven Maßzahl handelt es sich um die mittlere, quadratisch gewichtete Abweichung *rmse*. Berechnet wird sie aus:

$$\text{rmse} = \sqrt{\frac{\sum_{i=1}^N d_i^2}{N}} \qquad \begin{array}{l} d = \text{Prognosewert} - \text{Beobachtungswert} \\ N = \text{Anzahl der Wertepaare} \end{array}$$


Auch hier entspricht ein $\text{rmse}=0$ einer völligen Übereinstimmung von Prognose und Beobachtung. Bei einem *rmse* größer null ist die Vorhersage fehlerhaft.⁹

Nachstehende Abbildung gibt ein Beispiel für den bias der Maximallufttemperatur in Kelvin am nächsten Tag für 14 Orte in Deutschland im Jahr 2000. Vorzeichen wurden in diesem Fall nicht in die Berechnung miteinbezogen. Bei einer Fehlertoleranz von nur 0,5 Kelvin sind ungefähr 25% der Prognosen als „richtig“ einzuordnen. Nimmt man jedoch 2,5 Kelvin als Summe der

⁹ <http://www.deutscher-wetterdienst.de/lexikon/download.php?file=Verifikation.pdf>
(Zugriff: 20.09.2008; Deutscher Wetterdienst, Thomas Kratzsch).

Abweichungen der Beobachtungswerte von den Prognosewerten in Kauf, ergibt sich eine Trefferquote von circa 85%.

Abbildung 3: *rmse der Maximallufttemperatur am nächsten Tag*



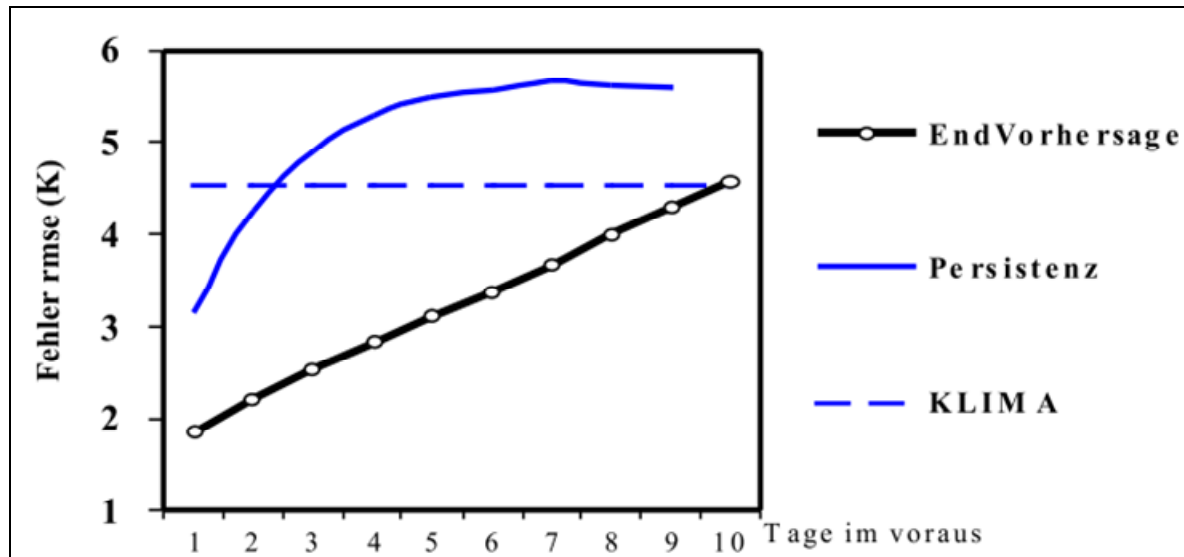
Quelle: Deutscher Wetterdienst (<http://www.deutscher-wetterdienst.de/lexikon/download.php?file=Verifikation.pdf> (Zugriff: 20.09.2008; Deutscher Wetterdienst, Thomas Kratzsch)).

Eine weitere Besonderheit in der Fehlerermittlung für Wettervorhersagen stellt die Tatsache dar, dass das Wetter eine Erhaltungsneigung besitzt. „Es neigt dazu, sich von Tag zu Tag nur innerhalb gewisser Schranken zu ändern“.¹⁰ Eine Vorhersage, die also ohne Berechnung das gleiche Wetter für den morgigen Tag prognostiziert, nennt man Persistenzvorhersage. Ein weiterer Wert, der zum Vergleich mit den errechneten Vorhersagen herangezogen werden muss, ist die Klimavorhersage. Sie gibt das normalerweise für den untersuchten Zeitraum zu erwartende Wetter wieder. Abbildung 4 vergleicht die Vorhersagegüte der drei Strategien. Daraus lassen sich drei Schlussfolgerungen ziehen. Erstens ist die Klimavorhersage nach zwei bis drei Tagen besser als die Persistenzvorhersage. Zweitens muss die Vorhersagegüte für mittelfristige und

¹⁰ <http://www.deutscher-wetterdienst.de/lexikon/download.php?file=Verifikation.pdf> (Zugriff: 20.09.2008; Deutscher Wetterdienst, Thomas Kratzsch).

längerfristige Vorhersagen immer mit der Klimavorhersage verglichen werden. Und drittens nimmt der rmse mit zunehmendem Vorhersagezeitraum ebenfalls zu, so dass nach einem bestimmten Zeitpunkt die „praktische Grenze der Vorhersagbarkeit mit rmse¹¹ erreicht wird.

Abbildung 4: Fehlervergleich dreier Strategien zur Vorhersage der täglichen Maximumtemperatur, Jahr 2000, 6 deutsche Orte



Quelle: Deutscher Wetterdienst (<http://www.deutscher-wetterdienst.de/lexikon/download.php?file=Verifikation.pdf>) (Zugriff: 20.09.2008; Deutscher Wetterdienst, Thomas Kratzsch).

Die nachstehende Tabelle zeigt beispielhaft Fehlerwerte des Deutschen Wetterdienstes für die Minimal- und Maximaltemperatur sowie die Sonnenscheindauer und die Windgeschwindigkeit bis zu sieben Tagen im Voraus, welchen jeweils der Klimavorhersagefehler gegenübersteht.

¹¹ <http://www.deutscher-wetterdienst.de/lexikon/download.php?file=Verifikation.pdf> (Zugriff: 20.09.2008; Deutscher Wetterdienst, Thomas Kratzsch).

Tabelle 1: *rmse im Jahr 2000, 6 Orte in Deutschland; Sonnenscheindauer in % der astronomisch möglichen*

Folgetag	1.	2.	3.	4.	5.	6.	7.	Klima	Einheit
Minimaltemperatur	1,52	2,05	2,32	2,58	2,84	2,93	3,17	4,04	K
Maximaltemperatur	1,85	2,22	2,54	2,83	3,11	3,37	3,67	4,53	K
Sonnenscheindauer	24,80	24,50	25,80	27,50	28,40	29,30	29,60	30,00	%
Windgeschwindigkeit	1,63	1,92	2,03	2,18	2,33	2,41	2,55	2,30	m/s

Quelle: Deutscher Wetterdienst (<http://www.deutscher-wetterdienst.de/lexikon/download.php?file=Verifikation.pdf> (Zugriff: 20.09.2008; Deutscher Wetterdienst, Thomas Kratzsch)).

2.1.5. Grenzen der Wettervorhersagen

Neben den systematischen Prognosefehlern, die sich aus der mangelnden Feinheit des jeweiligen Wettermodells ergeben, besteht das größte Hindernis einer exakten Wettervorhersage in dem chaotischen Verhalten des Wetters selbst. Der metaphorische, sogenannte Schmetterlingseffekt besagt, dass selbst der Flügelschlag eines Schmetterlings über kurz oder lang die Wetterentwicklung beeinflusst. Sobald sich der Wert einer physikalischen Größe im Anfangszustand der Simulation des Wettermodells auch nur minimal ändert, kann die Berechnung der deterministischen Gleichungen zu deutlich abweichenden Prognosen führen.

Auch zukünftige genauere Modelle und noch exaktere Messungen oder Beobachtungen werden diese Eigenschaft nicht völlig überwinden können.

2.2. Künstliche neuronale Netze

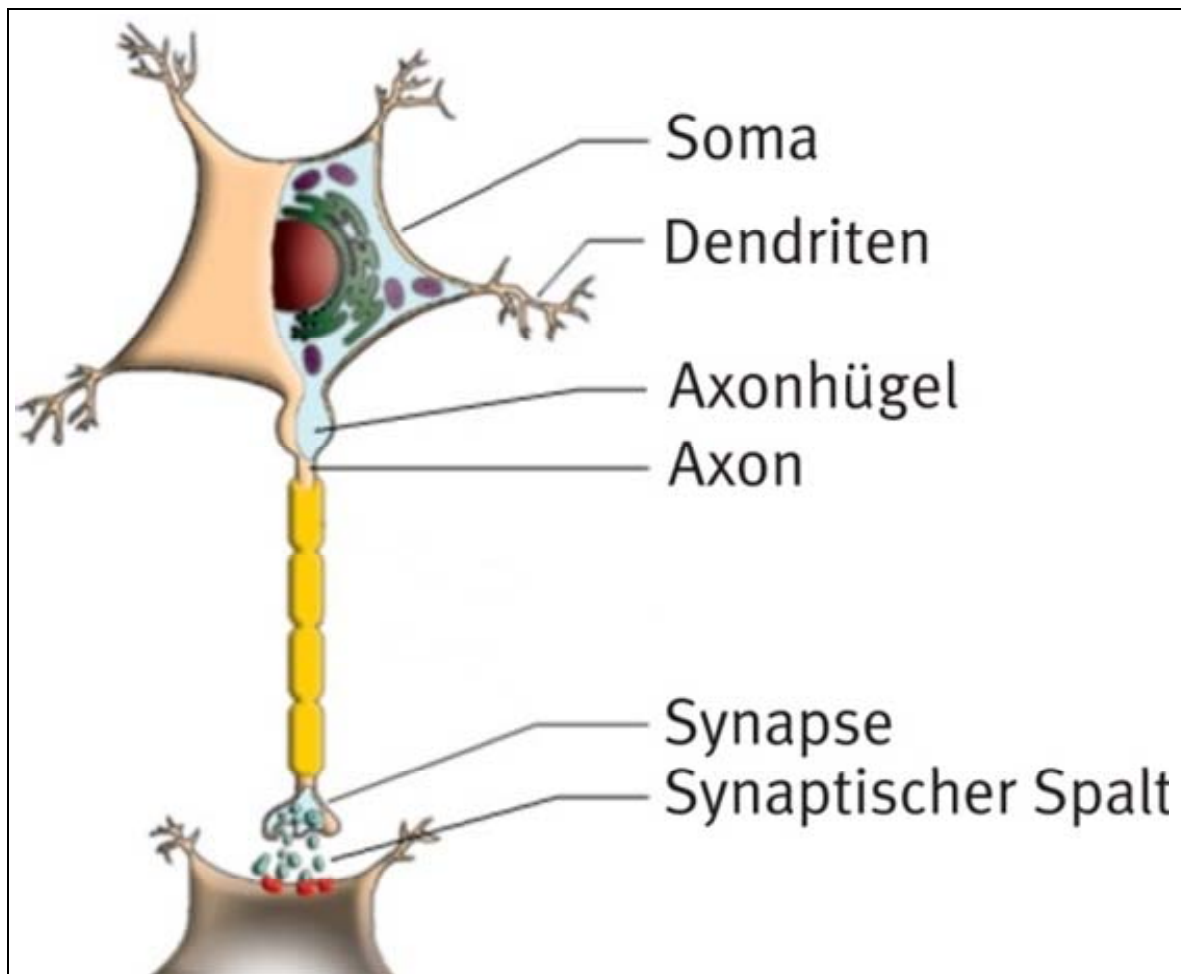
Künstliche neuronale Netze stellen eine mögliche Realisierung der Ziele des Data-Mining dar. Sie dienen der Mustererkennung in gegebenen Datenmengen und der Zuordnung neuer Datensätze zu gefundenen Klassen von Mustern.

Um dieses Vorhaben umzusetzen, imitieren neuronale Netze die Arbeitsweise des Gehirns. Sie sind abstrakte Nachbildungen des biologischen Vorbildes und versuchen durch Simulation der Neuronen des Gehirns dessen Funktionsweise abzubilden und daraus Vorteile gegenüber herkömmlichen Informationsverarbeitungssystemen zu erzielen. Zur Erklärung der Zusammenhänge zwischen künstlichen und natürlichen Neuronen, werden im Anschluss Aufbau und Funktion zusammenfassend vorgestellt.

2.2.1. Biologisches Vorbild

Den Grundbaustein der Gehirne von Menschen und anderen Wirbeltieren bilden die Nervenzellen. „Die meisten Schätzungen gehen von 100 Milliarden (10^{11}) Nervenzellen des Menschen aus.“¹² Abbildung 5 gibt einen Überblick über den Aufbau eines Neurons.

Abbildung 5: Vereinfachter Aufbau einer Nervenzelle



Quelle: Lukas Hensel (<http://www.lukashensel.de/biomain.php?biopage=neuron> (Zugriff: 20.09.2008)).

Das Soma, auch Zellkörper genannt, beinhaltet neben dem Zellkern noch weitere Organellen, die unter anderem der Energieversorgung und Produktion von Neurotransmittern dienen. Diese chemischen Botenstoffe sind für die Übertragung von Erregungen zwischen den Nervenzellen verantwortlich. An den Zellkörper grenzen die feinen Dendriten an. Sie sind meist stark verästelt und nehmen die Reize anderer Nervenzellen auf. Zu diesem Zweck verbinden die

¹² Zell, A.: Simulation neuronaler Netze (R. Oldenbourg Verlag; München; Nachdruck 2003).

Dendriten eine Nervenzelle mit „etwa 2.000 bis 10.000 Vorgängerzellen“.¹³ An das Soma schließt sich außerdem der Axonhügel als Ursprung des Axons an. „Dieser längliche Fortsatz leitet elektrische Nervenimpulse vom Zellkörper ... zur Synapse.“¹⁴ Sobald ein Reiz an der Synapse eintrifft, setzt sie die Neurotransmitter frei, so dass diese im synaptischen Spalt an eine angrenzende Nervenzelle übertragen werden können. In diesem Fall ist die Nachfolgerzelle aktiviert und kann ihrerseits den ankommenden Reiz an eine andere Zelle weitergeben. Auch der Grad der Aktivierung eines Neurons kann unterschieden werden. Dies geschieht durch Variation der Frequenz der Impulsweitergabe.

2.2.2. Eigenschaften

Zu den von natürlichen Nervensystemen übernommenen Eigenschaften zählen zum einen die Lernfähigkeit, das heißt das Vermögen ein gewünschtes Verhalten auf spezielle Eingabedaten anzupassen. Zum anderen sind auch künstliche neuronale Netze befähigt zu generalisieren und daher nicht nur gelerntes Verhalten bei gleicher Eingabe wiederzugeben, sondern auch auf neue Eingaben passend zu reagieren.

Überdies wird das Wissen verteilt gespeichert. Erst diese Eigenschaft erlaubt die parallele Bearbeitung von Informationen und „bewirkt ... eine höhere Fehlertoleranz des Gesamtsystems gegenüber Ausfall einzelner Neuronen oder Verbindungen.“¹⁵ Weiterhin verfügen künstliche Netze, genau wie das biologische Vorbild, über verhältnismäßig einfach strukturierte Verarbeitungselemente, die Neuronen. Zur Übertragung von Erregungen zwischen den Neuronen finden ebenso wie in der Natur gerichtete und gewichtete Verbindungen Verwendung. Sie übernehmen die Umsetzung der Lernfähigkeit, indem ihre Verbindungsgewichte angepasst werden. Außerdem erfolgt eine Kommunikation ausschließlich über die Verbindung zwischen einzelnen Neuronen und nicht wie in der algorithmischen Programmierung über abstrakte Datenstrukturen.¹⁶

Allerdings sind auch einige Unterschiede in den Eigenschaften künstlicher neuronaler Netze zu ihrem natürlichen Vorbild zu nennen. So ermöglichen Simulationen derzeit auf Grund der technischen Begrenzungen lediglich eine um mehrere Größenordnungen geringere Anzahl an Neuronen und Verbindungen. Einfluss auf die Stärke einer Verbindung kann im Gegensatz zu den

¹³ Zell, A.: Simulation neuronaler Netze (R. Oldenburg Verlag; München; Nachdruck 2003).

