

# Strukturen für neuronale Netze in der Tageslicht-/Kunstlichtregelung

- zur Veröffentlichung bei LuxJunior 2003 –

-

Krzyzanowski, J., Rosemann, A., Kaase, H.

Technische Universität Berlin

Fachgebiet Lichttechnik, Sekr. E6

Einsteinufer 19; D-10587 Berlin; Germany

Tel: +49 / 30 / 314 – 22401

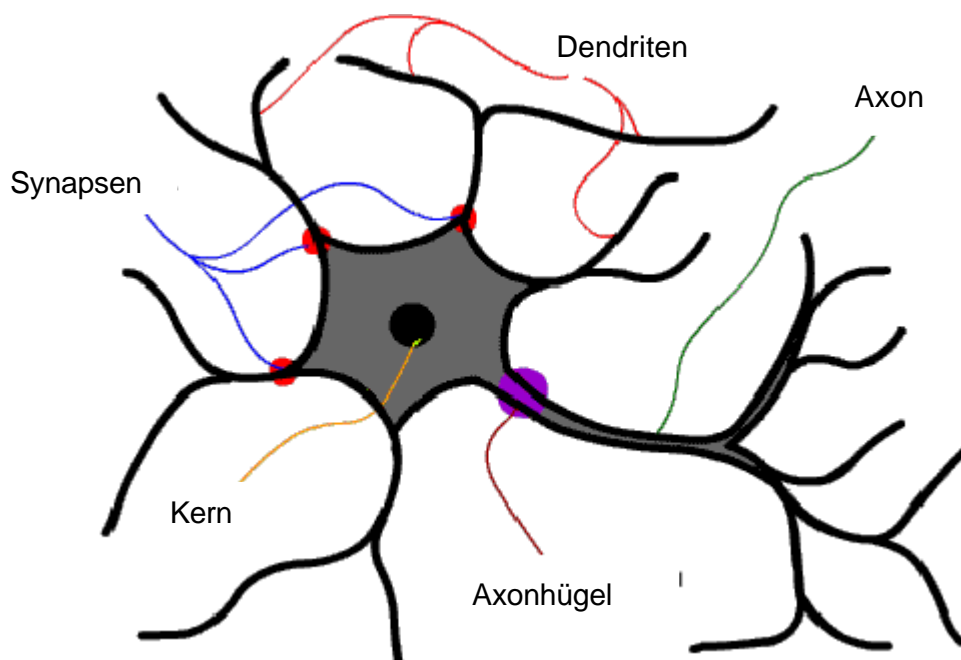
Fax: +49 / 30 / 314 – 22161

Email: [lichttechnik@ee.tu-berlin.de](mailto:lichttechnik@ee.tu-berlin.de)

<http://www.lichttechnik.tu-berlin.de>

## 1 Vom biologischen zum künstlichen neuronalen Netz

Ein künstliches neuronales Netz ist ein System, das in Aufbau und Funktion dem menschlichen Gehirn nachempfunden wird. Das Gehirn des Menschen besteht aus ca. 10 Billionen Neuronen.



**Abb. 1** Aufbau eines biologischen Neurons /1/

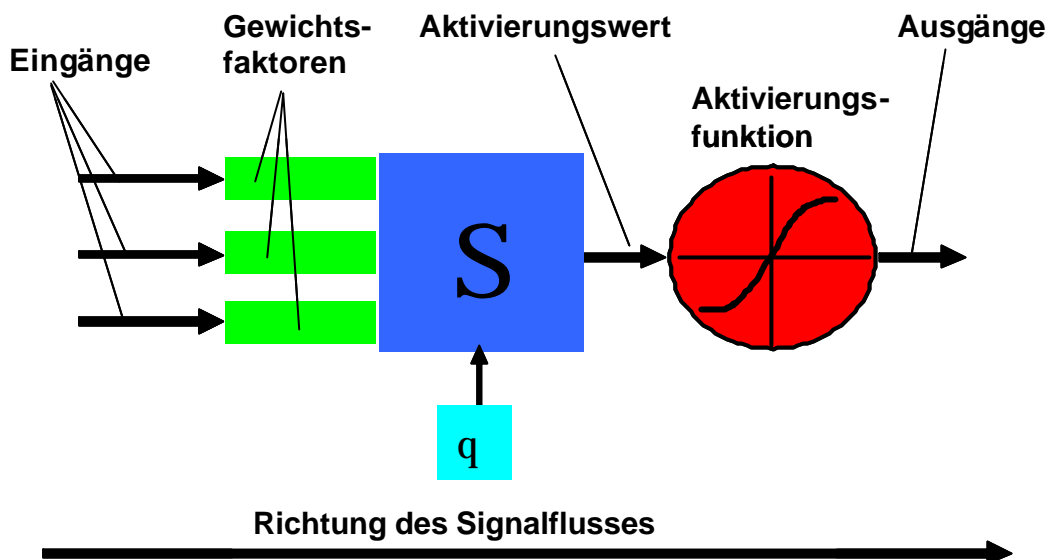
Ein biologisches Neuron (Abb. 1) wiederum besteht aus:

- einem Zellkern
- vielen Dendriten, über die ankommende Reize in die Nervenzelle gelangen
- einem Axon, durch das die Zellaktivität an andere Zellen weitergeleitet wird
- Kontaktstellen zwischen dem Axon und den Dendriten (Synapsen), die die elektrochemischen Impulse verstärken oder hemmen /2/

Ein Neuron des menschlichen Gehirns hat zwischen 20000 und 200000 Eingänge, durch die Nervenimpulse zum Neuron gelangen. Um logische Funktionen nachzubilden, werden die Neuronen zu einem Netz verbunden.

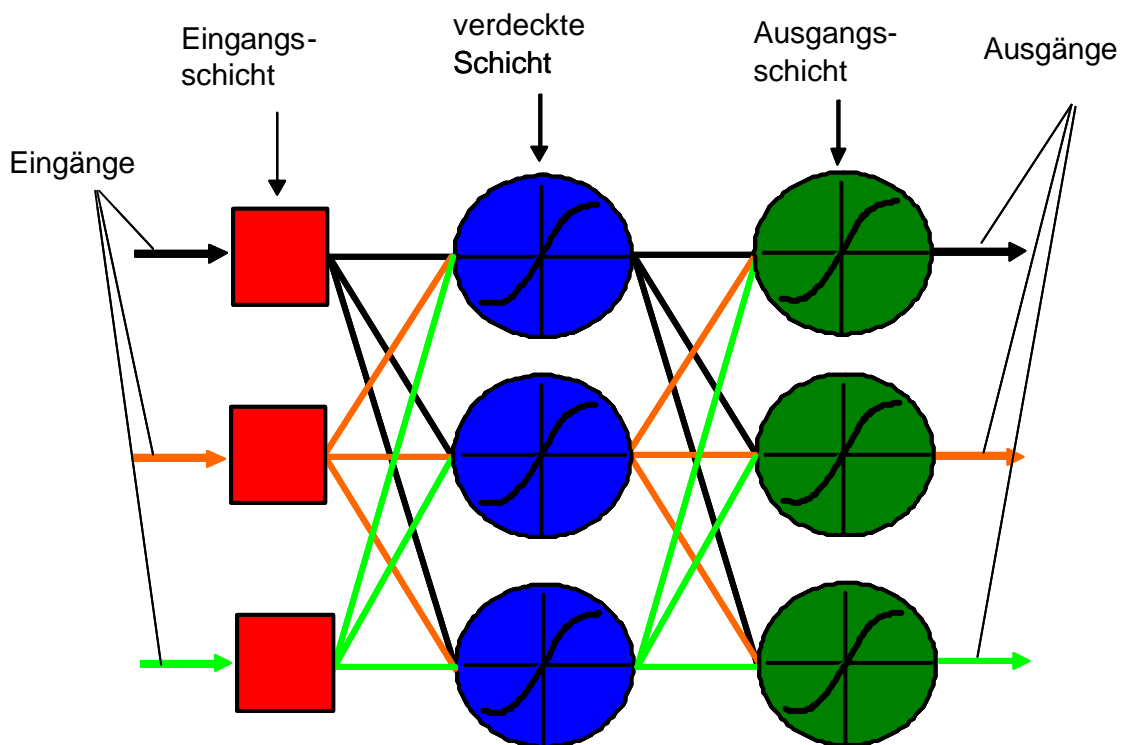
Zu den wesentlichen Vorteilen der neuronalen Netze zählen die Eigenschaften, dass die Netze alleine lernen können und auch dann noch funktionieren, wenn Teile des Netzes ausfallen. Ein weiterer wichtiger Vorteil der Netze ist die Verallgemeinerungsfähigkeit des gesammelten (erlernten) Wissens. Aber neuronale Netze haben auch Nachteile. So können beispielsweise exakte Berechnungen von Zahlenwerten nicht einfach ermittelt werden.

