

Zeitschrift: bulletin.ch / Electrosuisse
Herausgeber: Electrosuisse
Band: 105 (2014)
Heft: 10

Artikel: Künstliche Neuronale Netze
Autor: Leuenberger, Rolf
DOI: <https://doi.org/10.5169/seals-856308>

Nutzungsbedingungen

Die ETH-Bibliothek ist die Anbieterin der digitalisierten Zeitschriften auf E-Periodica. Sie besitzt keine Urheberrechte an den Zeitschriften und ist nicht verantwortlich für deren Inhalte. Die Rechte liegen in der Regel bei den Herausgebern beziehungsweise den externen Rechteinhabern. Das Veröffentlichen von Bildern in Print- und Online-Publikationen sowie auf Social Media-Kanälen oder Webseiten ist nur mit vorheriger Genehmigung der Rechteinhaber erlaubt. [Mehr erfahren](#)

Conditions d'utilisation

L'ETH Library est le fournisseur des revues numérisées. Elle ne détient aucun droit d'auteur sur les revues et n'est pas responsable de leur contenu. En règle générale, les droits sont détenus par les éditeurs ou les détenteurs de droits externes. La reproduction d'images dans des publications imprimées ou en ligne ainsi que sur des canaux de médias sociaux ou des sites web n'est autorisée qu'avec l'accord préalable des détenteurs des droits. [En savoir plus](#)

Terms of use

The ETH Library is the provider of the digitised journals. It does not own any copyrights to the journals and is not responsible for their content. The rights usually lie with the publishers or the external rights holders. Publishing images in print and online publications, as well as on social media channels or websites, is only permitted with the prior consent of the rights holders. [Find out more](#)

Download PDF: 15.04.2026

ETH-Bibliothek Zürich, E-Periodica, <https://www.e-periodica.ch>

Künstliche Neuronale Netze

Ideen aus der Natur zur Lösung technischer Probleme

Wie aus dem Zusammenwirken von Nervenzellen im menschlichen Gehirn kognitive Leistungen zustande kommen, ist bei Weitem nicht geklärt. Spannend ist aber, dass bereits die Nutzung einfachster Prinzipien aus dem biologischen Vorbild technische Lösungen ermöglicht. So fanden künstliche Neuronale Netze in den letzten Jahren in vielen Gebieten Anwendungen, bei denen herkömmliche Methoden oft weniger erfolgreich waren. Aufgaben wie die Mustererkennung, Prognosen, Diagnosen sowie Bewegungssteuerungen in der Robotik können oft mit neuronaler Technik effizient gelöst werden.

Rolf Leuenberger

Als «beängstigend menschlich» bezeichnete 1950 «Der Spiegel» die damals ersten, programmierbaren, elektronischen Rechenmaschinen. [1] Man sprach von Elektronengehirnen und glaubte, mit einer elektronischen Rechenmaschine von der Grösse eines Wolkenkratzers könnte die Leistungsfähigkeit des menschlichen Gehirns erreicht werden. Heute wissen wir, dass riesige Rechenleistung alleine nicht genügt, um die fantastischen Leistungen des menschlichen Gehirns nachzubilden.

Doch selbst wenn man die schwer definierbaren Fähigkeiten des Gehirns, wie etwa Wahrnehmung, Emotionen oder Kreativität, ausschliesst, bleiben immer noch Eigenschaften, die aus technischer Sicht ausgesprochen interessant sind. Der Gedanke, technische Systeme mit ähnlichen Eigenschaften, wie sie unser Gehirn hat, auszustatten, gewann in den letzten 50 Jahren zunehmend an Attraktivität.

Vorbild Gehirn

Besonders interessant ist die Lernfähigkeit des Gehirns. Sie gibt uns Menschen eine enorme Anpassungsfähigkeit an gegebene Umstände und ermöglicht uns auch, unsere Verhaltensmuster für beste Überlebenschancen optimal anzupassen. Im Gegensatz zu fest programmierten oder konstruierten Maschinen kann die Lernfähigkeit technischen Systemen neue Dimensionen eröffnen.