¹⁴ <http://www.lukashensel.de/biomain.php?biopage=neuron> (Zugriff: 20.09.2008; Lukas Hensel).

¹⁵ Zell, A.: Simulation neuronaler Netze (R. Oldenburg Verlag; München; Nachdruck 2003).

¹⁶ Zell, A.: Simulation neuronaler Netze (R. Oldenburg Verlag; München; Nachdruck 2003).

natürlichen Einflussmöglichkeiten zur Reizhemmung oder -intensivierung nur über das Gewicht einer Verbindung genommen werden. Auch wird bei künstlichen Neuronen der Grad der Aktivierung nicht durch Frequenzänderung beschrieben, „sondern ... mit einem numerischen Aktivierungswert, der eher einer Amplitudenmodulation entspricht.“¹⁷ Ein weiterer deutlicher Unterschied zu natürlichen Nervensystemen liegt in der Anwendung der Lernverfahren, welche mathematische oder physikalische Modelle zu Grunde legen und vor allem beim überwachten Lernen nicht dem biologischen Beispiel folgen.

2.2.3. Anwendungen

Geeignete Anwendungen der künstlichen neuronalen Netze ergeben sich aus deren Eigenschaften, wie der Lern- und Generalisierungsfähigkeit und der Tatsache, dass Aufgaben anhand von Beispielen gelöst werden, ohne die Notwendigkeit eines bekannten Lösungsweges für das gestellte Problem. Es bietet sich daher an, neuronale Netze zur Lösung von Fragestellungen zu nutzen, die auf dem Wege der algorithmischen Programmierung nicht oder nur ineffizient berechnet werden können. Als Beispiele sind hier etwa die Mustererkennung, speziell Text-, Sprach-, Bild- oder Gesichtserkennung. Weiterhin zählt die Analyse, Regelung und Prognose komplexer Prozesse, beispielsweise die Entwicklung von Aktienkursen oder die Steuerung autonomer Fahrzeuge zu den Anwendungsgebieten. Aber auch andere Probleme, die oben genannte Bedingungen erfüllen, können Verwendung für künstliche neuronale Netze finden.


2.2.4. Bestandteile

Künstliche neuronale Netze bestehen aus Neuronen, den gerichteten, gewichteten Verbindungen zwischen den Neuronen und einer Lernregel, einem „Algorithmus, gemäß dem das neuronale Netz lernt, für eine vorgegebene Eingabe eine gewünschte Ausgabe zu produzieren.“¹⁸

Abbildung 6 zeigt die Komponenten und Verarbeitungsschritte eines künstlichen Neurons.

¹⁷ Zell, A.: Simulation neuronaler Netze (R. Oldenburg Verlag; München; Nachdruck 2003).

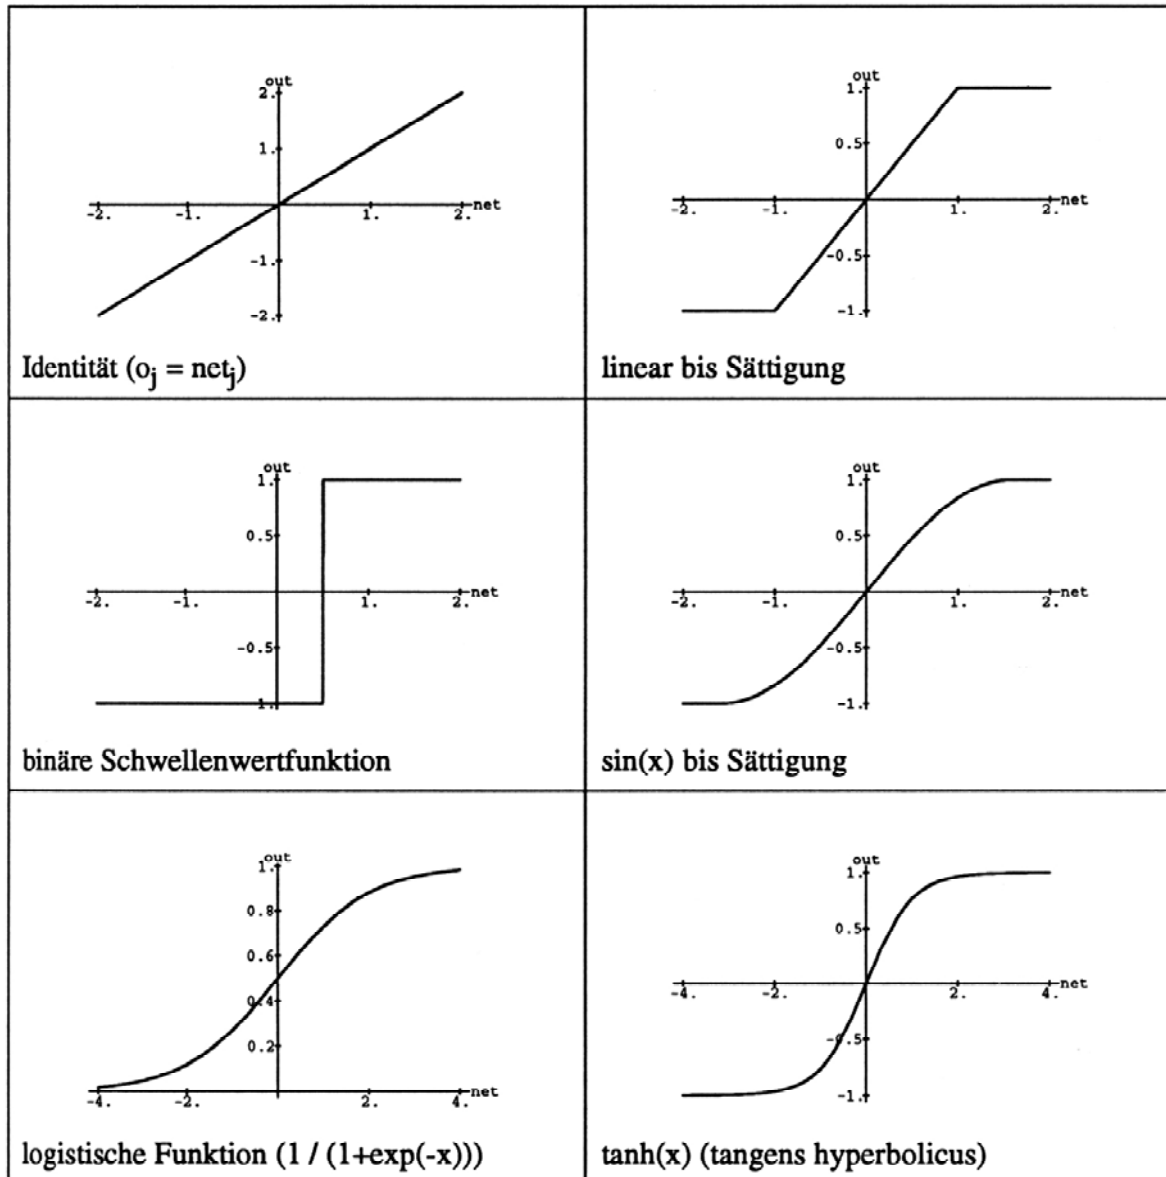
¹⁸ Zell, A.: Simulation neuronaler Netze (R. Oldenburg Verlag; München; Nachdruck 2003).

Abbildung 6: künstliches Neuron n 

Quelle: Lämmel, U.; Cleve, J.: Lehr- und Übungsbuch Künstliche Intelligenz (Fachbuchverlag Leipzig; Wismar; 2004; 2. Auflage).

Jedes Neuron n besitzt einen Aktivierungszustand a_n , der angibt, wie stark das Neuron angeregt ist. Zur Berechnung dieser Größe bedarf es einer Netzeingabe von außen oder der Eingabedaten o_j , die von anderen vorgeschalteten Neuronen j anliegen. Diese werden dann in Kombination mit den Gewichten w_{jn} an den Verbindungen zu dem Neuron n durch die Propagierungsfunktion $net_n = \sum_j w_{jn} * o_j$ ermittelt. Mit Hilfe dieses Wertes kann nun die Aktivität $a_n = f_{act}(net_n, \theta)$ errechnet werden, wobei θ den Schwellwert des Neurons angibt. Sobald die Netzeingabe net_n den Schwellwert θ überschreitet, ist das Neuron aktiviert. Die Ausgabe von n wird durch die zugehörige Ausgabefunktion $o_n = f_{out}(a_n)$ berechnet und wird damit erneut zur Eingabe anderer verbundener Neuronen. Ausgabe- und Aktivierungsfunktionen sind zum Beispiel die Identitätsfunktion, die Schwellenwertfunktion, die logistische Funktion oder der tangens hyperbolicus. Abbildung 7 gibt einen Überblick über einige mögliche Funktionen.

Abbildung 7: Mögliche Aktivierungsfunktionen




Quelle: Zell, A.: Simulation neuronaler Netze (R. Oldenburg Verlag; München; Nachdruck 2003).

2.2.5. Architekturen

Erst die Verknüpfung einzelner Neuronen über Verbindungen produziert ein neuronales Netz. Diese müssen nicht nur aus Eingabe- und Ausgabeneuronen bestehen, sondern können auch zwischen diesen beiden Schichten eine oder mehrere Verarbeitungsschichten, mit sogenannten verdeckten Neuronen, enthalten. Nachstehende Abbildung stellt dieses anschaulich dar.

Abbildung 8: Aufbau eines Netzes mit 5 Eingabeneuronen, 7 Neuronen in den Zwischenschichten und 4 Ausgabeneuronen



Quelle: Zell, A.: Simulation neuronaler Netze (R. Oldenburg Verlag; München; Nachdruck 2003).

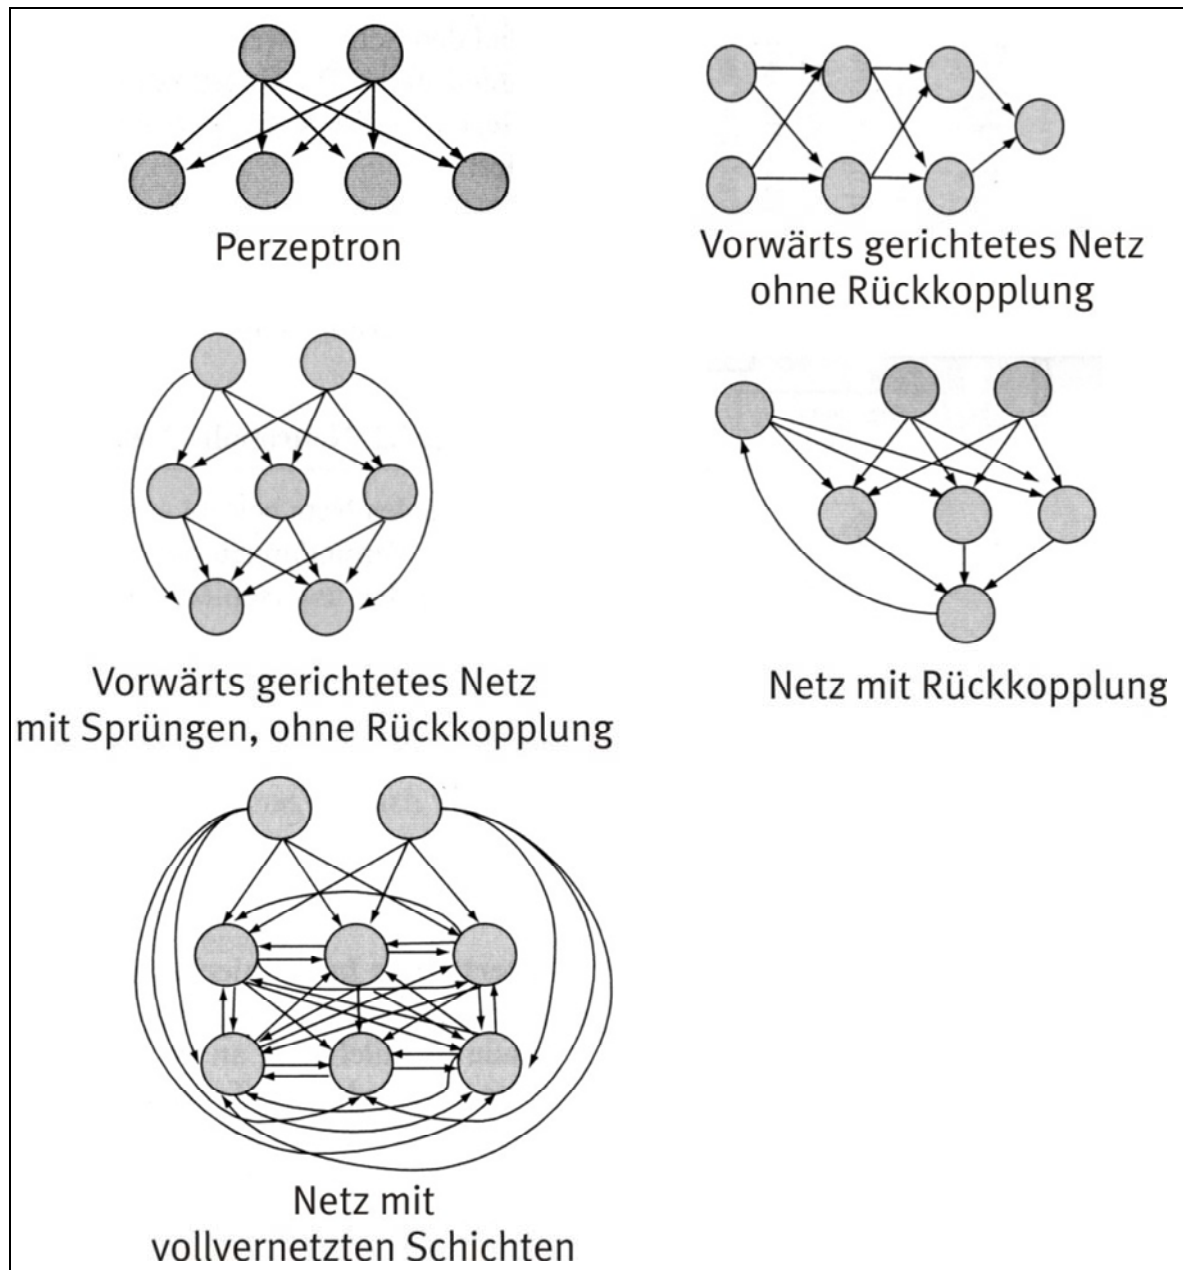
„Durch die Menge der Verbindungen werden unterschiedliche Architekturen definiert.“¹⁹ Bei den Architekturen neuronaler Netzwerke unterscheidet man zwischen Netzen, deren Neuronen ohne Rückkopplung verbunden sind, und denen, die Rückkopplungen beinhalten. Eine spezielle Architektur der vorwärts gerichteten Netze ohne Rückkopplung stellt das Perzeptron dar. Diese Topologie enthält nur eine Eingabeschicht von Neuronen und eine Ausgabeschicht. Zwischenschichten werden nicht verwendet.

Zu den Netzwerktopologien ohne Rückkopplung zählen einerseits die schichtweise vorwärts gerichteten Netze und andererseits vorwärts gerichtete Netze mit Abkürzungen, das heißt Verbindungen, die Schichten überspringen.

Rückkopplungen können nicht nur zwischen Neuronen verschiedener Schichten erfolgen, sondern auch von einem Neuron zu sich selbst oder von einem Neuron zum anderen innerhalb einer Schicht stattfinden. Ebenso sind vollständig verbundene Netzarchitekturen möglich. Einige übersichtliche Beispiele liefert Abbildung 9.

¹⁹ Lämmel, U.; Cleve, J.: Lehr- und Übungsbuch Künstliche Intelligenz (Fachbuchverlag Leipzig; Wismar; 2004; 2. Auflage).