Ein künstlich nachgebildetes Neuron ist in seinem Aufbau einem biologischen Neuron nachempfunden. Die Eingangssignale gelangen auf Signaleingänge, die beim biologischen Vorbild den Dendriten entsprechen. Die Funktion der Synapsen werden mit Hilfe von Gewichtungsfaktoren dargestellt (Abb. 2), d. h. jedes Eingangssignal wird mit diesem Faktor gewichtet, so dass sie entweder verstärkt oder gehemmt werden können. Anschließend werden alle so modifizierten Signale sowie ein Schwellwert  $\theta$ , der eine notwendiges Mindestaktivierungslevel des Neurons bestimmt, aufsummiert und dienen als Aktivierungswert  $\alpha$  der Zelle. Das Neuron besitzt eine i. A. nichtlineare Übertragungsfunktion  $f$  (Aktivierungsfunktion). In Abhängigkeit vom Aktivierungswert der Zelle wird der Funktionswert dieser Übertragungsfunktion bestimmt und als Ausgangssignal  $y = f(\alpha)$  ausgegeben (Axon).



**Abb. 2** *Aufbau eines künstlichen Neurons*

Ein künstliches neuronales Netz entsteht durch die vernetzte Anordnung mehrerer künstlicher Neuronen, die in Schichten organisiert sind. Wie in Abb. 3 dargestellt werden die Eingangssignale mit allen Neuronen der Eingangsschicht verbunden. Die jeweiligen Ausgangssignale werden mit den Neuronen der nachfolgenden Schicht verbunden, so daß die Signale vorwärts durch das Netz transportiert werden. Im Rahmen der hier dargestellten Untersuchungen wurden nur neuronale Netze betrachtet, bei denen die Signale nicht auf Neuronen vorangegangener Schichten rückgekoppelt werden.



**Abb. 3** *Aufbau eines künstlichen neuronalen Netzwerkes mit drei Schichten*

Das ganze Wissen des Netzes steckt in den Werten der Gewichtungsfaktoren und der Schwellwerte. Die Lernfunktion des Netzes besteht in der automatischen Wahl der Gewichtungsfaktoren, um das Netz auf die Lösung einer Aufgabe zu optimieren. Grundsätzlich gibt es zwei Lernmethoden: überwachtes und unüberwachtes Lernen: beim überwachten Lernen wird dem Netz eine Lernmenge, d. h. eine Sammlung von Eingangsdaten und zugehörigen Sollwerten, präsentiert. Über die Abweichungen der vom Netz ermittelten Ausgangs- zu den Sollwerten werden die Modifikationen an den Gewichtswerten durchgeführt.

Unüberwachtes Lernen unterscheidet sich vom überwachten Lernen dadurch, dass dem Netz nur Eingangsdaten ohne die jeweiligen Zielwerte präsentiert werden. Bei dieser Methode entstehen zunächst zufällige Ausgangswerte. Neuronen, die gewisse Merkmale aufweisen, werden anschließend entweder durch Anhebung der Gewichtungsfaktoren unterstützt oder aber durch Absenken dieser Faktoren unterdrückt, so dass sich das Netz selber organisiert /2/.

Für das Trainieren eines neuronalen Netzes gibt es mehrere Algorithmen; auf die hier im Einzelnen nicht eingegangen wird. Bei den hier beschriebenen Untersuchungen wurde der Backpropagation-Algorithmus verwendet. Dieser sehr verbreitete Algorithmus gehört zu der Gruppe der Methoden für überwachtes Lernen und versucht eine definierte Kostenfunktion zu minimieren. Diese Kostenfunktion  $D$  wird oft auf die quadratischen Abweichungen zwischen Ausgangs- und Sollwerten zurückgeführt:

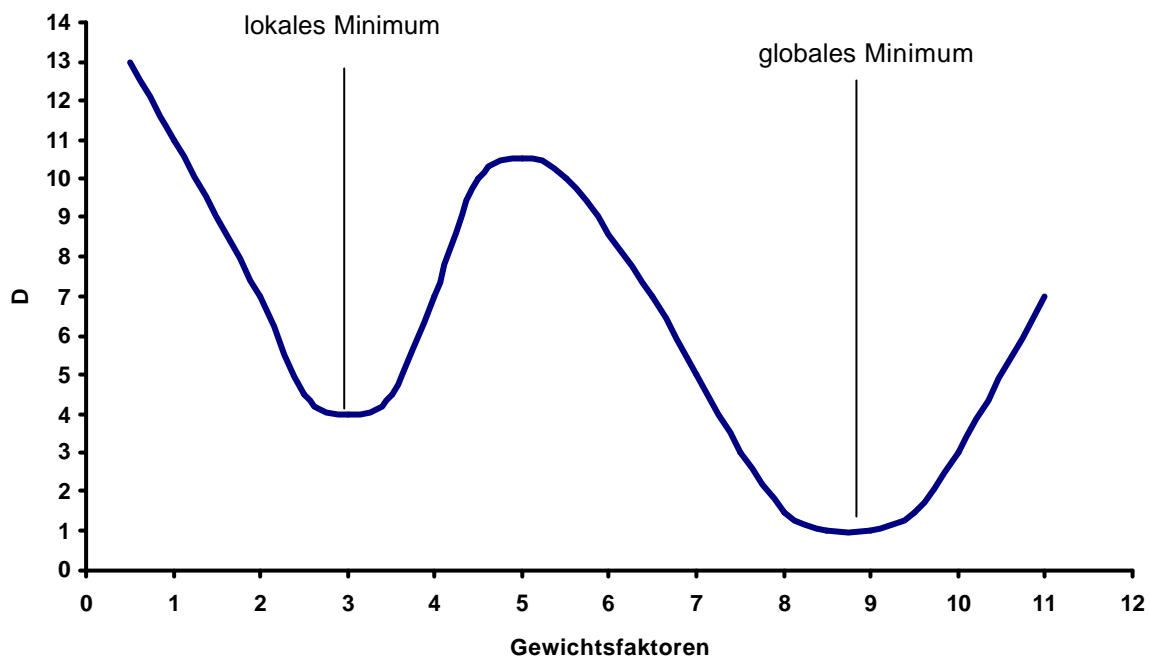
$$D = 0.5 \sum_{j=1}^p \sum_{k=1}^M \left( A_k^{(j)} - S_k^{(j)} \right)^2$$

Hierbei sind  $A$  die Ausgänge des Netzes und  $S$  die Sollwerte der Lernmenge.

$D$  ist also eine Funktion der Gewichtungsfaktoren und stellt allgemein eine Abbildung des Raumes  $R^n$  nach  $R^m$  dar, wobei  $n$  die Anzahl der Eingangssignale und  $m$  die Zahl der Ausgänge darstellt. Das Ziel des überwachten Lernens ist es, das globale Minimum dieser Abbildung zu finden.

Das Backpropagationverfahren nutzt hierzu das Gradientenabstiegsverfahren. Der momentane Lernzustand des Netzes ist durch die Werte der Gewichtungsfaktoren gegeben und wird daher durch einen Punkt auf dem „Gebirge“ der Kostenfunktion im Raum  $R^m$  (vgl. Abb. 4) repräsentiert. Wenn man die Gewichtungsfaktoren so ändert, dass

der Lernzustand in Richtung des stärksten Gefälles verschiebt, wird man sich auf ein Minimum hinbewegen.



**Abb. 4** Beispiel einer eindimensionalen Kostenfunktion

Die Lernregel lautet:

$$\delta w_{ij} = -\eta \frac{\partial D}{\partial w_{ij}}$$

Je stärker der Gradient ist, desto größer fällt die Gewichtungsfaktoränderung aus.  $\eta$  ist die Lernrate /3/.

## 2 Anwendungen in der Beleuchtungstechnik

Im Rahmen einer Dissertation an der Technischen Universität Istanbul, Türkei, wurden mit Hilfe von neuronalen Netzen die vom Nutzer bevorzugten Beleuchtungsstärkeniveaus ermittelt. Die hierfür eingesetzten Lerndaten wurden in realen Büroräumen gemessen, in denen sich Testpersonen die Beleuchtung nach ihren Wünschen einstellen konnten /4/.

Neuronale Netze finden im Rahmen eines Forschungsprojektes an der TU Berlin Anwendung bei dem Aufbau eines Beleuchtungsregelungssystems für Tageslichtsysteme und Kunstlichtbeleuchtung. Im Fall des Projektes „Autoadaptive Systeme“ wird das Netz mit Eingangsdaten, die die Außenbedingungen (horizontale Außenbeleuchtungsstärke, Himmelzustand, wahre Ortszeit und Jahreszeit) beschreiben, und Sollwerten, die die Beleuchtungssituationen in Innenraum

beschreiben (Jalousienposition und deren Neigungswinkel sowie die Dimmzustände der Leuchten), trainiert.

