

Künstliche Neuronale Netze - Methode und Anwendung

Tawil, M.

Künstliche Neuronale Netze (KNN) sind Modelle, mit denen man versucht, einige Funktionen des menschlichen Gehirns nachzuempfinden. Diese Modelle bestehen, ähnlich dem Gehirn, aus einer Vielzahl gleichartiger Elemente (Neuronen), die parallel arbeitend Informationen verarbeiten. Eine der wichtigsten Eigenschaften von KNN ist ihre Fähigkeit gelernte Beispiele zu verallgemeinern und basierend darauf neue Sachverhalte zu prognostizieren.

Artificial neural nets (ANN) are models for imitating some of the functions of the human brain. These models consist of a large number of identical elements (neurons), which process information simultaneously. One of the most important qualities of ANN is their ability to generalise from learned examples and then to forecast new circumstances.

1 Das Biologische Vorbild

Das biologische Neuronale Netz besteht aus einem sich im Gehirn von Menschen und Tieren befindlichen Bündel von Nervenzellen (**Bild 1**), sog. Neuronen. Ein Neuron besteht aus dem Zellkörper (Soma), einem oder mehreren Eingängen (Dendriten) und einem Ausgang (Axon), der auch verzweigt sein kann.

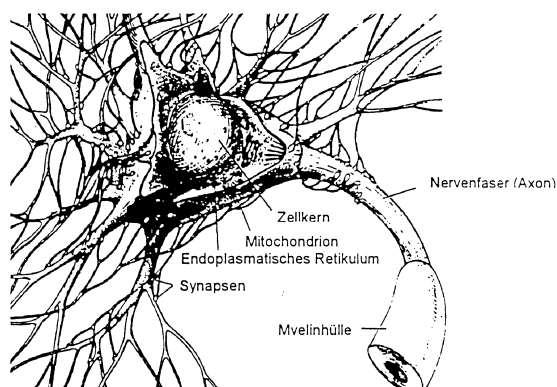


Bild 1: Biologische Nervenzelle

An der Stelle, wo ein Axon auf die Zelloberfläche eines Neurons oder auf eine seiner Dendriten trifft, befinden sich die Synapsen. In den Synapsen findet eine Gewichtung der Eingangssignale statt, d.h. die Signale werden entweder geschwächt oder ver-

stärkt. Anschließend werden über das Axon eintreffende Signale chemisch bzw. elektrisch an das Neuron übertragen. Übersteigt die Summe der Eingangssignale einen bestimmten Schwellenwert, so wird ein Aktionspotential ausgelöst, d.h. das Neuron „feuert“.

Obwohl alle Neuronen ein gemeinsames Grundverhalten aufweisen, kann man verschiedene Neuronentypen definieren, die sich in Größe, Verzweigungsfaktor des Dendritenbaumes, Länge des Axons, Leitungsgeschwindigkeit usw. unterscheiden /1/. Die Komplexität der Funktion des Nervensystems resultiert somit allein aus der großen Zahl parallel arbeitender Neuronen (~10 Milliarden) und deren Verknüpfung untereinander und nicht aus aufwendigen algorithmischen Verfahren. Jede dieser biologischen Einheiten kann vereinfacht also als analog arbeitender Summenverstärker mit Schwellenschaltung beschrieben werden. Hierbei findet die Informationsverarbeitung lokal statt. Es existiert keine globale Überwachungseinheit. Diese Arbeitsweise erlaubt es auch, das Absterben von Neuronen zu verkraften, ohne daß die bestehenden Informationen im Sinne der Redundanz mehrfach abgelegt sein müßten. Vielmehr wird das dort vorhandene „Wissen“ verteilt im System gespeichert, so daß jedes Neuron einen Teil zur Information beiträgt, aber doch nicht die gesamte Information besitzt. Das „Wissen“ liegt in Form von Beispielen vor. Aktuell vorliegende Probleme werden mit entsprechenden, in der Vergangenheit erfolgreich gelösten Problemen assoziiert. Die Assoziationsfähigkeit eines Menschen ermöglicht ihm angemessen auf seine Umwelt zu reagieren und Situationen zu meistern, in denen er sich nie zuvor befunden hat.