Abbildung 9: Beispiele für Netzarchitekturen



Quelle: Lämmel, U.; Cleve, J.: Lehr- und Übungsbuch Künstliche Intelligenz (Fachbuchverlag Leipzig; Wismar; 2004; 2. Auflage).

2.2.6. Lernverfahren

Lernverfahren neuronaler Netze sind in drei Klassen untergliederbar. Die erste Klasse bildet das überwachte Lernen. Hierbei wird die Kenntnis der Eingabe und der gewünschten Ausgabe vorausgesetzt. Durch Training dieser Daten passt das Netz die Schwellwerte der Neuronen oder die Gewichte an den Verbindungen zwischen den Neuronen an, bis die gelernte Ausgabe sich mit der erwarteten Ausgabe deckt. Zusätzlich soll eine Generalisierung erreicht wer-

den, so dass auch unbekannte ähnliche Eingabemuster zu einer sinnvollen Ausgabe führen. Dieses Lernverfahren entspricht nicht dem biologischen Vorbild, führt aber schnell zum gewünschten Ergebnis.

Die zweite Klasse von Lernregeln bildet das bestärkende Lernen. Bei diesem Verfahren wird dem neuronalen Netz neben den Eingabemustern nur eine Ausgabe in Form von „richtig“ oder „falsch“ gegeben. Mögliche Ausgabemuster müssen selbstständig vom Netz gefunden werden. Einer geringeren Geschwindigkeit steht bei diesem Lernverfahren die größere Ähnlichkeit zum natürlichen Lernen gegenüber.

Beim unüberwachten Lernen, der dritten Klasse, wird dem Netz gar keine Information zur Ausgabe bereitgestellt. Ziel dieses Lernverfahrens ist die Zusammenfassung ähnlicher Eingabemuster in Klassen. Obwohl diese Lernregel am ehesten dem biologischen Vorbild folgt, ist sie im Gegensatz zu den vorherigen Verfahren nur für bestimmte Anwendungen geeignet.

2.2.6.1. Hebbsche Lernregel

„Die Hebbsche Lernregel ... ist die Grundlage für die meisten komplizierten Lernregeln. Sie besagt: Wenn Zelle j eine Eingabe von Zelle i erhält und beide gleichzeitig stark aktiviert sind, dann erhöhe das Gewicht w_{ij} (die Stärke der Verbindung von i nach j).“²⁰ Zur Berechnung der Gewichtsänderung Δw_{ij} wird folgende Formel genutzt.

$$\Delta w_{ij} = \eta o_i a_j$$

Die Konstante η gibt die Lernrate und somit die Stärke der Gewichtsänderung, o_i die Eingabe des Vorgängerneurons und a_j die Aktivierung des Nachfolgers an.

2.2.6.2. Delta-Regel

Im Gegensatz zur Hebbschen Lernregel, berechnet die Delta-Regel die Gewichtsänderung Δw_{ij} aus der Differenz δ_j der errechneten Aktivierung a_j des Nachfolgeneurons und der gewünschten Aktivierung t_j . Die entsprechende Formel lautet:

$$\Delta w_{ij} = \eta o_i (t_j - a_j) = \eta o_i \delta_j$$

Aus der Summe der Differenzen $\sum_j \delta_j$ der Ausgabeneuronen eines Eingabemusters lässt sich somit die Fehlerfunktion E_p berechnen. Da sich positive und negative Werte von δ_j aufheben können, wird der Fehler aus

²⁰ Zell, A.: Simulation neuronaler Netze (R. Oldenburg Verlag; München; Nachdruck 2003).

$E_p = \sum_j (\delta_{pj})^2$ errechnet. Der Gesamtfehler eines Netzes ergibt sich dann aus der Summe der einzelnen Musterfehler. Dieser kann durch einen Parameter vor der Summe ergänzt werden, um eventuelle Folgeberechnungen zu erleichtern oder grafische Verläufe des Netzfehlers übersichtlicher zu gestalten. Am prinzipiellen Kurs der Fehlerkurve ändert dies jedoch nichts.

$$E = \sum_p E_p$$

Diese Formel gilt auch für die anderen genannten Lernverfahren. Die Delta-Regel kommt nur beim Lernen mit dem Perzeptron und bei Anwendung einer linearen Aktivierungsfunktion zum Einsatz.

2.2.6.3. Backpropagation

Das Backpropagation-Lernverfahren zählt zur Klasse des überwachten Lernens und wird aufbauend auf der Delta-Regel für mehrstufige vorwärts gerichtete neuronale Netze und nichtlineare Aktivierungsfunktionen angewandt.

Der Ablauf des Verfahrens kann wie folgt beschrieben werden: Nachdem eine Eingabe am Netz anliegt, wird von Schicht zu Schicht eine zugehörige Ausgabe errechnet. Anschließend wird die berechnete Ausgabe des Netzes mit der gewünschten Ausgabe verglichen und, auf Grund des resultierenden Fehlers, eine Anpassung der Gewichte vorgenommen. Anschließend wird dem Netz erneut ein Eingabemuster unterbreitet.

Die Formel zur Berechnung der Gewichtsänderung Δw_{ij} stimmt mit der Delta-Regel überein.

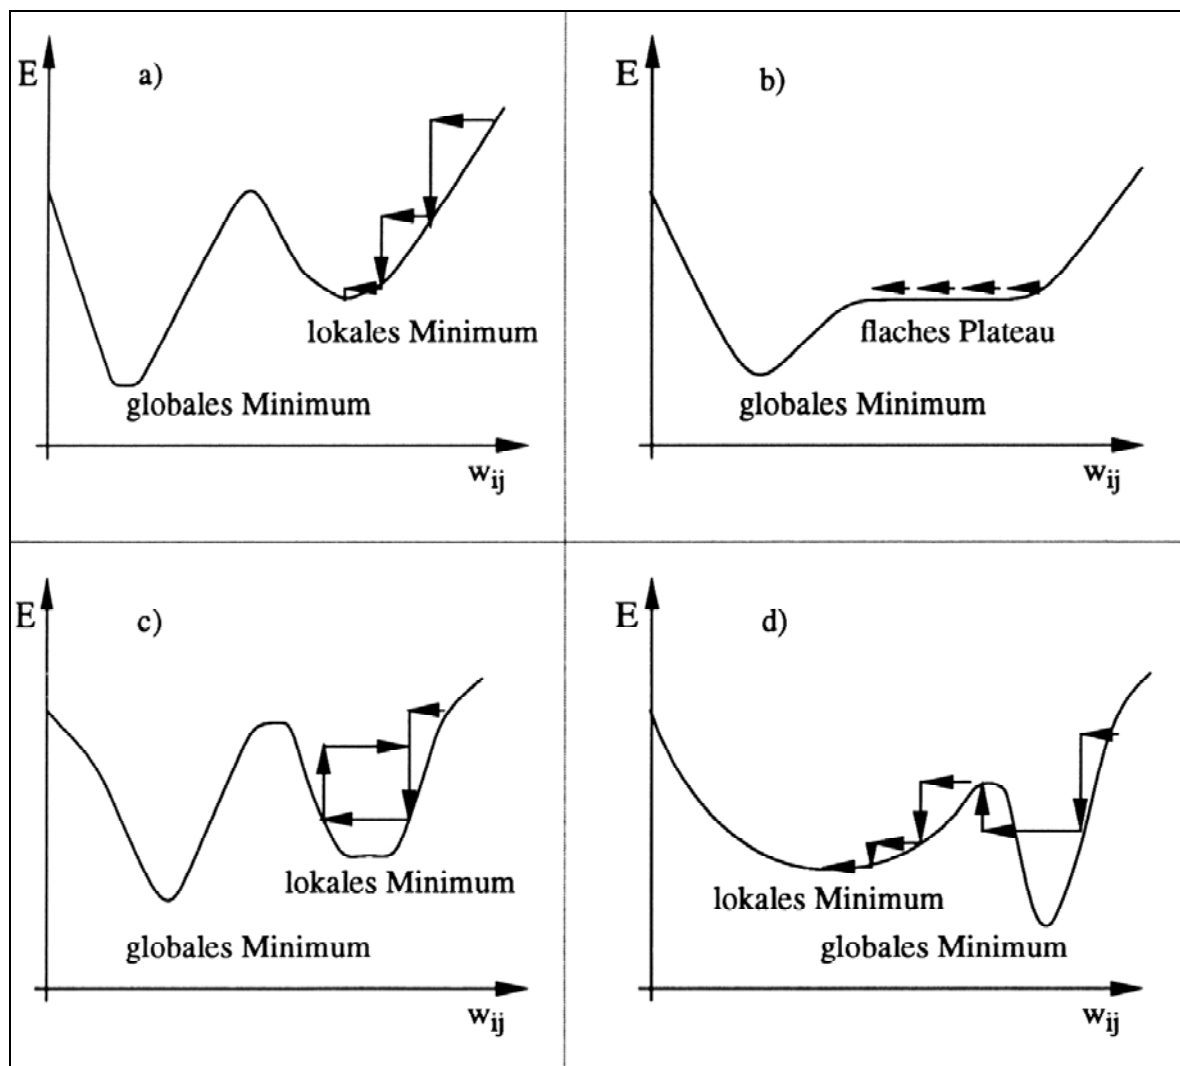
$$\Delta w_{ij} = \eta o_i (t_j - a_j) = \eta o_i \delta_j$$

Allerdings wird die Differenz δ_j für Neuronen aus verschiedenen Schichten unterschiedlich bestimmt. Unter Anwendung der logistischen Funktion zur Bestimmung der Aktivierung eines Neurons ergibt sich das Fehlersignal δ_j aus:

$$\delta_j = \begin{cases} o_j(1-o_j)(t_j - o_j) & \text{falls } j \text{ eine Ausgabezelle ist} \\ o_j(1-o_j) \sum_k (\delta_k w_{jk}) & \text{falls } j \text{ eine verdeckte Zelle} \end{cases}$$

Bei der Anwendung des Backpropagation-Verfahrens kann es zu Problemen kommen, das heißt die Minima der Fehlerkurve werden übersprungen oder das Auffinden der Minima beansprucht viel Zeit. Abbildung 10 veranschaulicht diese Fälle grafisch.

Abbildung 10: Mögliche Probleme beim Auffinden globaler Minima des Backpropagation Lernverfahrens



Quelle: Zell, A.: Simulation neuronaler Netze (R. Oldenburg Verlag; München; Nachdruck 2003).

Zur Vermeidung solcher Fälle empfiehlt es sich den Parameter η , den Wertebereich der Eingabe oder die Aktivierungsfunktion zu variieren. Führt dieser Lösungsansatz nicht zu besseren Ergebnissen, können folgende Modifikationen von Backpropagation angewendet werden.

2.2.6.4. Backpropagation-Momentum

„Es wird zusätzlich die vorherige Gewichtsänderung $\Delta w_{ij}(t-1)$ zum Zeitpunkt $t-1$ mit einbezogen. Ein Faktor μ zwischen 0 und 1 steuert den Anteil dieser Veränderung, so dass sich die aktuelle Gewichtsänderung zum Zeitpunkt t wie folgt formulieren lässt:

$$\Delta w_{ij}(t) = \eta o_i \delta_j + \mu * \Delta w_{ij}(t-1)^{21}$$

Durch diese Änderung wird die Gewichtsveränderung Δw_{ij} bei langwierigen Berechnungen beschleunigt und bei stark schwankenden Werten der Fehlerfunktion gebremst.

2.2.6.5. Quickprop

Beim Quickprop-Verfahren wird angenommen, dass sich die Fehlerfunktion durch eine Parabel abbilden lässt. Es wird daher das jeweilige lokale Minimum der Fehlerfunktion im Scheitelpunkt der Parabel bestimmt.

Quickprop kann schneller als die vorherig genannten Verfahren zu einem Ergebnis mit minimalem Fehler führen.

2.2.6.6. Resilient Propagation

Um den Betrag der Gewichtsveränderung bei diesem Lernverfahren zu bestimmen, werden die Vorzeichen des Anstiegs der Fehlerkurve zum aktuellen Zeitpunkt mit dem des vorherigen verglichen. Treten gleiche Vorzeichen auf, wird die Veränderung der Gewichte erhöht. Im Falle von verschiedenen Vorzeichen wird davon ausgegangen, dass ein lokales Minimum der Fehlerfunktion übersprungen wurde und die letzte Gewichtsveränderung wird zurückgesetzt. Anschließend wird sie mit kleinerem Betrag wiederholt. Je nach Anwendung kann Resilient Propagation noch schneller zu einem minimalen Fehlerwert führen als Quickprop. Allerdings kann dies zu Lasten der Generalisierungsfähigkeit des Netzes geschehen.

3. Wettervorhersage mit vorwärts gerichteten neuronalen Netzen

Die Wettervorhersage mit Hilfe von neuronalen Netzen bietet sich gerade deshalb an, weil auf dem numerischen Wege noch nicht alle möglichen Vorgänge bei der Wetterentstehung erforscht wurden. Somit wird der Einfluss der verschiedenen gesammelten Daten nur näherungsweise durch Modelle erklärt. Genau an dieser Schwachstelle der herkömmlichen Art das Wetter zu prognostizieren, können neuronale Netze ansetzen, da sie keinerlei Kenntnis des algorithmischen Lösungsweges voraussetzen. Die Vorhersage erfolgt ausschließlich aus der Analyse der Wetterdaten der Vergangenheit.

Auch die chaotische Eigenschaft des Wetters qualifiziert dessen Vorhersage für die Anwendung künstlicher neuronaler Netze, denn selbst in chaotischen Systemen sind Verhaltensmuster zu finden und genau danach suchen die neuronalen Netze.

²¹ Lämmel, U.; Cleve, J.: Lehr- und Übungsbuch Künstliche Intelligenz (Fachbuchverlag Leipzig; Wismar; 2004; 2. Auflage).

Im Rahmen dieser Arbeit werden die Daten vom Deutschen Wetterdienst genutzt. Sie stehen nach Standort der Messstationen sortiert zum kostenlosen Download bereit. Auf Grund des Umstandes, dass für den Standort Wismar keine Wetterdaten online zur Verfügung stehen, werden die nachfolgend beschriebenen Experimente mit dem Standort Rostock-Warnemünde durchgeführt. Die Anzahl der untersuchten Jahre wird wegen des enormen Rechenaufwandes auf acht begrenzt. Je nach Wetterstation stünden sogar Daten zurück bis zum Ende des neunzehnten Jahrhunderts zur Verfügung. Ebenso ist es denkbar, nicht nur die Informationen eines Standortes für die Analyse und Prognose des Wetters zu nutzen, sondern auch eine Auswahl geografisch nah gelegener Stationen oder sogar alle deutschen Standorte einzubeziehen. Auch hier setzt die für diese Arbeit zur Verfügung stehende Rechentechnik eine Grenze.

Ebenso wurde bei der Auswahl der Einflussgrößen und -zeiträume auf exemplarische Zusammenstellung geachtet, da auch hier das enorme Datenvolumen nicht in allen möglichen Kombinationen getestet werden kann.

Nichtsdestotrotz haben die durchgeführten Experimente repräsentativen Charakter und können als Vorlage für derartige Untersuchungen herangezogen werden. Die Aussagekraft der gewonnenen Erkenntnisse dieser Arbeit wird durch die genannten Einschränkungen aber nicht beeinträchtigt.

3.1. Statistische Analyse der Daten des DWD

Die vom Deutschen Wetterdienst bereitgestellten Daten enthalten verschiedenste physikalische Einflussgrößen des Wetters. Pro Tag werden circa 80 einzelne Werte aufgenommen. Manche von ihnen werden dreimal am Tag erfasst, so zum Beispiel die Temperatur und der Luftdruck. Nicht alle der aufgelisteten Größen stellen einen Messwert dar. Zu vielen der über den Tag mehrfach gemessenen Daten wird zusätzlich ein Mittelwert errechnet und angegeben.

Fast jeder Kenngröße ist ein Qualitätsbyte angefügt, welches angibt, ob die angegebenen Werte einer Qualitätskontrolle unterzogen wurden. Für die Wettervorhersage mit neuronalen Netzen spielt diese Zahl jedoch keine Rolle, ob ein Wert nach der Messung geprüft, bestätigt, ergänzt oder ersetzt wurde.