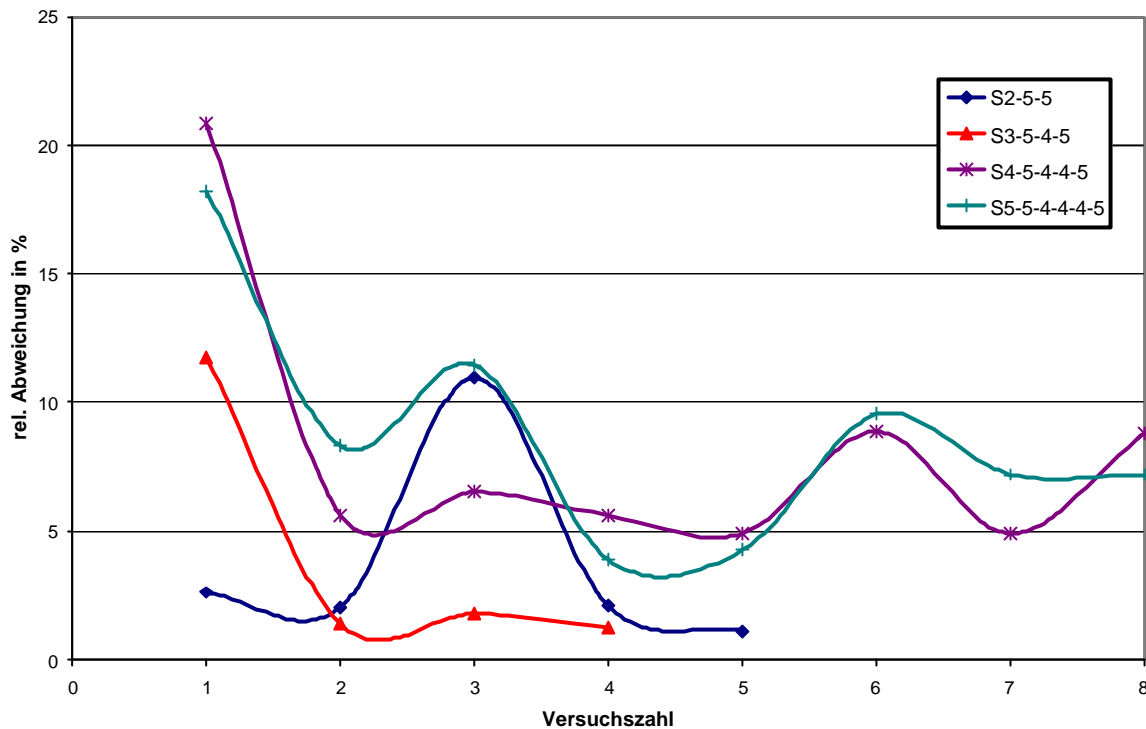
Es ist zu untersuchen, inwiefern die Struktur der einzusetzenden neuronalen Netze, d. h. Schichtenanzahl und Zahl der Neuronen pro Schicht sowie die vorgegebene Lernmenge einen Einfluss auf die Funktion des neuronalen Netzes hat. In einem nächsten Schritt wird untersucht, wie sich die Netze bei neuen Situationen, d. h. bei Eingangssignalen, die nicht trainiert wurden, aufgrund ihrer „Erfahrung“ Ähnlichkeiten zu Daten, mit denen es schon trainiert wurde, herstellt.

Verschiedene Strukturen für neuronale Netze wurden hierfür zunächst getestet. Diese neuronalen Netze wurden softwaretechnisch simuliert. Die Randbedingungen der Untersuchungen (Lerngeschwindigkeit, Anzahl der Iterationen Lernalgorithmus Backpropagation, Umfang der Lernmenge) blieben bei allen Versuchen aus Gründen der Vergleichbarkeit konstant.

In der folgenden Tabelle sind die getesteten Netze in der ersten Untersuchungsphase zusammengefasst:

| Netzname      | S2-5-5 | S3-5-4-5 | S4-5-4-4-5 | S5-5-4-4-4-5 |
|---------------|--------|----------|------------|--------------|
| Schichtanzahl | 2      | 3        | 4          | 5            |
| Neuronanzahl  | 5-5    | 5-4-5    | 5-4-4-5    | 5-4-4-4-5    |

Die Netze wurden zunächst trainiert. Hierbei umfasst ein Versuch eine Iterationszahl von 1000. Nach jedem Versuch wurde die Kostenfunktion des Netzes berechnet. Lag die Kostenfunktion über einem definierten Akzeptanzwert von 0.01, so wurde ein neuer Versuch mit 1000 Lerniterationen gestartet. Auf diese Weise kann festgestellt werden, ob und wie schnell das betrachtete neuronale Netz gegen einen Zielwert konvergiert. Zunächst wurde betrachtet, welche Einflüsse die Zahl an Schichten sowie die Zahl der Neuronen pro Schicht auf die Genauigkeit des Netzes haben (Abb. 5).