Um einige Eigenschaften des biologischen Nervensystems wie die simultane Informationsverarbeitung, Assoziativität, Fehlertoleranz, Adaptionsfähigkeit, Lernfähigkeit u.a. für technische Systeme nutzen zu können, entstanden seit Anfang der achtziger Jahre eine ganze Reihe Künstlicher Neuronaler Netzwerke. Allerdings erreichen diese Modelle nicht einmal ansatzweise die Komplexität ihrer biologischen Vorbilder und stellen daher nur ein recht primitives Abbild dieser dar.

2 Das mathematische Modell

Künstliche Neuronale Netze (KNN) orientieren sich in ihrem Aufbau und ihrer Funktionsweise am biologischen Vorbild. Sie stellen ein sehr Abstraktes Modell des tierischen bzw. menschlichen Nervensystems dar. Dementsprechend bestehen KNN aus mehreren, miteinander verknüpften Informationsverarbeitungseinheiten, den Neuronen.

Das künstliche Neuron (**Bild 2**) kann als eine Schaltung aufgefaßt werden. Diese Schaltung erzeugt, analog zum biologischen Vorbild, erst eine Ausgabe, wenn die Summe der Eingangssignale des Neurons einen bestimmten Schwellenwert überschreitet. Dabei können die Eingabe- sowie Ausgabesignale der Neuronen binär (0, 1) reell (+, -), oder bipolar (-1, +1) sein.




Bild 2: Innerer Aufbau eines Neurons /2/

Analog zum biologischen Neuron werden auch hier die Eingangssignale gewichtet. Diese Gewichtung stellt eine Art Filter dar. Sie kann die Signale verstärken oder abschwächen. Die Gewichtung $w = 0$ bedeutet „keine Verbindung“.

Das Neuron enthält verschiedene mathematische Funktionen zur Informationsverarbeitung. Mit der Propagandierungsfunktion kann die Summe, der Maximal- oder Minimalwert der gewichteten Eingaben gebildet werden. Die Aktivierungsfunktion eines Neurons ist seine statische Kennlinie und beschreibt den Zusammenhang zwischen Ein- und Ausgängen. Sie kann linear, sprunghaft (Schwellwertfunktion) oder stetig (sigmoide Funktion) sein (**Bild 3**). Somit legt die Aktivierungsfunktion fest, wie sich aus einem Aktivierungszustand zum Zeitpunkt t ein Aktivierungszustand $t+1$ berechnen läßt. Die Ausgabefunktion bildet den aktuellen Zustand des Neurons auf einen gewünschten Wertebereich ab. Die Schnelligkeit der Informationsverarbeitung innerhalb des Neuronalen Netzes liegt darin begründet, daß jedes Neuron nur eine sehr einfache Rechenoperation (Verarbeitungsfunktion) durchzuführen hat /3/. Durch die Verknüpfung der Neuronen lassen sich KNN realisieren. Dabei werden die Neuronen in verschiedenen Schichten zusammengefaßt. In der Eingabeschicht werden die

von außen kommenden Eingangssignale verarbeitet und an die Neuronen der versteckten Schicht weitergeleitet. Diese Neuronen werden netzintern verwaltet und unterliegen voll dem Informationsfluß, der gemäß dem gewählten Netzmodell definiert ist /4/. Die Ausgabeschicht stellt das Ergebnis der vom Netz durchgeführten Informationsverarbeitung zur Verfügung. Hier können also die Endwerte der Berechnung abgegriffen werden.