Die nachstehende Tabelle beinhaltet einen Auszug aus den verwendeten Größen mit Beispielwerten.

Tabelle 2: Beispiele für Kenngrößen des Deutschen Wetterdienstes

Abk.	Beschreibung	Messung/ Berechnung/ Beobachtung	Zeitpunkt der Messung/ Beobachtung/ Zeitraum der Be- rechnung	Einheit/ Codierung	Beispiel
P0	Luftdruck in Stati- onshöhe	Messung	6, 12, 18 Uhr	0,1 hPa	10187
PM	Tagesmittel des Luftdrucks in Stationshöhe	Berechnung	0-23 Uhr, 24 Werte	0,1 hPa	10182
TXX	Tagesmaximum der Temperatur der Luft in 2m Höhe	Messung	0-24 Uhr	0,1 °C	42
TNK	Tagesminimum der Temperatur der Luft in 2m Höhe	Messung	0-24 Uhr	0,1 °C	3
TT	Temperatur der Luft in 2m Höhe	Messung	6, 12, 18 Uhr	0,1 °C	15
TMK	Tagesmittel der Temperatur	Berechnung		0,1 °C	31
FK	Windstärke	Berechnung	6, 12, 18 Uhr	Bft	4
FMK	Tagesmittel der Windstärke	Berechnung	0-23 Uhr	0,1 Bft	30
DK	Windrichtung (in 32-teiliger Wind- rose)	Berechnung	6, 12, 18 Uhr	0=windstil 1 2= NNO 4= NO 6= ONO ...	28
N	Bedeckungsgrad mit allen Wolken	Beobachtung	6, 12, 18 Uhr	Achtel	8
SD	Tagessumme der Sonnenscheindauer	Beobachtung	0-24 Uhr	0,1 Std	25
RS	24-stündiger Nieder- schlag	Berechnung	6-6 Uhr	0,1 mm	17

Quelle: Deutscher Wetterdienst (http://www.dwd.de/bvbw/generator/Sites/DWDWWW/Content/Oeffentlichkeit/KU/KU2/KU21/klimadaten/german/download_kl2000_standardformat,templateId=raw,property=publicationFile.pdf/download_kl2000_standardformat.pdf (Zugriff: 20.09.2008; Deutscher Wetterdienst)).

3.1.1. Häufigkeitsverteilungen

Die Feststellung der Häufigkeitsverteilung jeder einzelnen Kenngröße ist nötig, damit eine sinnvolle Einteilung in Klassen möglich ist. Genaueres zu den

gewählten Klassen findet sich im Abschnitt 3.2.2. Klassifizierung der Daten.

Für alle bereitgestellten Maßzahlen sind Minimum, Maximum, Spannweite, arithmetisches Mittel, absolute Klasseneinteilung, klassifizierte relative Häufigkeitsverteilung, Häufigkeit der Fehlkennungen, mittlere absolute Abweichung, Standardabweichung, Variationskoeffizient und Schiefe angeführt.

Fehlkennungen beinhalten Werte, die vom Deutschen Wetterdienst bereits als falsch gekennzeichnet sind, aber nicht durch einen richtigen Wert ersetzt wurden. Da der relative Anteil der Fehlkennungen im Verhältnis zum gesamten Datenvolumen sehr gering ist, wurde bei diesen Fällen der Fehlerwert entfernt. Eine Löschung des Datensatzes des ganzen Tages kommt nicht in Frage, denn dadurch wäre die Abbildung des zeitlichen Ablaufs gestört.

Felder, die keinen Inhalt besitzen, werden im Zuge der Codierung auf null gesetzt. Auch dieser Anteil ist noch sehr klein und der Einfluss auf das Ergebnis kann vernachlässigt werden. Wie bei den Fehlwerten würde ein Entfernen der betroffenen Tage aus den Daten zu einer zeitlichen Verschiebung führen und wird daher nicht angewendet. Eine Ausnahme bilden hierbei die drei Kenngrößen zur Schneehöhe. Da es im gesamten betrachteten Zeitraum nur sechs Mal zu einer messbaren Schneehöhe kam, werden diese Größen im Weiteren nicht mehr eingeschlossen.

Auszugsweise Angaben für einige Luftdruck- und Temperaturwerte zeigt Tabelle 3 diese Analyse.

Tabelle 3: Häufigkeitsanalyse der Wetterdaten (Auszug)

	Luft- druck 6 Uhr	Luft- druck 12 Uhr	Luft- druck 18 Uhr	Luftdruck Durchschnitt	Maximum Tempera- tur	Minimum Tempera- tur
Minimum	9713	9731	9681	9747	-74	-133
10 %	9787,7	9803,7	9757,5	9817,6	-33,4	-98,2
20 %	9862,4	9876,4	9834	9888,2	7,2	-63,4
30 %	9937,1	9949,1	9910,5	9958,8	47,8	-28,6
40 %	10011,8	10021,8	9987	10029,4	88,4	6,2
50 %	10086,5	10094,5	10063,5	10100	129	41
60 %	10161,2	10167,2	10140	10170,6	169,6	75,8
70 %	10235,9	10239,9	10216,5	10241,2	210,2	110,6
80 %	10310,6	10312,6	10293	10311,8	250,8	145,4
90 %	10385,3	10385,3	10369,5	10382,4	291,4	180,2
Maximum	10460	10458	10446	10453	332	215
Spannweite	747	727	765	706	406	348
Arithmeti- sches Mittel	10127,53	10130,68	10129,15	10129,54	128,92	71,27
Häufigkeit der Fehlkennung	0	0	0	0	0	0
10 %	0,2	0,3	0,1	0,2	0,3	0,1
20 %	0,8	1,1	0,4	1,2	3,7	1,2
30 %	3,4	3,5	1,8	3,8	12,7	3,8
40 %	8,4	9,1	5,9	9,6	18,1	10,9
50 %	19,2	20,1	15,3	22,1	15,3	18,7
60 %	30,2	29,2	29,5	29,3	15,2	17,3
70 %	24,2	23,6	29,6	21,7	19,7	16,5
80 %	9,9	9,3	12,3	8,6	9,7	19,2
90 %	3,3	3,1	4,1	2,8	3,9	11,0
100 %	0,6	0,7	1,0	0,7	1,2	1,2
Mittlere abso- lute Abweichung	81,3	80,8	78,7	78,0	64,5	52,3
Standard- abweichung	104,1	103,6	101,6	100,0	75,8	61,8
Variations- koeffizient	0,01	0,01	0,01	0,01	0,59	0,87
Schiefe	-0,23	-0,22	-0,21	-0,15	0,07	-0,17

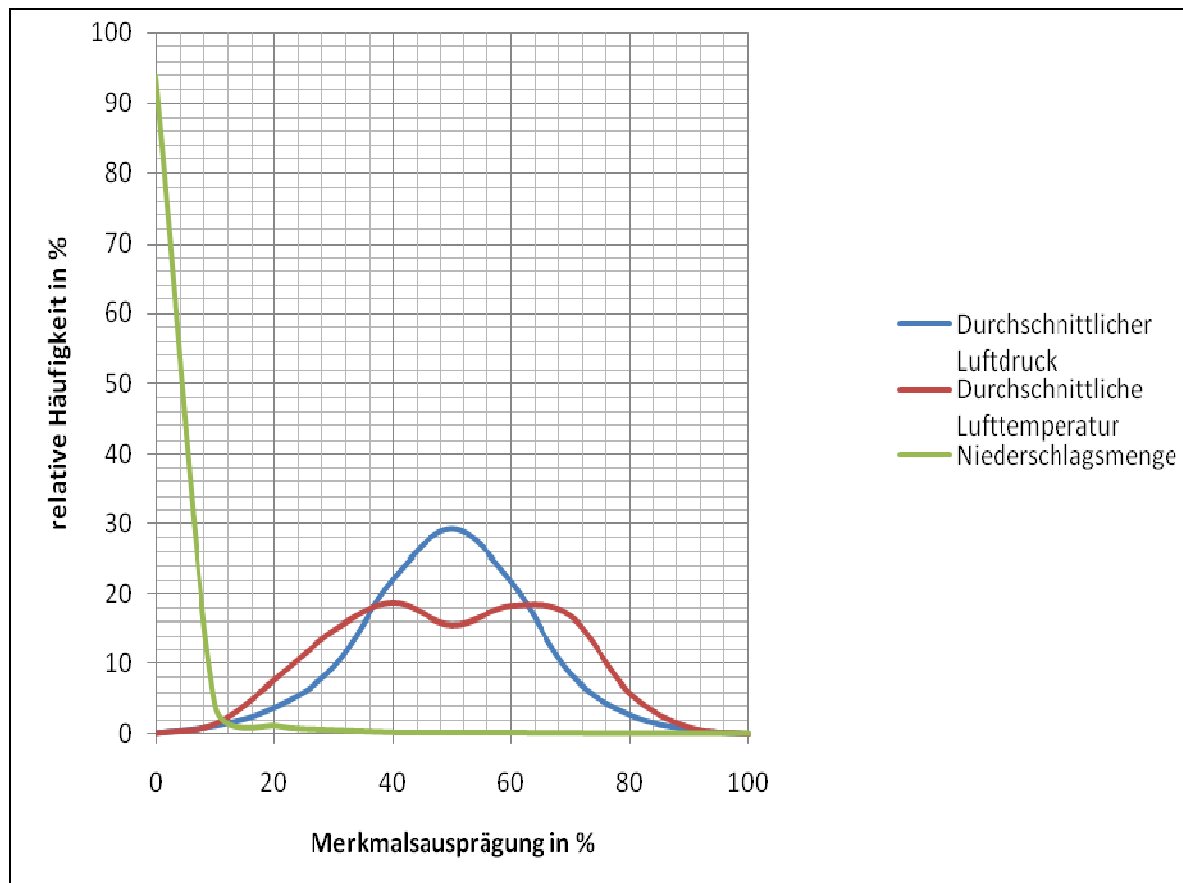
Quelle: Eigene Darstellung.

Aus den berechneten Häufigkeiten lässt sich bei quantitativ skalierten Merkmalen, wie dem Luftdruck, zumeist eine unterschiedlich genaue Annäherung an die Gauß-Verteilung ablesen. Andere Maßzahlen weisen einen logarithmischen Verlauf der Häufigkeitsverteilung auf.

Zur Veranschaulichung zeigt die folgende Abbildung den Verlauf von drei

exemplarischen Verteilungen.

Abbildung 11: Vergleich von 3 Häufigkeitsverteilungen



Quelle: Eigene Darstellung.

3.1.2. Korrelationen

Um zu ermitteln, zwischen welchen Datenreihen Abhängigkeiten bestehen, eignet sich besonders der Korrelationskoeffizient. Er „ist ein Maß für die Ausprägtheit des linearen Zusammenhangs von“²² zwei Merkmalen. Da er sich immer zwischen -1 und 1 bewegt, ist ein Vergleich zwischen verschieden dimensionierten Größen möglich. Hierbei bedeutet ein Korrelationskoeffizient von 1 eine vollständige Abhängigkeit zweier Merkmale. Ein Wert von null lässt keinerlei linearen Zusammenhang erkennen. Negative Korrelation zeigt eine antiproportionale Beziehung. Erforderlich ist die Berechnung dieses Koeffizienten, weil durch Ausschluss einer der zwei korrelierenden Kenngrößen Redundanz in den Eingabedaten vermieden werden kann.

Eine Ausnahme hierzu bilden Messreihen, die zu unterschiedlichen Uhrzeiten aufgenommen wurden und immer eine sehr hohe Korrelation aufweisen.

²² Schwarze, J.: Grundlagen der Statistik I Beschreibende Verfahren (Verlag Neue Wirtschafts-Briefe; Herne/Berlin; 10. Auflage 2005).

Zum Beispiel wird die Temperatur der Luft in 2m Höhe morgens um 6 Uhr, mittags um 12 Uhr und abends um 18 Uhr gemessen. Diese Redundanz ist bei einigen Netzen aber erwünscht, damit auch eine Vorhersage solch genaue Werte enthalten kann.

Die Berechnung der Korrelationskoeffizienten für alle untersuchten Kenngrößen wird in Tabelle 4 demonstriert. Die hervorgehobenen Werte lassen auf korrelierte Merkmale schließen.

Tabelle 4: Auszug aus der Korrelationstabelle

Korrelation zwischen Merkmalen	Luftdruck 6 Uhr	Luftdruck 12 Uhr	Luftdruck 18 Uhr	Luftdruck Durchschnitt	Temperatur Maximum	Temperatur Minimum
1 und 2	0,97	0,97	0,97	-0,03	0,93	0,31
1 und 3	0,90	1,00	-0,06	-0,08	0,63	0,99
1 und 4	0,98	-0,03	-0,09	0,09	0,91	0,98
1 und 5	-0,01	-0,08	0,02	-0,10	0,94	0,94
1 und 6	-0,08	0,07	-0,11	-0,08	0,99	0,95
1 und 7	0,14	-0,10	-0,09	-0,02	0,97	0,98
1 und 8	-0,10	-0,08	-0,05	-0,03	0,98	0,98
1 und 9	-0,08	-0,02	-0,07	-0,05	0,92	-0,32
1 und 10	0,00	-0,03	-0,07	-0,09	-0,26	0,97

Quelle: Eigene Darstellung.

Die hervorgehobenen Werte lassen auf einen Zusammenhang zwischen den untersuchten Merkmalen schließen. Da es sich bei P01, P02, P03 und PM um Luftdruckmessungen beziehungsweise -berechnungen desselben Tages handelt, ist eine fast hundertprozentige Abhängigkeit ablesbar. Zwischen dem Luftdruck P01 und der Tagesmaximumtemperatur ist mit einem Wert der Korrelation von -0,01 keine Abhängigkeit erkennbar.

3.2. Datenvorverarbeitung

Bevor die Daten des Deutschen Wetterdienstes zur Verarbeitung in einem neuronalen Netz verwendet werden können, bedarf es der Auswahl geeigneter Datensätze, der Klassierung dieser Daten und der Codierung in ein von der verwendeten Software JavaNNS und den Lernverfahren lesbares Format.

3.2.1. Auswahl ein- und mehrdimensionaler Datenmengen

Da in der vorliegenden Arbeit ein Vergleich zwischen ein- und mehrdimensionalen Prognoseverfahren vorgesehen ist, werden Kombinationen des Datenmaterials angelegt.

Die erste, einfachste und dennoch umfangreichste mehrdimensionale Testreihe besteht in der Verknüpfung aller Wetterdaten eines Tages mit denen des Folgetages als Netzeingabe und des zweiten Folgetages als Ausgabe. Tabelle 5

liefert die grafische Veranschaulichung dieser Versuchsanordnung unter dem Punkt Auswahl 1. Die Auswahl aller zur Verfügung stehenden Daten entspricht am stärksten der Eigenschaft neuronaler Netze, Zusammenhänge selbständig ohne vorgegebenen Lösungsweg zu ermitteln, da ohne diese Kenntnis keine Vorauswahl relevanter Daten getroffen werden kann. Die Anzahl der dabei vorhergesagten Tage unterschreitet zwar die von numerischen Systemen erzielten Zeiträume, ist aber zur Demonstration der prinzipiellen Machbarkeit absolut ausreichend. Analog können komplexere Experimente mit dafür geeigneter Soft- und Hardware durchgeführt werden.

Die zweite Datenzusammenstellung sieht als Eingabedaten vier aufeinanderfolgende Tage mit allen verfügbaren Größen vor. Ausgegeben wird repräsentativ nur die maximale Tagestemperatur der Luft für die kommenden zwei Tage. Dieser Versuchsaufbau stellt einen Übergang zwischen der ein- und mehrdimensionalen Prognose dar. Die Eingabe besteht noch aus einer Vielzahl von Merkmalen. Im Gegensatz dazu beinhaltet die Ausgabe nur eine Kennzahl. Zur Vorhersage aller gewünschten Größen wäre also für jede dieser Größen ein Netz zu erstellen und zu trainieren. Tabelle 5 bildet dieses Experiment in Auswahl 2 ab.