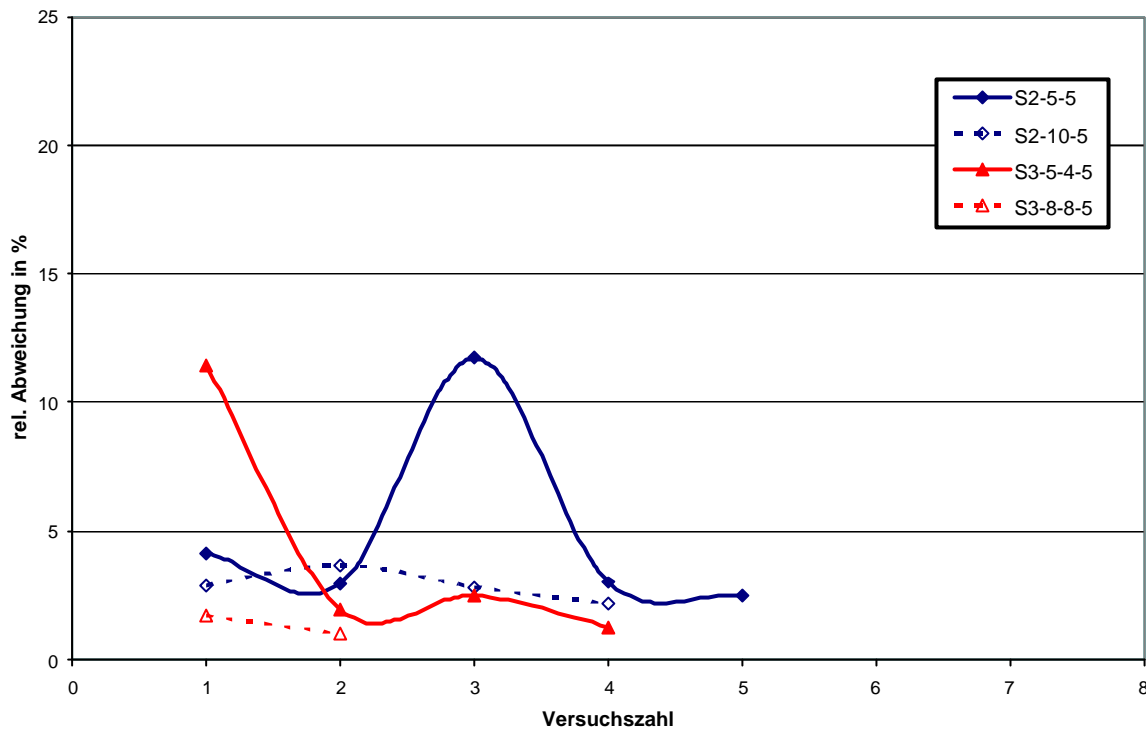
**Abb. 5** Relative Abweichungen verschiedener Netze im Verlauf des Lernens

In Abb. 5 ist zu erkennen, dass sich bei unterschiedlichen Netzen deutliche Unterschiede bezüglich der Lernfähigkeit ergeben. Insbesondere zeigen sich Vorteile bei den zwei- und dreischichtigen Netzen. Dieses legt die Vermutung nahe, dass die Struktur der fünfschichtigen Netze zu komplex für die Aufgabe ist und das Netz sich langsamer adaptiert. Die vielen Freiheitsgrade, die durch die höhere Anzahl an Gewichtungsfaktoren entstehen, führen hier nicht zu einem Vorteil.

In der nächsten Stufe der Untersuchungen wurde die Anzahl an Neuronen pro Schicht bei den zwei- und dreischichtigen Netzen verändert:

| Netzname      | S2-5-5 | S2-10-5 | S3-5-4-5 | S3-8-8-5 |
|---------------|--------|---------|----------|----------|
| Schichtanzahl | 2      | 2       | 3        | 3        |
| Neuronanzahl  | 5-5    | 10-5    | 5-4-5    | 8-8-5    |

Die Ergebnisse sind in Abb. 6 dargestellt. Das Netz S2-10-5 ist im Vergleich zu S2-5-5 breiter ausgelegt und führt zu besseren Ergebnissen. Gleiches gilt im Falle dreischichtiger Netze. Das Netz S3-8-8-5 ist bereits nach der zweiten Lernphase so gut adaptiert, dass es bereits die Akzeptanzgrenze erreicht hatte.