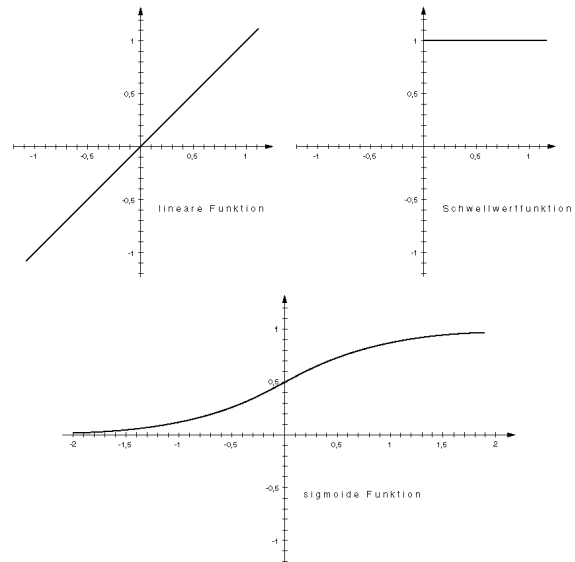


Bild 3: Aktivierungsfunktionen von Neuronen

2.1 Lernalgorithmen von KNN

Ein wichtiges Unterscheidungskriterium der KNN ist ihr Lernalgorithmus. Der Lernprozeß eines Neuronalen Netzes wird über die Verstellung der Gewichte von den Eingangswerten nach einer bestimmten Lernregel gesteuert. Je nach Verwendungszweck gibt es für jedes KNN eine Lernregel. Die meisten heute verwendeten Lernregeln basieren auf der Hebb'schen Regel. Dabei gibt es zwei Arten des Lernens. Dies sind das überwachte und das unüberwachte Lernen. Im letzteren Fall wird das Netz während des Lernprozesses nicht von außen gesteuert sondern teilt selbst die Eingabedaten in verschiedene Klassen ein. Beim überwachten Lernen werden dem KNN zusätzlich die vorsortierten Eingabewerte (Muster), die zu einer bestimmten Klasse gehören, gegeben. Das Netz wird in diesem Fall von außen trainiert. Durch einen Soll-Ist-Vergleich wird ein Fehler berechnet. Dieser Fehler wird vom Netz dazu benutzt, die Zuordnung der Eingabewerte zu einer bestimmten Klasse zu erlernen. Das Lernen durch Fehlerkorrektur ist der am meisten angewandte Lernmechanismus. Hier werden die Gewichte solange geändert bis der Fehler zwischen dem Ist- und dem Soll-Wert minimal wird /5/.

3 Grundtypen von KNN

3.1 Allgemeines

Es gibt heute eine Vielzahl unterschiedlicher künstlicher neuronaler Netztypen, die nach dem gleichen, oben erläuterten, mathematischen Modell arbeiten. Welcher Typ bei welchem Anwendungsfall Verwendung findet, ist stets von der vorliegenden Problemstellung abhängig. Ein KNN muß immer auf die vorliegende Problematik angepaßt werden. Diese Anpassung wird durch die Wahl der Netzarchitektur, der Neuronenzahl, der Eingangs- und Aktivierungsfunktion gewährleistet. So hängt die Wahl der Netzarchitektur und die Festlegung der Neuronenzahl vom Komplexitätsgrad der Aufgabenstellung ab. Dies sind jedoch keine allgemeingültigen Aussagen über Eignung bzw. Nichteignung eines Netzes zur Lösung einer entsprechenden Problemstellung. Aus diesem Grund müssen zur Abbildung bestimmter Sachverhalte die optimalen Netzattribute mittels umfangreicher problemspezifischer Versuche ermittelt werden /3/.

Zur detaillierten Beschreibung der verschiedenen Netzwerkmodelle sei an dieser Stelle auf die im Text zitierte Literatur /1, 4, 5/ verwiesen. Im folgenden wird das unter den neuronalen Systemen am meisten verwendete Modell der Backpropagation kurz erläutert.

3.2 Backpropagation-Netz

In **Bild 4** ist die Struktur eines Backpropagation-Netzes, das nach dem Prinzip der Fehlerrückführung arbeitet, abgebildet. Das Netz besteht aus einer Eingabe- sowie einer Ausgabeschicht und einer oder mehrerer verdeckten Schichten. Die Signalübertragung erfolgt in Vorwärtsrichtung. Im folgenden soll die Funktionsweise des KNN nach der Backpropagation-Methode erläutert werden.