Eine dritte Experimentreihe demonstriert die Vorhersage des Wetters mit Hilfe eindimensionaler Tests. Hierbei wird vom Wetter der letzten sieben Tage, repräsentiert durch die Tagesmaximaltemperatur, auf die Witterung des nachfolgenden Tages geschlossen. Verdeutlicht wird diese Variante in Tabelle 5 Auswahl 3.

Einen letzten Versuchsaufbau liefert die vierte Datenauswahl (siehe Tabelle 5 Auswahl 4). Dazu werden, wie im vorherigen Experiment, die Werte der Maximaltemperatur von sieben Tagen auf die folgenden sieben Tage abgebildet.

Einen grafischen Überblick über die vier Anordnungen der Versuche gibt die Tabelle 5.

Tabelle 5: Die 4 gewählten Datenzusammenstellungen

		Eingabe							Ausgabe							
Anzahl Tage		1	2	3	4	5	6	7	1	2	3	4	5	6	7	
Auswahl 1	Luftdruck								→							
	Temperatur								→							
	Feuchte								→							
	Windstärke								→							
	Windrichtung								→							
	Bedeckung								→							
	Sonnenscheindauer								→							
	Niederschlagsmenge								→							
	...								→							
2	Luftdruck								↘							
	Temperatur								→							
	Feuchte								↗							
	Windstärke															
	Windrichtung															
	Bedeckung															
	Sonnenscheindauer															
	Niederschlagsmenge															
	...															
3	Luftdruck															
	Temperatur								→							
	Feuchte															
	Windstärke															
	Windrichtung															
	Bedeckung															
	Sonnenscheindauer															
	Niederschlagsmenge															
	...															
4	Luftdruck															
	Temperatur								→							
	Feuchte															
	Windstärke															
	Windrichtung															
	Bedeckung															
	Sonnenscheindauer															
	Niederschlagsmenge															
	...															

Quelle: Eigene Darstellung.

3.2.2. Klassifizierung der Daten

Auf Grund der vorangestellten Häufigkeitsanalyse ist es möglich, die Einteilung der Datensätze in Klassen festzulegen. Quantitative Merkmale, wie Luftdruck, Temperatur oder Niederschlagshöhe unterteilen sich in Klassen mit gleichem Abstand. Dadurch wird die jeweils festgestellte Häufigkeitsverteilung beibehalten. Beispiele für die Klassenbildung sind in Tabelle 6 zu finden. Angegeben sind bei den quantitativen und ordinalen Kennzahlen immer die Klassenobergrenzen. Nominale Merkmalsklassen enthalten keinen Wertebereich, sondern den exakten Wert.

Eine Ausnahme stellt die Niederschlagshöhe dar. Da die Häufigkeitsverteilung bei dieser Größe besonders stark von der Normalverteilung und sogar der Gauß-Verteilung abweicht, erfolgt die Klassenteilung unter Annäherung an eine Gleichverteilung.

Auch einige andere Kennzahlen fallen in diese Gruppe. Eine weitere Besonderheit bilden Maßzahlen, die Schnee betreffen, wie etwa Schneehöhe. Wegen der Tatsache, dass sie einen so verschwindend geringen Anteil am Gesamtdatenvolumen stellen, wurden sie im Weiteren nicht miteinbezogen.

3.2.3. Codierung der Daten

Da die durchgeführten Experimente auf die logistische Aktivierungsfunktion zurückgreifen, ist es erforderlich, alle Daten auf den Zahlenbereich von 0 bis 1 abzubilden. Um dabei eine möglichst starke Abgrenzung zwischen verschiedenen codierten Werten zu erreichen, beschränkt sich die Auswahl innerhalb dieses Bereiches auf exakt 0 oder 1. Diese Festlegung erklärt die hohe Anzahl an Neuronen, die bei der mehrdimensionalen Experimentreihe zustande kommt.

Bei der Codierung der Daten erfolgt eine Unterscheidung nach der Merkmalskala. Quantitative und ordinale Kennzahlen werden auf Grund der Eigenschaft, dass sie eine natürliche Ordnung besitzen, durch eine normierte Codierung abgebildet. Dadurch bleibt die Reihenfolge in den codierten Daten erkennbar.

Daten mit einer nominalen Skala werden durch die binäre Codierung dargestellt. Somit wird hier der Charakter einzelner Ausprägungen beibehalten und jeder Code unterscheidet sich deutlicher von einem anderen Code des gleichen Merkmals.

Die praktische Anwendung dieser zwei Regeln wird in Tabelle 6 verdeutlicht.

Tabelle 6: Auszug Klassenbildung und zugehörige Codierung

		Klassen								
Skala	Kennzahl	1	2	3	4	5	6	7	8	9
quantitativ	Luftdruck	9700	9800	9900	10000	10100	10200	10300	10400	10500
	Sonnenscheindauer	0000000	1000000	1100000	1110000	1111000	1111100	1111110	1111111	1111111
		20	40	60	80	100	120	140	160	
ordinal	Niederschlagshöhe	0000000	1000000	1100000	1110000	1111000	1111100	1111110	1111111	
	Windstärke	0	5	20	50	...				
		0000	1000	1100	1110	1111				
nominal	Bedeckungsgrad	10	20	30	40	50	60	70		
		000000	100000	110000	111000	111100	111110	111111		
	Windrichtung	0	20	30	40	50	60	70	80	
Sichtweite	Niederschlagsform	0000000	1000000	1100000	1110000	1111000	1111100	1111110	1111111	
		0	6	7	8					
	000	100	010	001						

Quelle: Eigene Darstellung.

3.2.4. Trainings- und Testdatensätze für verschiedene Netzarchitekturen

Das Ziel des Lernens bei neuronalen Netzen besteht nicht nur aus dem auswendigen Lernen der präsentierten Datensätze, sondern insbesondere der Fähigkeit, auch neue Varianten des Gelernten zuordnen zu können und auch für solche Daten eine Vorhersage zu erstellen. Im konkreten Fall bedeutet dies, dass nicht nur das Wetter der letzten Jahre prognostiziert wird, da das Ergebnis dieser Daten bereits in der Vergangenheit liegt und somit keinen Nutzen darstellen würde. Die Generalisierungsfähigkeit neuronaler Netze ermöglicht eben auch die Umsetzung dieses Vorhabens.

Für das Training bedeutet dies, dass nicht nur Datensätze zum Lernen zur Verfügung gestellt werden müssen, sondern auch zur Überprüfung des Grades der Generalisierung der Netze. Zu diesem Zweck wurden die klassifizierten, codierten Daten zufällig in zwei etwa gleich große Gruppen geteilt. Die erste Hälfte dient dabei zum Training der Netze. Der zweite Teil wird nach dem Lernvorgang an das Netz angelegt. Anschließend werden die Ergebnisse beider Datensätze verglichen. Je geringer dabei die Differenz der Trefferquote ist, desto höher ist der Generalisierungsgrad. Damit verbessert sich auch die Fähigkeit auf unbekanntere Wettersituationen zu reagieren.

Die verwendete Software JavaNNS verlangt zur Präsentation der Ein- und Ausgabedaten sogenannte Pattern-Dateien. Für jede der unter 3.2.1 vorgestellten Datenmengen existieren also eine Trainings- und eine Testmusterdatei. Diese beinhaltet neben Informationen des Netzes, an die die Daten angelegt werden, immer die Kombination aus Eingabemuster und zugehöriger Ausgabe. Deutlich wird dies mit der Hilfe der Trainingsdatei der dritten oben aufgeführten Zusammenstellung von Datenmengen (siehe Tab. 5), in Abbildung 12. Dort ist ab Zeile zehn das erste Eingabemuster der Trainingsdatei eines neuronalen Netzes mit 70 Ein- und 10 Ausgabeneuronen (siehe Abb. 12, Zeile 6 & 7) zu finden. Jede dieser Zeilen beinhaltet eine codierte Temperaturklasse. Zeile zehn enthält zum Beispiel den Code für den Bereich von 3,7 bis unter 8,7 Grad Celsius. Die folgende Zeile repräsentiert die Temperatur des darauffolgenden Tages. Im Anschluss an das erste Eingabemuster steht die erste Ausgabe. In diesem Fall handelt es sich dabei um die Temperatur des achten Folgetages. Dieser Aufbau wiederholt sich anschließend 1560 Mal (siehe Abb. 12, Zeile 5). Die Struktur der Datei mit Testdaten ist analog.

Abbildung 12: Auszug aus der Trainingsdatei eines 70-10 Netzes

```

1  SNNS pattern definition file V3.2
2  generated at Mon Sep 05 10:08:50 2008
3
4
5  No. of patterns : 1561
6  No. of input units : 70
7  No. of output units : 10
8
9  # Input pattern 1:
10 1 1 1 1 0 0 0 0 0 0
11 1 1 1 1 0 0 0 0 0 0
12 1 1 1 1 1 0 0 0 0 0
13 1 1 1 1 0 0 0 0 0 0
14 1 1 1 1 0 0 0 0 0 0
15 1 1 1 1 0 0 0 0 0 0
16 1 1 1 1 0 0 0 0 0 0
17 # Output pattern 1:
18 1 1 1 1 0 0 0 0 0 0
19
20 # Input pattern 2:
21 1 1 1 1 0 0 0 0 0 0
22 1 1 1 1 1 0 0 0 0 0
23 1 1 1 1 0 0 0 0 0 0
24 1 1 1 1 0 0 0 0 0 0
25 1 1 1 1 0 0 0 0 0 0
26 1 1 1 1 0 0 0 0 0 0
27 1 1 1 1 0 0 0 0 0 0
28 # Output pattern 2:
29 1 1 1 1 0 0 0 0 0 0
30

```

Quelle: Eigene Darstellung für den JavaNNS. Zell, A.: Java Neuronal Network Simulator 1.1; Tübingen; 1995; Version 1.1 2002.


3.3. Aufbau verschiedener Netzarchitekturen

Für die Maximierung der Trefferquote bei der Vorhersage verschiedener Wettergrößen ist es notwendig, nicht nur eine Netzarchitektur zu trainieren. Vielmehr erhöht die Anzahl der getesteten Topologien die Wahrscheinlichkeit, ein gutes Ergebnis zu erzielen.

Von den in Kapitel 2.2.5 vorgestellten möglichen Bauarten wird im Rahmen dieser Arbeit ausschließlich mit vorwärts gerichteten Netzen ohne Rückkopplung gearbeitet. Dabei kommen aber verschiedene Zusammenstellungen von Zwischenschichten mit verdeckten Neuronen zum Einsatz. Auch das Perzeptron, welches ohne eine verarbeitende Schicht auskommt, wird betrachtet.

JavaNNS bietet die Möglichkeit, den Aufbau des verwendeten neuronalen Netzes grafisch darzustellen. Abbildung 13 zeigt das 70-10-Netz zu der in Abbildung 12 präsentierten Trainingsdatei. Links befinden sich die 70 Ein- und rechts die 10 Ausgabeneuronen.

Abbildung 13: Architektur des 70-10-Perzeptrons




Quelle: Eigene Darstellung im JavaNNS. Zell, A.: Java Neuronal Network Simulator 1.1; Tübingen; 1995; Version 1.1 2002.

Abbildung 13 stellt eine vereinfachte Anzeige des Netzes ohne Verbindungen

und Bezeichnungen an den einzelnen Neuronen dar. Vor allem bei den um ein Vielfaches umfangreicheren Netzen, wie zum Beispiel der Zusammenstellung 1 und 2 aus Tabelle 5, ist die Ansicht der Verbindungen und Namen auf Grund der Übersichtlichkeit und des zusätzlichen Bedarfs an Prozessorleistung nicht mehr zu empfehlen. Exemplarisch zeigt Abbildung 14 das selbe Netz wie Abbildung 13, allerdings mit Darstellung der Verbindungen. Deutlich zu erkennen ist die Tatsache, dass jedes Eingabeneuron (oben in der Abb.) mit jedem Ausgabeneuron verbunden ist. Auch in diesem Bild wird zu Gunsten der Übersicht auf Namen an den Neuronen verzichtet.

Abbildung 14: 70-10-Perzeptron mit Verbindungen




Quelle: Eigene Darstellung im JavaNNS. Zell, A.: Java Neuronal Network Simulator 1.1; Tübingen; 1995; Version 1.1 2002.

Diejenigen Architekturen, die eine oder mehrere Zwischenschichten enthalten,

dienen zum Training der Datenzusammenstellung, die die meisten Ein- und Ausgabeneuronen enthalten. Ein solches Netz mit zwei Schichten verdeckter Neuronen ist in Abbildung 15 dargestellt.

Abbildung 15: 840-40-20-420-Netz



Quelle: Eigene Darstellung im JavaNNS. Zell, A.: Java Neuronal Network Simulator 1.1; Tübingen; 1995; Version 1.1 2002.

3.4. Implementierung Fehlerermittlung

Die im JavaNNS bereitgestellte Fehlerermittlung ist auf Grund ihrer grafischen Abbildung gut als Unterstützung für die Netzentwicklung geeignet. Sie gibt bereits erste Hinweise auf das Lernverhalten des trainierten Netzes. Allerdings bedarf es für eine konkrete Ermittlung der Trefferquote einer externen Anwendung. Da eine Tabellenkalkulationssoftware wegen des hohen Datenvolumens nicht in Frage kommt, wird die Berechnung der Anzahl von Übereinstimmungen zwischen gelernter und erwünschter Ausgabe automatisiert durchgeführt. Dafür werden die sogenannten Result-Dateien, die in mehreren Lernzyklen angelegt werden, ausgelesen und in einer nach Dateinamen der ans Netz angelegten Datensätze sortierten Textdatei festgehalten. Der Aufbau ei-

ner Result-Datei ist ähnlich der einer Pattern-Datei. Je Trainings- oder Testmuster finden sich darin die gelernte und die gewünschte Ausgabe untereinander.

Die Berechnung der Trefferquote verdeutlicht folgendes Beispiel in Abbildung 16.

Abbildung 16: Auszug aus einer Result-Datei des 70-10-Netzes

```

1  SNNS result file V1.4-3D
2  generated at Wed Sep 17 12:32:03 2008
3
4  No. of patterns      : 1552
5  No. of input units  : 70
6  No. of output units : 10
7  startpattern        : 1
8  endpattern          : 1552
9  teaching output included
10 #1.1
11 1 1 1 0 0 0 0 0 0 0
12 1 0 1 0 0 0 0 0 0 0
13
14 #2.1
15 1 1 1 1 0 0 0 0 0 0
16 1 0 1 0 0 0 0 0 0 0
17

```

Quelle: Eigene Darstellung für den JavaNNS. Zell, A.: Java Neuronal Network Simulator 1.1; Tübingen; 1995; Version 1.1 2002.

In Zeile 11 des Auszugs steht der Code „1 1 1 0 0 0 0 0 0 0“. Dabei handelt es sich um die gesuchte Ausgabe. Vom Netz vorhergesagt wird aber in Zeile 12 dieser Code: „1 0 1 0 0 0 0 0 0 0“. Die Trefferquote liegt also bei neun von zehn möglichen Übereinstimmungen. Das zweite Muster der Ergebnisdatei ergibt eine Trefferquote von 80%.

Den direkten Vergleich zwischen Trainingserfolg und Generalisierungsfähigkeit bei den Testdaten übernimmt eine tabellarische Übersicht. Einen Teil

der darin enthaltenen Daten für die ersten 20 Experimente demonstriert Tabelle 7.

Tabelle 7: Auszug aus der Ergebnisübersicht

(Die Abkürzungen in der Spalte für Lernmethoden stehen für b = **B**ackpropagation und m = **B**ackpropagation-**M**omentum.)