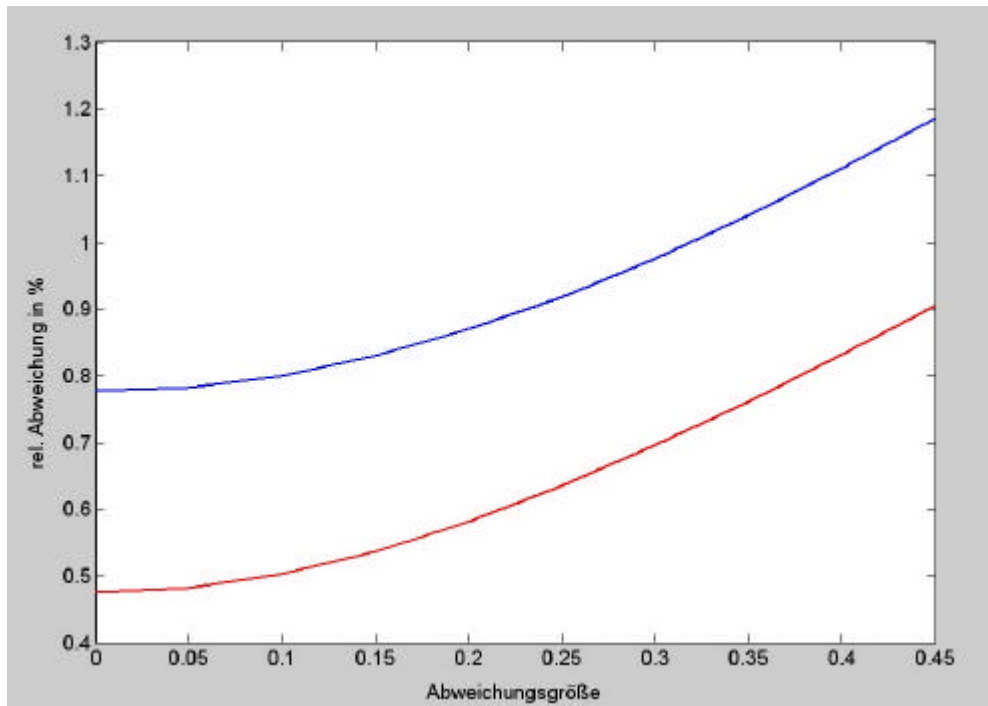
**Abb. 6** Vergleich 2- und 3-schichtiger Netze mit unterschiedlicher Breite

Die bisherigen Betrachtungen lassen den Schluss zu, dass die Schichtenanzahl einen geringeren Einfluss auf die Genauigkeit hat, als sehr sinnvoll hat sich eine Änderung der Anzahl der Neuronen pro Schichte erwiesen. Diese Betrachtungen basieren jedoch nur auf der Qualität der neuronalen Netze bezüglich der Lernmenge. In einem nächsten Schritt muss diese Qualität für veränderte Eingangsdaten überprüft werden. So können Aussagen über das Verhalten der Netze unter realen Bedingungen getroffen werden.