Die Eingabe-Neuronen antworten auf ein Eingabemuster mit Werten, die an die versteckten Neuronen gegeben werden. Deren Ausgänge wirken wiederum auf die Neuronen der Ausgabeschicht. Das Netz erzeugt schließlich Ausgabemuster (Output). Der Output O wird mit den gewünschten Ziel-Ausgabemustern t (target) verglichen. Hieraus wird dann ein Fehler berechnet. Ausgehend von diesem Fehler werden die Gewichtungen der Neuronen in der Ausgabeschicht und der verdeckten Schicht verstellt. Anschließend werden dem Netz neue Eingabemuster bereitgestellt, eine Antwort hieraus berechnet und erneut ein Fehler gebildet. Dieser Vorgang wird solange wiederholt, bis Output O und

gewünschter Output t genügend nahe beieinander liegen. Das Netz ist dann trainiert und steht zur Beurteilung ähnlicher Sachverhalte zur Verfügung. Das so trainierte Netz muß getestet werden. Dazu sind Testdaten vorzusehen, die sich von den Trainingsdaten unterscheiden müssen. Nur dadurch kann gewährleistet werden, daß das trainierte Netz in der Lage ist, basierend auf dem in den Neuronen gespeicherten Wissen, unbekannte Muster und Sachverhalte richtig einzuordnen.

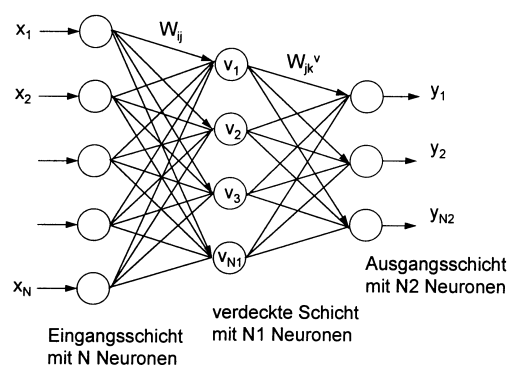


Bild 4: Backpropagation-Netz mit n Eingängen, m Ausgängen und einer verdeckten Schicht /5/

4 Anwendungsbereiche von KNN

Die Bandbreite der Anwendung Künstlicher Neuronaler Netze hat mit der rasanten Entwicklung der Hard- und Software von Rechnern zugenommen. Es existieren heute zahlreiche Netzmodelle für spezielle Anwendungen in der Qualitätssicherung, Bild-, Muster- und Spracherkennung sowie Automatisierungstechnik /5/. KNN werden schon in der Konstruktion und Entwicklung zur Bauteilauslegung und -optimierung erfolgreich eingesetzt /3, 6/. Ein weiteres Einsatzgebiet neuronaler Systeme ist die Fertigung. Dort werden sie zur Prozeßoptimierung durch Festlegung geeigneter Prozeßparameter heran gezogen /2, 7/.

Am Institut für Maschinenwesen der TU Clausthal wurde im Rahmen des Sonderforschungsbereichs SFB 362 "Fertigen in Feinblech" ein KNN entwickelt, mit dessen Hilfe das Rückfederungsverhalten tiefgezogener Blechteile vorhergesagt wird.

Zum Erzeugen des Trainingssets für das KNN wurden zahlreiche Versuche unter Variation der auf den Tiefziehvorgang wirkenden Parameter (5 Parameter) sowie deren Kombinationen durchgeführt. Nach den Versuchen wurden die gefertigten Werkstücke vermessen, um so die Rückfederungswerte zu ermitteln. Es entstand ein statistisch gesicherter

Trainingsset, mit dem ein ausgewähltes und an die vorliegende Problemstellung angepaßtes Netz beaufschlagt wurde.

Das hier verwendete KNN arbeitet nach der Backpropagation-Methode. Es wurde verschiedene Netzarchitekturen unter Variation der Neuronen- sowie Schichtenzahl und der Aktivierungsfunktionen getestet. Dabei arbeiteten die künstlichen neuronalen Netze zwischen 15 000 und 20 000 Iterationsschritten je durchgerechneter Startwertkombination ab. Es hat sich gezeigt, daß besonders gute Ergebnisse mit ein bis drei Neuronen unter Anwendung von logsig-, tansig- und linearen Aktivierungsfunktionen sowie deren Kombinationen erzielt werden können. Trainingsversuche mit einer höheren Anzahl von Neuronen oder anderen Aktivierungsfunktionen, wie z.B. die Schwellwertfunktion, lieferten eher schlechte Ergebnisse.