Test Nr.	Anz. Input	Anz. Hidden 1	Anzahl Output	Lern methode	Zyklen	% train	% test	% Differenz	% Gesamt
1	840	10	420	b	1	80,47%	80,34%	0,13	80,40%
2	840	10	420	b	5	80,16%	79,88%	0,28	80,02%
3	840	10	420	b	10	81,19%	81,06%	0,13	81,12%
4	840	10	420	b	20	82,11%	81,99%	0,12	82,05%
5	840	10	420	b	50	82,86%	82,68%	0,18	82,77%
6	840	10	420	b	100	74,23%	74,49%	-0,26	74,36%
7	840	10	420	b	200	82,65%	82,76%	-0,10	82,71%
8	840	10	420	b	500	83,63%	83,62%	0,01	83,62%
9	840	10	420	b	1000	80,81%	80,73%	0,08	80,77%
10	840	10	420	b	5000	81,47%	81,25%	0,23	81,36%
11	840	10	420	m	1	76,90%	76,63%	0,28	76,77%
12	840	10	420	m	5	84,03%	83,81%	0,21	83,92%
13	840	10	420	m	10	81,74%	81,29%	0,45	81,52%
14	840	10	420	m	20	85,26%	85,05%	0,20	85,16%
15	840	10	420	m	50	80,27%	79,62%	0,65	79,95%
16	840	10	420	m	100	80,71%	80,36%	0,35	80,54%
17	840	10	420	m	200	82,79%	82,47%	0,32	82,63%
18	840	10	420	m	500	83,47%	83,00%	0,46	83,24%
19	840	10	420	m	1000	85,43%	85,10%	0,32	85,27%
20	840	10	420	m	5000	81,73%	81,15%	0,58	81,44%

Quelle: Eigene Darstellung.

3.5. Netzentwicklung

Prinzipiell existieren unterschiedliche Möglichkeiten ein Netz zu verändern, um weniger Unterschiede zwischen der erlernten und der geplanten Ausgabe zu erhalten. Die einfachste Methode dabei stellt die Wiederholung dar. Die zur Verfügung stehenden Muster werden nicht nur einmal am Netz angelegt, sondern erneut präsentiert. In der Software JavaNNS ist dies mit Hilfe der einstellbaren Zyklenanzahl realisiert. Zusätzlich besteht die Möglichkeit, durch Anpassung der Parameter der verschiedenen Lernverfahren eine Verbesserung zu erzielen. Führt diese Maßnahme nicht zu einem gewünschten Resultat, kann das Lernverfahren gegen ein erfolgreicherer ersetzt werden und mit den genannten Schritten an das jeweilige Problem angeglichen werden. Diese

Vorgehensweise bietet sich in jedem Fall an und ist auch bei der vorliegenden Aufgabenstellung zusätzlich zu allen anderen Netzentwicklungsmethoden sinnvoll.

Sofern diese Versuche nicht den gewünschten Effekt haben, ist eine Überarbeitung der Netzarchitektur denkbar. Es ist durchaus nicht auszuschließen, dass die gestellte Aufgabe mit der vorhandenen Anzahl an Neuronen in der Zwischenschicht nicht zufriedenstellend oder gar nicht lösbar ist. Auch der umgekehrte Weg des Entfernens von Neuronen kann zu günstigeren Ergebnissen führen. Zum Beispiel ist das der Fall, wenn die präsentierten Daten nur auswendig gelernt wurden und keine Abstraktion auf ähnliche Eingaben resultiert.

Die Veränderung der Verbindungsstärke und Anzahl stellt eine weitere Möglichkeit der Netzentwicklung dar. Die Modifikation der Gewichte geschieht bereits während des Lernens und eine Löschung oder Hinzunahme von Verbindungen ist nur nötig, wenn das Netz nicht schon vollständig verknüpft ist. Ansonsten können diese beiden Korrekturen über die Gewichtsänderung vorgenommen werden.

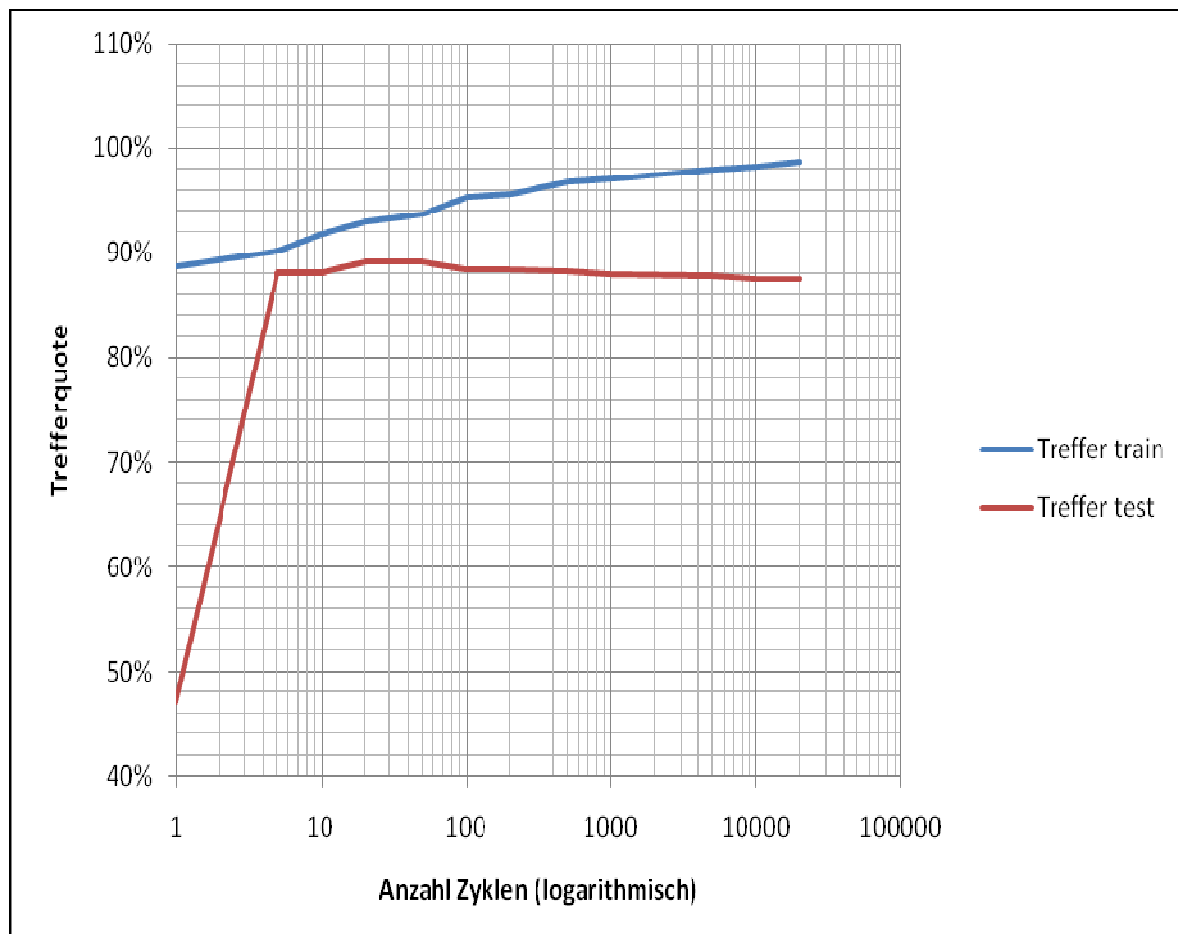
Eine weitere Methode zur Netzverbesserung, ist die Variation des Schwellwertes der Neuronen. Dies bietet sich an, wenn die verlangten Ausgabemuster zwar erkannt werden, eine Aktivierung des Neurons aber wegen eines zu hohen Schwellwerts nicht eintritt.

Eine letzte Technik bei der Netzentwicklung bildet die Änderung der Codierung. Die Daten können je nach Aktivierungsfunktion im Bereich von 0 bis 1 oder -1 bis 1 abgebildet werden. Der Vorteil hiervon liegt in der besseren Unterscheidung von verschiedenen Mustern oder im gegenteiligen Fall in der deutlicheren Ähnlichkeit zusammengehöriger Daten.

3.5.1. Minimierung des Netzfehlers durch Änderung der Netzparameter

Den mit Abstand größten Einfluss auf die Trefferzahl in den realisierten Versuchen nimmt die Zyklenzahl. Bei den ersten Datenzusammenstellungen mit sehr hoher Neuronenanzahl führen auch die hohen Wiederholungsraten zu besseren Ergebnissen. Ein negativer Nebeneffekt der häufigen Musterpräsentation ist aber der Umstand, dass der Lernerfolg zum größten Teil auf Auswendiglernen zurückzuführen ist. Deutlich sichtbar wird diese Auswirkung an den auseinanderdriftenden Trefferquoten der folgenden Grafik.

Abbildung 17: Diagramm der Trefferquoten von Trainings- und Testdatensätzen des 2. Versuchsaufbaus aus Tabelle 5



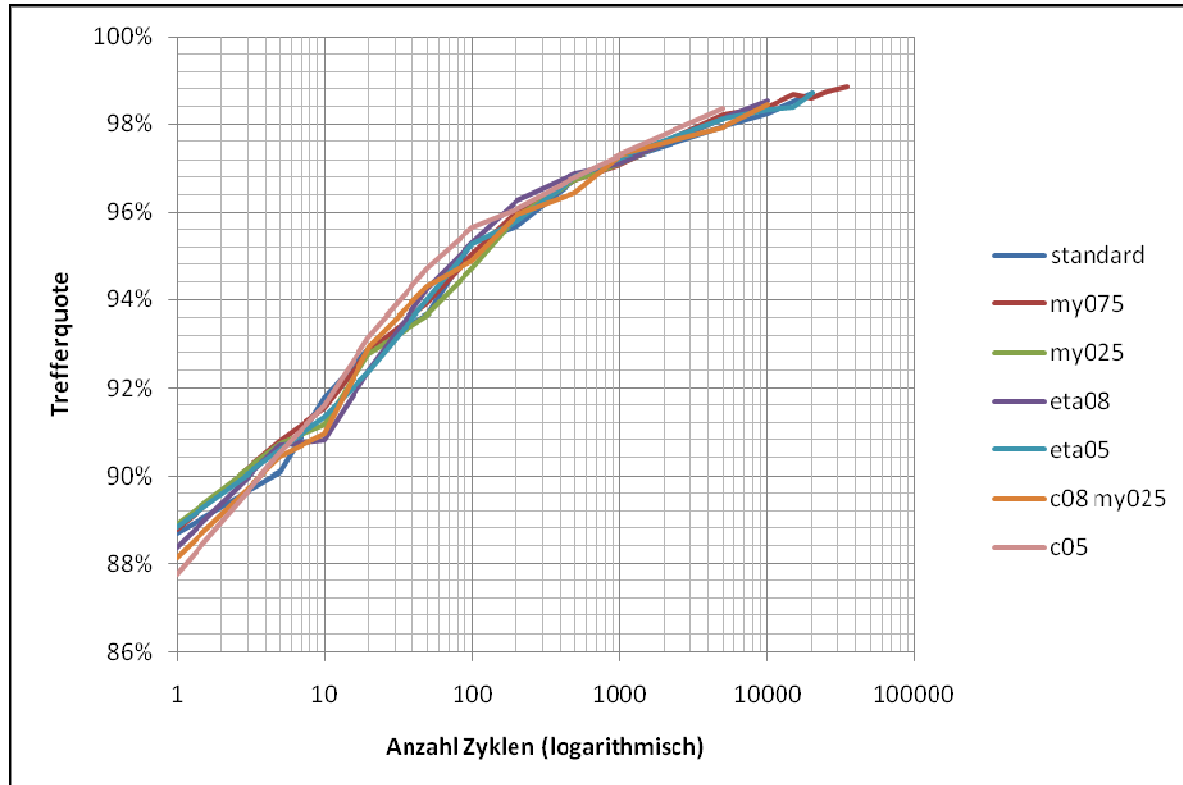
Quelle: Eigene Darstellung.

Besonders wegen der hohen Anzahl an Neuronen bei den ersten durchgeführten Experimenten, werden die besten Ergebnisse nicht mit den im JavaNNS voreingestellten Werten der Parameter erreicht. Speziell das Quickprop-Lernverfahren erfordert eine Verringerung der Lernrate bei größeren Netzen.²³ Jedoch lieferte Quickprop, mit Ausnahme des zweiten in Tabelle 5 gelisteten Experimentaufbaus, bei allen durchgeführten Experimenten nur durchschnittliche Trefferquoten. Auch veränderte Lernraten verbesserten diesen Umstand nicht.

Auch das Backpropagation-Verfahren und Backpropagation-Momentum reagiert merklich auf die Steigerung der Zyklenzahl. Eine Variation der Parameter hat nur einen geringen Einfluss auf den Erfolg. Das folgende Beispiel zeigt die Steigerung in Abhängigkeit von den Wiederholungen und die nur kleinen Abweichungen bei der Parameteränderung.

²³ Zell, A.: Simulation neuronaler Netze (R. Oldenburg Verlag; München; Nachdruck 2003).

Abbildung 18: Trefferquoten bei veränderten Parametern
 (Erklärung my075 bedeutet Parameter $\mu=0,75$; andere analog;
 Versuchsaufbau 1 der Tabelle 5)



Quelle: Eigene Darstellung.

3.5.2. Minimierung des Netzfehlers durch Variation der Codierung

Die Frage nach der signifikanteren Codierung wird in einer Reihe von Experimenten mit gleicher Architektur für normierte und binäre Codes geklärt. Verglichen wird an Hand der Datenzusammenstellung 4 aus Tabelle 5. Die Summe der Aktivierungen bei der normierten Codierung der Tagesmaximumtemperatur verhält sich proportional zur abgebildeten Temperatur. Im Gegensatz dazu ist die Gesamtaktivierung im Falle der binären Codierung immer gleich. Die angelegten Muster werden also auch vom Netz gleichwertig erkannt.


Tabelle 8: Gegenüberstellung normierte & binäre Codierung der Temperatur

Klasse	1	2	3	4	5	6
°C	-113	-63	-13	37	87	137
normiert	0000000000	1000000000	1100000000	1110000000	1111000000	1111100000
binär	0000000000	1000000000	0100000000	0010000000	0001000000	0000100000
Klasse	7	8	9	10	11	
°C	187	237	287	337	387	
normiert	1111110000	1111111000	1111111100	1111111110	1111111111	
binär	0000010000	0000001000	0000000100	0000000010	0000000001	

Quelle: Eigene Darstellung.

Die deutlich höheren Trefferquoten erreichen dabei die Netze, die mit den normierten Eingaben arbeiten. Hauptproblem der binären Ausgabemuster stellt die uneindeutige Unterscheidung zwischen aktiven und nicht aktivierten Neuronen dar. Abbildung 19 vergleicht im konkreten Beispiel die Ausgabe eines Netzes mit normierter und eines mit binärer Codierung.

Abbildung 19: Aktivierung (grün) links bei normierter, rechts binäre Codierung (Eingabemuster oben, Ausgabe unten)



Quelle: Eigene Darstellung im JavaNNS. Zell, A.: Java Neuronal Network Simulator 1.1; Tübingen; 1995; Version 1.1 2002.

Im Gegensatz zu diesem Beispiel ist die Verwendung binärer Datenmuster bei nominalskalierten Merkmalen der normierten Codierung vorzuziehen, da der Kontrast zwischen unähnlichen Zuständen durch diese Maßnahme betont wird.