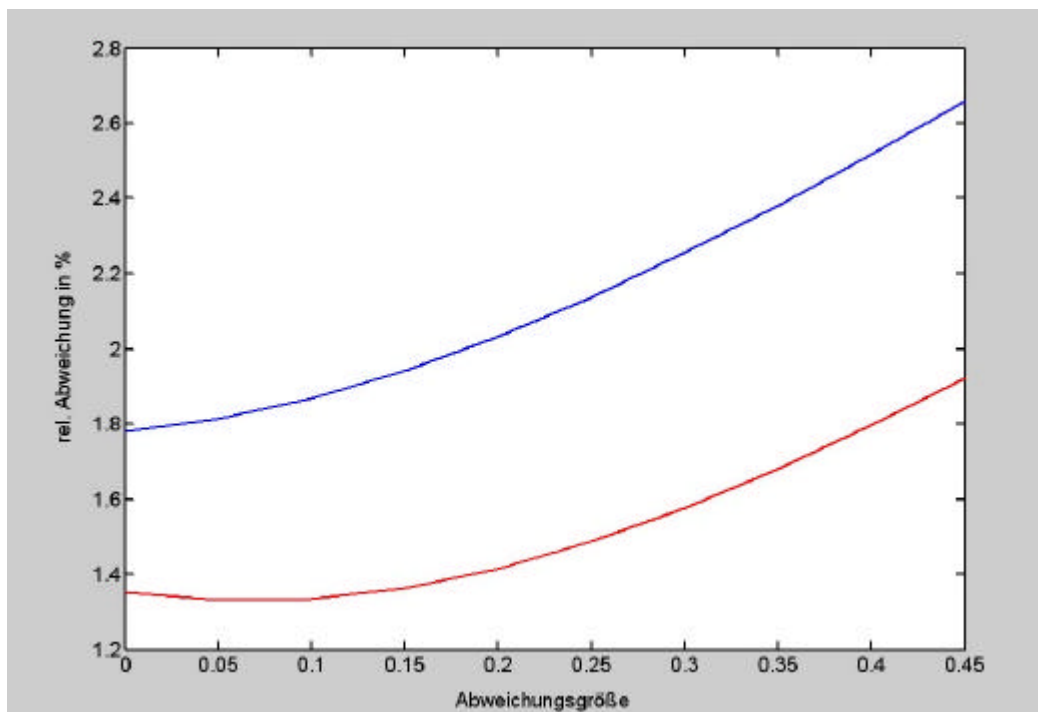
Hierzu wird zum einen die Lernmenge modifiziert. Dieses geschieht durch eine relative Veränderung der Daten von bis zu 45 %. Zusätzlich wird eine Testmenge mit Daten, die nicht für das Training des Netzes herangezogen wurden, definiert. Im weiteren Verlauf der Untersuchungen ist auch diese Testmenge auf die gleiche Art und Weise wie die Lernmenge modifiziert worden. Die veränderte Lernmenge und die Testmenge wurden den trainierten neuronalen Netzen präsentiert. Anschließend wurde über die Kostenfunktion die relative Abweichung bestimmt. Die Ergebnisse sind für die jeweils besten zweischichtigen und dreischichtigen Netze (S2-10-5 und S3-8-8-5) in Abb. 7 und Abb. 8 dargestellt.

Die roten Kurven zeigen relativen Abweichungen für verschiedene Abweichungsgrößen, der Lernmenge für das Netz S2. Die blauen Kurven stellen die relativen Abweichungen für die Netze bei der (modifizierten) Testmenge dar.

Der Anstieg der Kurven bei modifizierten Eingangsdaten ist zu erwarten. Die Maximalwerte der dargestellten Kurven bleiben noch in einem akzeptablen Bereich.



**Abb. 7** Netz S2-10-5: Verhalten bei modifizierten Lern- (rot) und Testdaten (blau)



**Abb. 8** Netz S3-8-8-5: Verhalten bei modifizierten Lern- (rot) und Testdaten (blau)

Die hier dargestellten Untersuchungen haben gezeigt, dass neuronale Netze grundsätzlich zur Regelung der Tages- und Kunstlichtbeleuchtung eingesetzt werden

können. Unterschiede in ihrer Funktionsweise ergeben sich aus der Netzstruktur und der Basislernmenge.

Die Anzahl der Schichten spielt in diesem Falle keine große Rolle. Eine zu große Anzahl an Schichten erfordert einen wesentlich größeren Lernaufwand, der aufgrund der Ergebnisse der Netze mit zwei bzw. drei Schichten nicht gerechtfertigt werden kann. Aufgrund der bisherigen Untersuchungen erscheint der Einsatz „breiter“ zweischichtiger bzw. dreischichtiger künstlicher neuronaler Netze für diese Aufgabe sinnvoll.

Weitere Untersuchungen mit unterschiedlich großen Lernmengen zeigen die Tendenz auf, dass ein Netz, das mit einer größeren Menge an Eingangsdaten trainiert wurde, geringere Abweichungen bei Testdaten aufweist. Die Fähigkeit zur Verallgemeinerung wird durch größere Lernmengen gestärkt. Gleichzeitig steigt jedoch auch der Aufwand, der für das Trainieren eines neuronalen Netzes betrieben werden muss.

## **Danksagung**

Die hier dargestellten Untersuchungen werden durch das BMWA im Rahmen des Verbundprojektes „Tageslichtnutzung in Gebäuden“ unterstützt.

## **Literatur**

- /1/ <http://republika.pl/neuronowe/pliki/strukt/strukt1.html>
- /2/ Zakharian, S., Ladewig-Riebler, P, Thoer, S.; Neuronale Netze für Ingenieure, Vieweg Verlag Braunschweig; Wiesbaden; ISBN 3-528-05578-2; 1988
- /3/ Hoffmann, N.; Kleines Handbuch neuronale Netze; Vieweg Verlag Braunschweig; Wiesbaden; ISBN 3-528-05239-2; 1993
- /4/ Çolak, N., Onaygil, S.; Prediction of the artificial illuminance using neural networks; Lighting Research and Technology, 31; pp. 63-66, 1999