Nach dem trainieren des Netzes wurden Bestätigungsversuche durchgeführt um die Zuverlässigkeit des Netzes bei der Rückfederungsvorhersage zu überprüfen. Die erzielte durchschnittliche Abweichung zwischen den durch das Künstliche Neuronale Netz errechneten und den experimentell ermittelten Rückfederungswerten liegt bei 0,02 mm. **Bild 5** stellt diese Differenz graphisch dar. Die im vorliegenden Fall trainierten Netze können also Rückfederungen mit einer Sicherheit von bis zu 98% vorhersagen.

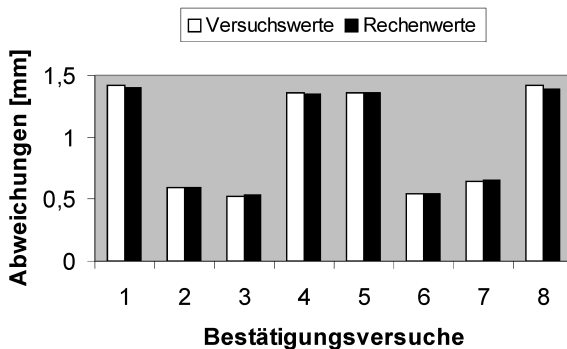


Bild 5: Verifizierung der Aussage eines trainierten Künstlichen Neuronales Netzes

Die hier vorhergesagten Rückfederungen von Tiefziehteilen sind den neuronalen Netzen in den abgefragten Parameterkombinationen nicht „bekannt“. Im Gegensatz zu einer Datenbank greifen die trainierten Netze auf ihr „Erfahrungswissen“ zurück, um auf unbekannte Fälle zu schließen und hier Vorhersagen zu treffen.

5 Zusammenfassung

Bestimmte Sachverhalte und Zusammenhänge können nur dann korrekt abgebildet werden, wenn diese in einem vorher erzeugten und statistisch geprüften Datensatz, mit dem das KNN trainiert wird, wiederzufinden sind. Den Vorteilen von KNN wie Lern-, Generalisierungs- und Adaptionfähigkeit sowie Fehlertoleranz stehen die Nachteile fehlende Nachvollziehbarkeit der Ergebnisse, lange Lernzeiten bei komplexen Netzanwendungen und die große Vielfalt von Netztypen gegenüber. Aufgrund der unterschiedlichen Netztypen, Lernalgorithmen sowie Aktivierungsfunktionen ist die Wahl eines optimalen KNN für eine bestimmte Aufgabenstellung ein iterativer Prozeß und daher mit großem Zeitaufwand verbunden. Die o.g. Nachteile sind sicher ein Grund dafür, daß das Anwendungspotential KNN in verschiedenen Ingenieurdisziplinen nur begrenzt ausgeschöpft wird. Ziel zukünftiger Forschungsarbeiten sollte daher sein, eine Vergleichsanalyse unterschiedlicher Netztypen durchzuführen und sich bei der Entwicklung von KNN mehr an ihren biologischen Vorbildern zu orientieren.

6 Literatur

- /1/ Berns, K.; Kolb, T.: Neuronale Netze für technische Anwendungen, Springer Verlag, Berlin, Heidelberg, 1994
- /2/ Heinen, F.: Entwicklung einer Methodik zur Rückfederungsvorhersage an Tiefziehteilen. Dissertation, TU Clausthal. Clausthal-Zellerfeld, 1998
- /3/ Krause, F.-L.; Carl, C.: Neuronale Netze in der Produktentwicklung. Konstruktion 49, H. 10 (1997): S. 19-23
- /4/ Kratzer, K. P.: Neuronale Netze - Grundlagen und Anwendungen. Carl Hanser Verlag, München; Wien, 1999
- /5/ Zakharian, S.; Ladewig-Riebler, P.; Thoen, S.: Neuronale Netze für Ingenieure. Vieweg Verlag, Braunschweig/Wiesbaden, 1998
- /6/ Artymiak, P.; Bukowski, L.; Feliks, J.; Narberhaus, S.; Zenner, H.: Determination of S-N curves with the application of artificial neural networks. Blackwell Science Ltd. Fatigue Fract Engng Mater Struct 22, S. 723-728, 1999
- /7/ Schulz, H.; Kalhöfer, E.: Zerspanungsparameter mit neuronalen Netzen bestimmen. wt Werkstattstechnik 88 (1998) H. 3: S. 125-128