3.5.3. Minimierung des Netzfehlers durch Variation der Netzarchitektur

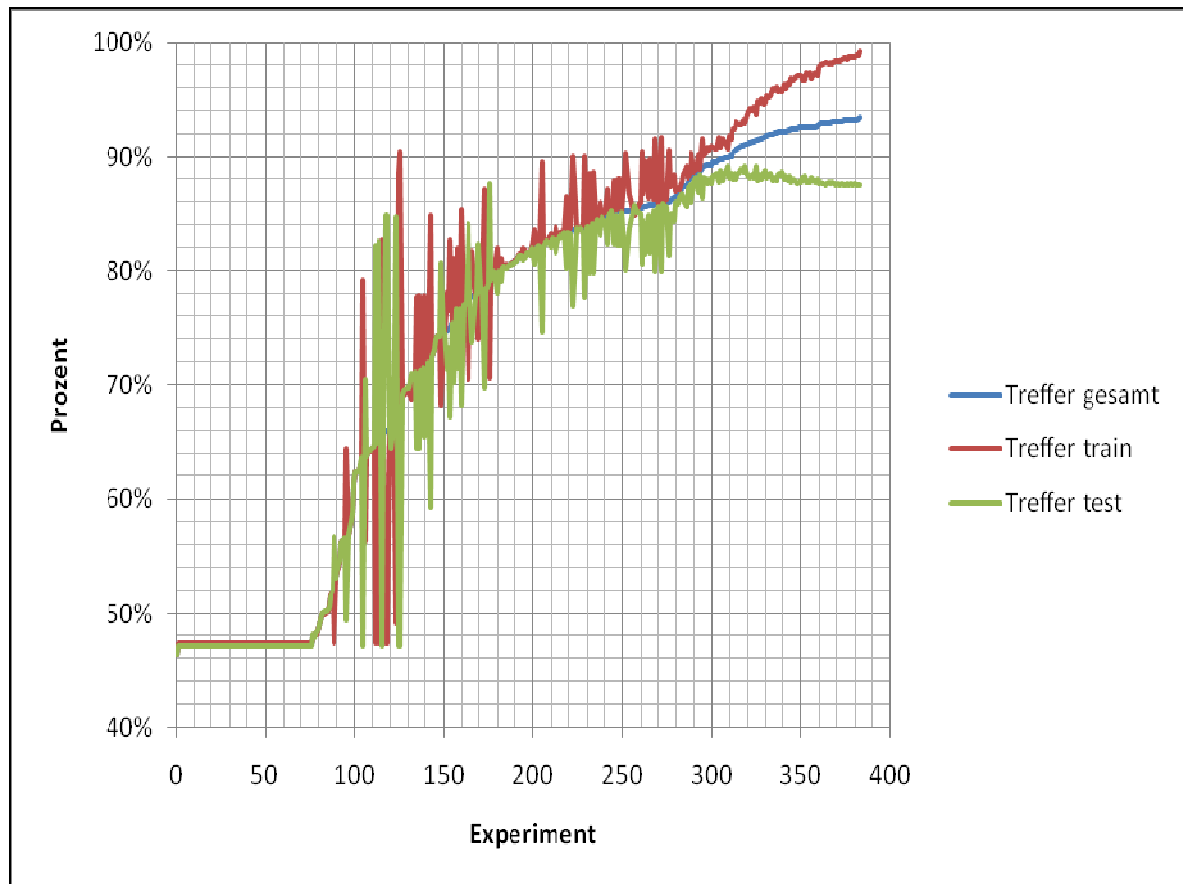
Die mit Abstand besten Trefferquoten erzielen in allen Versuchen die Netze ohne Zwischenschichten. Der Unterschied zwischen dem besten Ergebnis eines Perzeptrons und dem eines Netzes mit 600 verdeckten Neuronen beträgt fast zehn Prozent. Die Tatsache, dass Netze mit weniger Zwischenneuronen noch schlechtere Werte liefern, lässt darauf schließen, dass die Anzahl für das gestellte Problem noch nicht ausreicht. Allerdings ist angesichts der überdimensional großen Menge an Neuronen und der damit verbundenen immensen Rechendauer deutlich die Architektur des Perzeptrons zu bevorzugen.

3.6. *Auswertung der Experimente*

Im Versuchsaufbau mit zweitägiger Eingabe aller Wetterdaten und einer Ausgabe für den jeweiligen Folgetag (Auswahl 1 in Tabelle 5) erreichen die mit dem Backpropagation-Momentum trainierten Netze die eindeutig besseren Resultate. Den niedrigsten Erfolg im Bereich von Zufallswahrscheinlichkeiten verzeichnet das unmodifizierte Backpropagation-Verfahren. Der Quickprop- und Resilient Propagation-Algorithmus erreichen immerhin mittlere Erfolgsquoten bei unterschiedlichen Netzarchitekturen und Parametervariationen.

Dabei ist zu beachten, dass die Generalisierungsfähigkeit der Netze im oberen Bereich der Trefferquote nicht besonders hoch angesiedelt ist. Auch ist eine Zunahme der Differenz zwischen der Trefferquote der Trainings- und Testdaten nicht zu übersehen. Abbildung 20 veranschaulicht diesen Umstand grafisch. Die zu Grunde liegenden Trefferquoten stehen in sortierter Reihenfolge zur Verfügung. Den höchsten Wert der Trefferquote aller Datensätze von 93,41 % erreicht das 840-420-Netz bei 15.000 Zyklen und einer Veränderung des Lernparameters η auf den Wert 0,8.

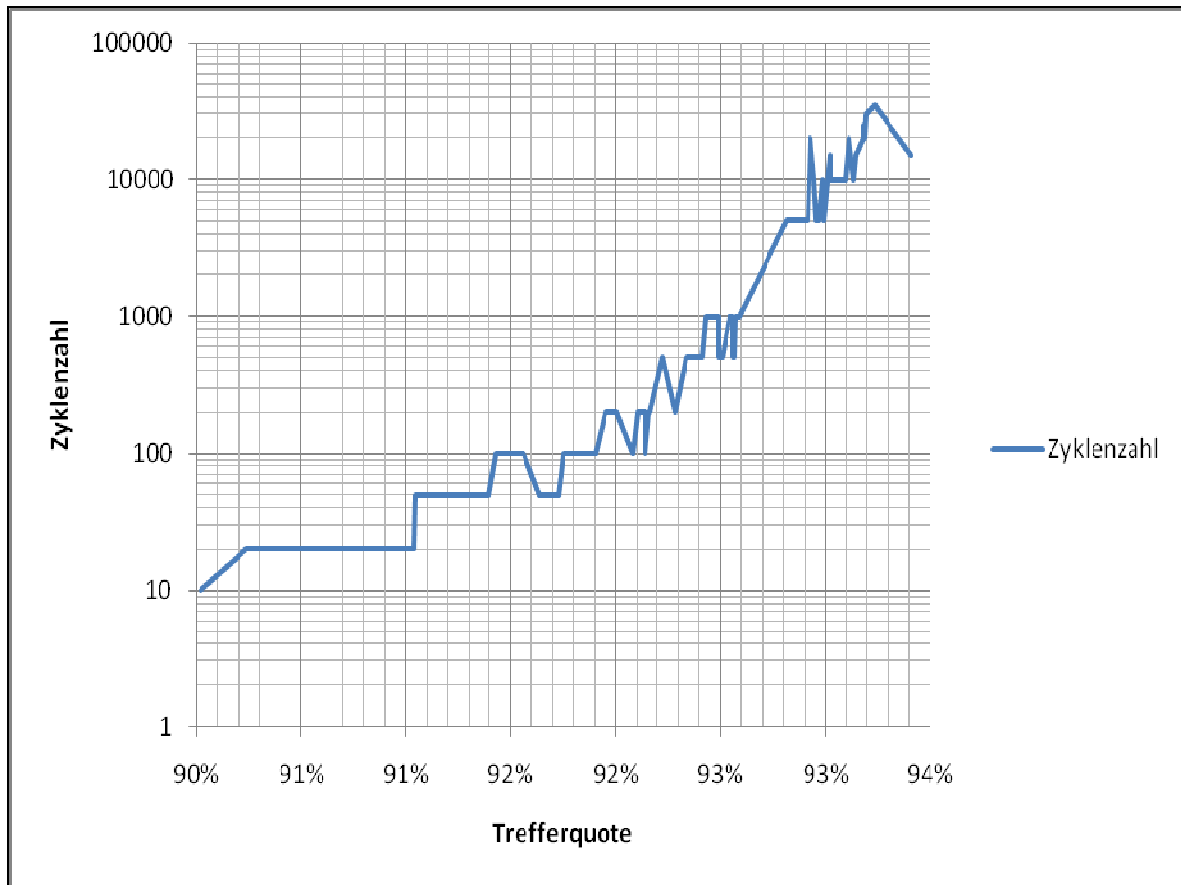
Abbildung 20: Trefferquoten des 1. Versuchsaufbaus nach Tabelle 5



Quelle: Eigene Darstellung.

Generell kann für diese Testreihe festgestellt werden, dass eine steigende Anzahl an Lernzyklen zu höheren Trefferquoten führen. Grafik 21 untermauert dies.

Abbildung 21: Zyklenzahl (logarithmisch) in Abhängigkeit von der Trefferquote



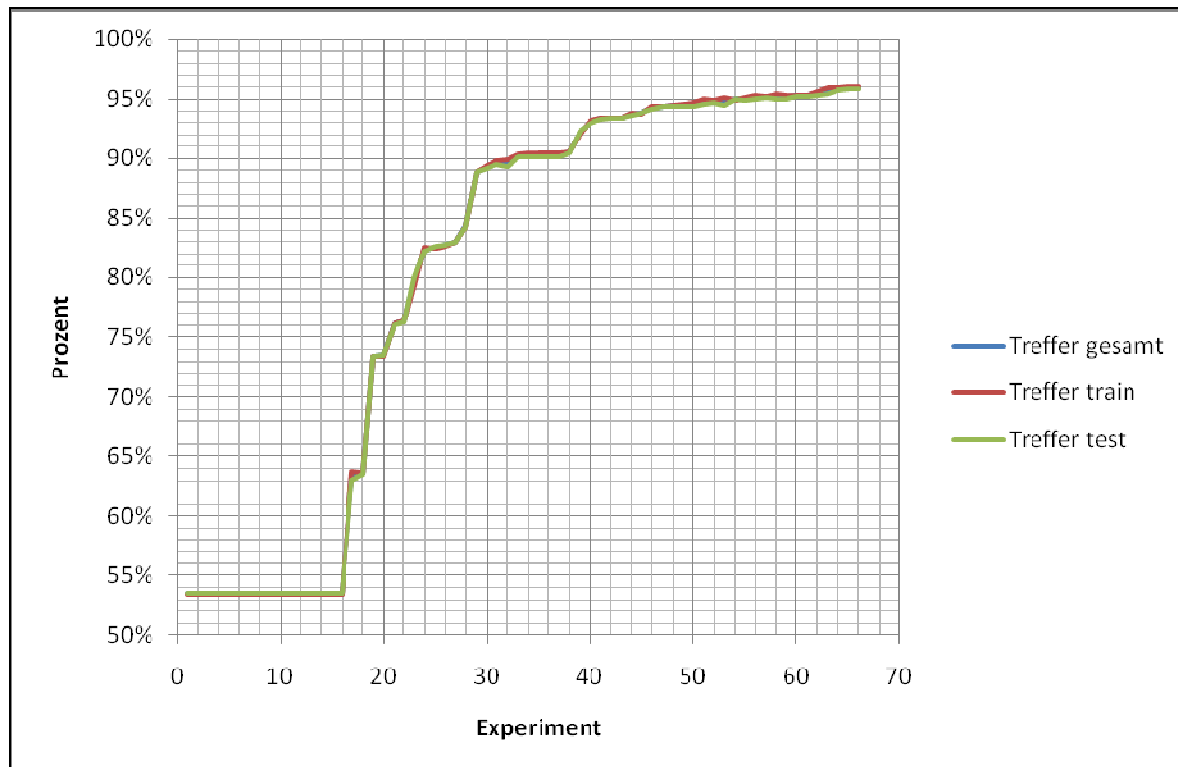
Quelle: Eigene Darstellung.

Bei der zweiten Auswahl an Ein- und Ausgabedaten der Tabelle 5 ist ebenfalls ein Trend der Differenz der Trefferquoten zwischen Trainings- und Testmustern zu verzeichnen. Auch das Backpropagation-Momentum-Lernverfahren berechnet hier die günstigsten Resultate. Die maximale Gesamttrefferquote von 97,4% wird dabei nach 100 Zyklen mit den Standardparameterwerten erzielt. Darüber hinaus erreicht das erst- und zweitplatzierte 1680-20-Netz einen 100%igen Lernerfolg. Es werden also alle Eingaben den richtigen Ausgaben des Trainingsmusters zugeordnet. Zwar kann der entsprechende Testdatenerfolg nicht in gleicher Höhe verzeichnet werden, liegt aber mit einem Wert von 94,63% und 94,78% immer noch sehr hoch.

Die Anwendung der Backpropagation-, Delta- und Hebbschen Lernregeln in diesem Versuchsaufbau führt nur zu Ergebnissen, die sich nicht von Zufallswerten unterscheiden.

Eine merklich hohe Generalisierungsfähigkeit weisen die Resultate der dritten Experimentreihe auf. Hier beläuft sich die Differenz zwischen Test- und Trainingsdatensätzen auf Beträge, die weitestgehend deutlich unter 0,5% liegen. Grafisch sichtbar wird dies in der Überlagerung des Verlaufs der Trefferquotengrafen von Test-, Trainings- und Gesamtdaten in Bild 22.

Abbildung 22: Trefferquoten des 3. Versuchsaufbaus aus Tabelle 5



Quelle: Eigene Darstellung.

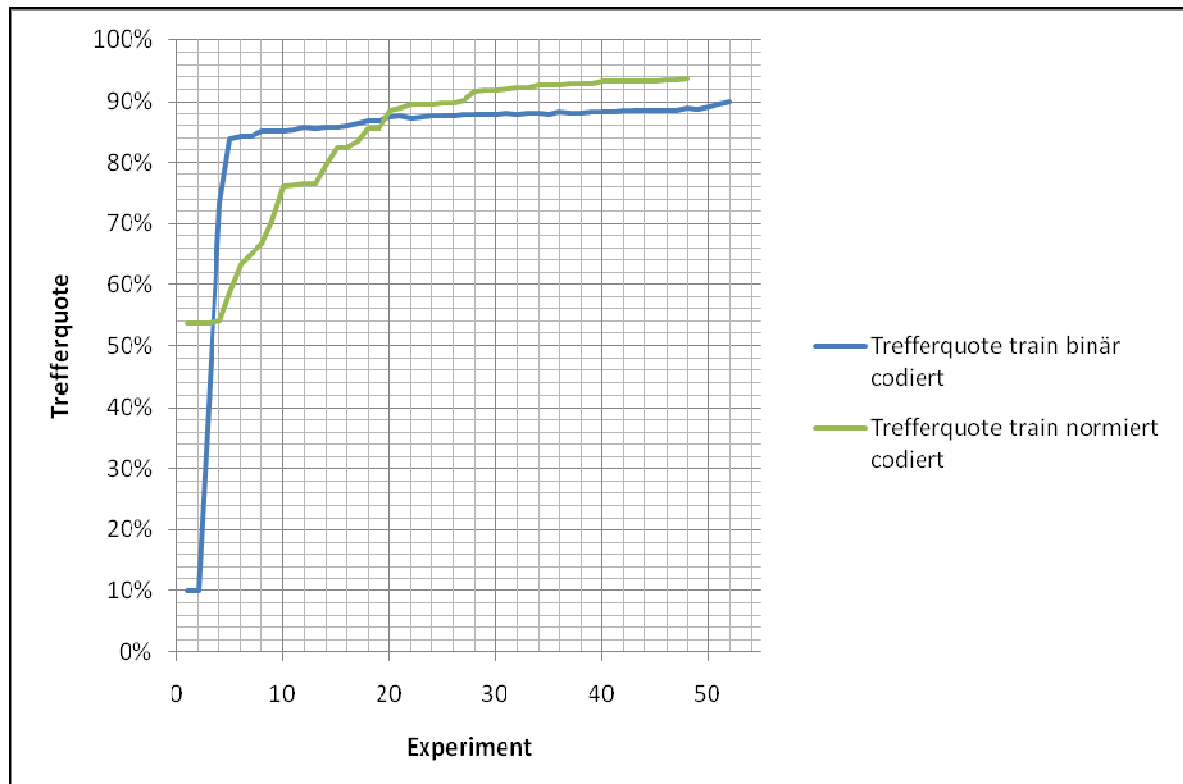
Ebenfalls im Bild ablesbar ist eine Reihe von Experimenten, die keinen Lernerfolg verzeichnen können. Dabei handelt es sich wiederum vornehmlich um Versuche, bei denen Delta- oder Hebbsche Lernverfahren zur Anwendung kommen.

Das beste Resultat liefert die Durchführung von 100 Lernzyklen auf ein Backpropagation-Momentum Netz. Die Trefferquote in diesem Fall beträgt insgesamt 95,91%. Fast gleichauf mit 95,9% findet sich ein Backpropagation Netz mit 500 Trainingsmusterpräsentationen.

Den erwünschten Vergleich der Vorhersagequalität bei unterschiedlicher Codierung liefert Experiment 4, mit normierter Codierung der Temperatur und mit der binären Variante.

Einen ersten übersichtlichen Eindruck der Resultate gibt Abbildung 23.

Abbildung 23: Trefferquoten des Experiments 4



Quelle: Eigene Darstellung.

Deutlich wird bei der Auswertung der letzten beiden Experimente auch, dass die Steigerung der Anzahl der Lernzyklen nicht zwangsläufig zu besseren Ergebnissen führt. Es zeigt sich bei diesem Anwendungsfall, dass der Einfluss der Lernrate η eine größere Bedeutung zukommt. So benötigt das Gewinner-Netz mit einer Trefferquote von 93,55% dieser Testreihe zwar 500 Wiederholungen, die direkt nachfolgende Erfolgsquote von 93,52% aber nur 5 Lernzyklen.

Insgesamt gesehen können die durchgeführten Experimente als Erfolg auf dem Weg zur Wettervorhersage mit künstlichen neuronalen Netzen gewertet werden. Diese Aussage gründet auf der Tatsache, dass sämtliche Versuchsreihen Trefferraten von über 90% erzielen.

4. Schlussbemerkungen

Auf Grund der gewonnenen Erkenntnisse zur Realisierung der Wettervorhersage mit vorwärts gerichteten neuronalen Netzen ist diese Methode als Ergänzung zu numerischen Wettermodellen durchaus in Betracht zu ziehen.

Leider kann mit den erfolgten Experimenten noch nicht die gleiche Vorhersagequalität, wie in Kapitel 2.1.4 beschrieben, erreicht werden. Dies liegt aber ausschließlich an den rechentechnischen Voraussetzungen. Nicht nur die Software JavaNNS setzt hier die Grenzen bei der Anzahl verwendeter Neuronen.

Dadurch ist es nicht möglich, eine feinere Klassifizierung der Wetterkenngrößen vorzunehmen, obwohl genau dies den Unterschied zur numerischen Vorhersagequalität ausmacht. Als Veranschaulichung für diesen Fakt wird der rmse aus Tabelle 1 für eine zweitägige Prognose der Tagesmaximaltemperatur von 2,22K der Trefferquote aus der zweitägigen Vorhersage des Versuchsaufbaus 2 aus Tabelle 5 von 97,4% gegenübergestellt. In diesem Vergleich übersteigt allein schon die angesetzte Klassenbreite von 5K den rmse. Hinzu kommt der aus der Gesamtwerteanzahl und Gesamttrefferzahl errechnete rmse von circa 6,5K aus dem Trainingsergebnis. Es ist in Angesicht dieser Zahlen unbedingt eine Verfeinerung der Klassenstruktur erforderlich.

Auch ist für derart umfangreichere Lernvorgänge sehr hohe Rechenleistung und dies über einen längeren Zeitraum nötig. Zum Vergleich folgt eine Liste der für diese Arbeit eingesetzten Rechnerleistungen. Entscheidend für den zeitlichen Aufwand ist allerdings die reine Rechenleistung eines Prozessors, da auch bei den verwendeten Zweikernmaschinen nur ein Prozessor die Rechenarbeit ausgeführt hat. Der Umfang des Hauptspeichers hat keinen Einfluss auf die Rechengeschwindigkeit. Für einen Eindruck der zu erwartenden Rechenzeiten sei gesagt, dass die Lernvorgänge der großen Netze mit bis zu 35.000 Zyklen vorrangig auf den stärkeren PCs durchgeführt wurden. Trotzdem benötigten einige Berechnungen bis zu drei Tagen.

Tabelle 9: Liste verwendeter Hardware

	Prozessoranzahl	Prozessorleistung in GHz	RAM in GB
AMD Athlon 64 X2 4600	2	2,40	1,00
Intel Core 2 Duo T5750	2	2,00	3,00
AMD Athlon XP 2800	1	2,08	1,50
AMD Athlon XP Sempron 3000	1	2,00	1,00
AMD Athlon XP 2500	1	1,84	1,00
Intel Pentium M	1	1,40	1,00

Quelle: Eigene Darstellung.

Trotz dieser hohen Anforderungen wäre die neuronale Methode zur Prognose praktikabel, denn der benötigte Hardwareumfang müsste nur für eine kurze Zeit, zum Beispiel ein bis zwei Wochen pro Jahr, zum Einsatz kommen. In dieser Zeit würden dann eine Aktualisierung der Wetterdaten vorgenommen werden. Nachdem ein Netz zur Vorhersage trainiert ist, könnten diese Kapazitäten für andere Berechnungen genutzt werden. Die tägliche oder auch stündliche Abfrage einer aktuellen Vorhersage benötigt nur eine minimale Rechenleistung und -zeit.

5. Ausblick

Für den noch offenen Beweis der Konkurrenzfähigkeit künstlicher neuronaler Netze mit den Modellen der numerischen Wettervorhersage sind dringend weiterführende Experimente, vor allem mit weniger grob gegliederten Klasseneinteilungen und folglich einer deutlich höheren Neuronenzahl, notwendig.

Außerdem wäre interessant, ob neuronale Netze diejenigen Kenngrößen genauer vorhersagen, die bei der numerischen Variante noch große rmse aufweisen, wie zum Beispiel die in Tabelle 1 aufgeführte Sonnenscheindauer.

Gerade der aktuelle Trend der Forschung zur Simulation ganzer Gehirne mit einer Vielzahl an Neuronen ermutigt eine weitere Untersuchung der betrachteten Aufgabe.

Literaturverzeichnis

http://service.mvnet.de/_php/download.php?datei_id=3087 (Zugriff: 20.09.2008; Ministerium für Arbeit, Bau und Landesentwicklung MV).

http://www.daserste.de/wwiewissen/beitrag_dyn~uid.ms2cxsysz7uk7sol~cm.asp (Zugriff: 20.09.2008; Heinz Greuling).

<http://www.deutscher-wetterdienst.de/lexikon/download.php?file=Verifikation.pdf> (Zugriff: 20.09.2008; Deutscher Wetterdienst, Thomas Kratzsch).

<http://www.deutscher-wetterdienst.de/lexikon/download.php?file=Wettervorhersage.pdf> (Zugriff: 20.09.2008; Deutscher Wetterdienst).

http://www.dwd.de/bvbw/appmanager/bvbw/dwdwwwDesktop?_nfpb=true&_pageLabel=_dwdwww_spezielle_nutzer_hobbymeteorologen_vorhersage&T43402827281174304681546gsbDocumentPath=Content%2FOeffentlichkeit%2FKU%2FKUPK%2FHobbymet%2FVorhersagemodelle%2FAllgemein__teaser.html&_state=maximized&_windowLabel=T43402827281174304681546&lastPageLabel=_dwdwww_spezielle_nutzer_hobbymeteorologen_vorhersage (Zugriff: 20.09.2008; Deutscher Wetterdienst).

http://www.dwd.de/bvbw/generator/Sites/DWDWWW/Content/Oeffentlichkeit/KU/KU2/KU21/klimadaten/german/download__kl2000standardformat,templateId=raw,property=publicationFile.pdf/download_kl2000standardformat.pdf (Zugriff: 20.09.2008; Deutscher Wetterdienst).

<http://www.lukashensel.de/biomain.php?biopage=neuron> (Zugriff: 20.09.2008; Lukas Hensel).

http://www.tmv.de/site/24_48/48.html (Zugriff: 20.09.2008; Tourismusverband Mecklenburg-Vorpommern).

http://www.welt.de/reise/article96292/Mecklenburg_Vorpommern_ist_beliebtestes_Urлаubsziel_im_Inland.html (Zugriff: 20.09.2008; Welt online).

Lämmel, U.; Cleve, J.: Lehr- und Übungsbuch Künstliche Intelligenz (Fachbuchverlag Leipzig; Wismar; 2004; 2. Auflage).

Schwarze, J.: Grundlagen der Statistik I Beschreibende Verfahren (Verlag Neue Wirtschafts-Briefe; Herne/Berlin; 10. Auflage 2005).

Zell, A.: Java Neuronal Network Simulator 1.1; Tübingen; 1995; Version 1.1 2002.

Zell, A.: Simulation neuronaler Netze (R. Oldenburg Verlag; München; Nachdruck 2003).

Autorenangaben

Anne Kroll, B. Sc.

Hochschule Wismar

Fakultät für Wirtschaftswissenschaften

Philipp-Müller-Straße

Postfach 12 10

D - 23952 Wismar

E-Mail: anne.kroll@yahoo.de

WDP - Wismarer Diskussionspapiere / Wismar Discussion Papers

- Heft 04/2006: Ines Pieplow: Zur Problematik der Abgrenzung von Eigen- und Fremdkapital nach IAS 32
- Heft 05/2006: Rüdiger-Waldemar Nickel: Der Markenwert. Ermittlung – Bilanzierung – Auswirkungen von IFRS
- Heft 06/2006: Jost W. Kramer: Sozialwirtschaft – Zur inhaltlichen Strukturierung eines unklaren Begriffs
- Heft 07/2006: Monika Paßmann: Potential und Grenzen automatischer Verhaltensmuster als Instrument erfolgreichen Selbstmanagements
- Heft 08/2006: Mandy Hoffmann/Antje Deike: Analyse der Auslandsaktivitäten von Unternehmen in Westmecklenburg
- Heft 09/2006: Jost W. Kramer: Grundkonzeption für die Entwicklung eines Qualitätsmanagements im sozialwirtschaftlichen Bereich
- Heft 10/2006: Dierk A. Vagts: Ärztliche Personalbedarfsermittlung in der Intensivmedizin
- Heft 11/2006: Andreas Beck: Die sozialwirtschaftliche Branche als qualitatives Ratingkriterium – unter besonderer Berücksichtigung von NPO-Krankenhäusern
- Heft 12/2006: Robert Löhr: Tax Due Diligence bei Kreditinstituten – eine Betrachtung ausgewählter Bilanz- und GuV-bezogener Analysefelder bei der Ertragsbesteuerung
- Heft 13/2006: Kristine Sue Ankenman: Austrian Neutrality: Setting the Agenda
- Heft 14/2006: Jost W. Kramer: Co-operative Development and Corporate Governance Structures in German Co-operatives – Problems and Perspectives
- Heft 15/2006: Andreas Wyborny: Die Ziele des Neuen Kommunalen Rechnungswesens (Doppik) und ihre Einführung in die öffentliche Haushaltswirtschaft
- Heft 16/2006: Katrin Heduschka: Qualitätsmanagement als Instrument des Risikomanagements am Beispiel des Krankenhauses
- Heft 17/2006: Martina Nadansky: Architekturvermittlung an Kinder und Jugendliche
- Heft 18/2006: Herbert Neunteufel/Gottfried Rössel/Uwe Sassenberg/Michael Laske/Janine Kipura/Andreas Brüning: Überwindung betriebswirtschaftlicher Defizite im Innoregio-Netzwerk Kunststoffzentrum Westmecklenburg
- Heft 19/2006: Uwe Lämmel/Andreas Scher: Datenschutz in der Informationstechnik. Eine Umfrage zum Datenschutzsiegel

- in Mecklenburg-Vorpommern
- Heft 20/2006: Jost W. Kramer/Monika Passmann: Gutachten zur Bewertung der Struktur-, Prozess- und Ergebnisqualität der allgemeinen Sozialberatung in Mecklenburg-Vorpommern
- Heft 21/2006: Marion Wilken: Risikoidentifikation am Beispiel von Kindertageseinrichtungen der Landeshauptstadt Kiel
- Heft 22/2006: Herbert Müller: Zahlen und Zahlenzusammenhänge – Neuere Einsichten zum Wirken und Gebrauch der Zahlen in Natur und Gesellschaft
- Heft 01/2007: Günther Ringle: Genossenschaftliche Prinzipien im Spannungsfeld zwischen Tradition und Modernität
- Heft 02/2007: Uwe Lämmel/Eberhard Vilkner: Die ersten Tage im Studium der Wirtschaftsinformatik
- Heft 03/2007: Jost W. Kramer: Existenzgründung in Kleingruppen nach der Novellierung des Genossenschaftsgesetzes
- Heft 04/2007: Beate Stirtz: Hybride Finanzierungsformen als Finanzierungsinstrumente mittelständischer Unternehmen
- Heft 05/2007: Uwe Lämmel/Anatoli Beifert/Marcel Brätz/Stefan Brandenburg/Matthias Buse/Christian Höhn/Gert Mannheim/Michael Rehfeld/Alexander Richter/Stefan Wisuwa: Business Rules – Die Wissensverarbeitung erreicht die Betriebswirtschaft. Einsatzmöglichkeiten und Marktübersicht
- Heft 06/2007: Florian Wrede: Computergestützte Management-Informationssysteme. Geschichte – Zukunft – Konsequenzen
- Heft 07/2007: Peter Biebig/Gunnar Prause: Logistik in Mecklenburg – Entwicklungen und Trends
- Heft 08/2007: Anja Ziesche: Risikomanagement unter dem Aspekt der Betrieblichen Gesundheitsförderung
- Heft 09/2007: Cornelia Ewald: Kreditinstitute in der Anlageberatung – Anforderungen aus der aktuellen Rechtsprechung und Gesetzgebung
- Heft 10/2007: Herbert Müller: Zahlen, Planeten, Pyramiden und das Meter. Wie die Planung der Pyramiden von Gizeh erfolgt sein könnte – eine ingenieurmethodische Betrachtung
- Heft 11/2007: Klaus Sanden/Barbara Bojack: Depressivität und Suizidalität im höheren Lebensalter
- Heft 12/2007: Andrea Kallies/Anne Przybilla: Marktanalyse von Enterprise Resource Planning-Systemen – Kategorisierung –
- Heft 13/2007: Anne Przybilla: Die Verwaltungsreform und die Einfüh-

- Heft 14/2007: Jost W. Kramer: Erfolgsaspekte genossenschaftlichen Wirtschaftens aus betriebswirtschaftlicher Perspektive
- Heft 1/2008: Uwe Lämmel (Hrsg.): Wirtschaftsinformatik – Was ist das?
- Heft 02/2008: Florian Wrede: Qualitätsmanagement – Eine Aufgabe des Controllings, des Marketings oder des Risikomanagements?
- Heft 03/2008: Regina Bojack/Barbara Bojack: Comenius, ein moderner Pädagoge
- Heft 04/2008: Chris Löbbert/Stefanie Pawelzik/Dieter Bastian/Rüdiger Steffan: Datenbankdesign und Data Warehouse-Strategien zur Verwaltung und Auswertung von Unfalldaten mittels Risikopotenzialwerten und Risikoklassen
- Heft 05/2008: Reinhard J. Weck/Anatoli Beifert/Stefan Wissuwa: Wissensmanagement - quo vadis? Case Positions zur Umsetzung in den Unternehmen. Eine selektive Bestandsaufnahme
- Heft 06/2008: Petra Wegener: Die Zeit und ihre Facetten in der Fotografie
- Heft 07/2008: Anne Przybilla: Personalrisikomanagement – Mitarbeiterbindung und die Relevanz für Unternehmen
- Heft 08/2008: Barbara Bojack: Co-Abhängigkeit am Arbeitsplatz
- Heft 09/2008: Nico Schilling: Die Rechtsformwahl zwischen Personen- und Kapitalgesellschaften nach der Unternehmensteuerreform 2008
- Heft 10/2008: Regina Bojack: Der Bildungswert des Singens
- Heft 11/2008: Sabine Hellmann: Gentechnik in der Landwirtschaft
- Heft 12/2008: Jost W. Kramer: Produktivgenossenschaften – Utopische Idee oder realistische Perspektive?
- Heft 01/2009: Günther Ringle: Vertrauen der Mitglieder in ihre Genossenschaft - Das Beispiel der Wohnungsgenossenschaften -
- Heft 02/2009: Madleen Duberatz: Das Persönliche Budget für Menschen mit Behinderungen – Evaluation der Umsetzung am Beispiel der Stadt Schwerin
- Heft 03/2009: Anne Kroll: Wettervorhersage mit vorwärts gerichteten neuronalen Netzen