Es ist aber auch die enorme Rechengeschwindigkeit, die unser Gehirn auszeichnet. Sehen wir zum Beispiel plötzlich das Gesicht einer bekannten Person in einer

Menschenmenge, dauert es wenige Zehntelsekunden, und wir erkennen diese Person – bezüglich Bildverarbeitung eine gigantische Leistung, die das Gehirn in diesem Augenblick vollbringt. Der Schlüssel dazu heisst parallele Signalverarbeitung. Diese 1,31 graue Masse Hirn besteht nämlich aus einer beachtlichen Anhäufung von Nervenzellen. Man nimmt an, dass es etwa 100 Milliarden Einzelzellen sind, wovon jede im Mittel mit einigen Tausend benachbarten Zellen verbunden ist. Das Ganze bildet also ein Netz mit etwa einer Billiarde Verbindungspunkten. Die Sinnesreize werden diesem Netz zugeführt, und über die gegenseitigen Ver-

knüpfungen sind sofort eine grosse Anzahl Nervenzellen gleichzeitig mit der Verarbeitung der Reize beschäftigt. Die Verarbeitung der Signale erfolgt also parallel mit vielen Nervenzellen. Interessanterweise sind die einzelnen Nervenzellen für unsere Begriffe gar nicht so schnell, ihre Wiederholungsrate beträgt etwa 200 Hz, während wir mit PCs arbeiten, die Taktraten von über 1 GHz aufweisen. Es ist die massive, vom Prinzip her gegebene Parallelität in der Signalverarbeitung, welche uns beispielsweise ein Gesicht so blitzschnell erkennen lässt.

Eine weitere technisch interessante Eigenschaft unseres Gehirns ist die Fehlertoleranz. So müssen wir zwar damit rechnen, dass nach einem feucht-fröhlichen Abend ganze Reihen von Nervenzellen im hohen Alkoholpegel absterben. Trotzdem werden wir keine Abnahme unserer Intelligenz feststellen können. Wir verfügen also über ein System, das trotz Ausfall einiger Funktionseinheiten seine Funktionsfähigkeit nicht verliert. Genauso fehlertolerant ist das Gehirn bezüglich der einkommenden Signale. Selbst wenn darin Rauschen oder Unterbrüche vorhanden sind, kann das Gehirn sinnvolle Verarbeitungsergebnisse liefern.

Lernfähigkeit, hohe Verarbeitungsgeschwindigkeit und Fehlertoleranz sind also Eigenschaften, die auch für techni-

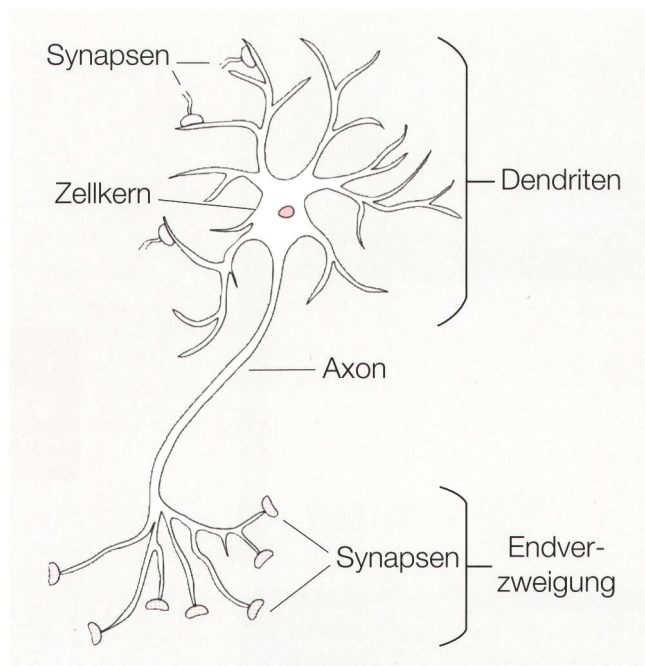


Bild 1 Prinzipalskizze eines natürlichen Neurons.




Bild 2 Funktion eines künstlichen Neurons.

sche Systeme interessant und hilfreich sein könnten. Kein Wunder, dass sich die Ingenieure sehr bald für die Einsichten der Neurologen zu interessieren begannen.

Wesentliche Denkansätze zum Verständnis des menschlichen Gehirns entstanden übrigens zur gleichen Zeit wie die ersten elektronischen Rechenmaschinen. Es waren der Psychiater Warren McCulloch und sein Mitarbeiter Walter Pitts, die in den 1940er-Jahren ein einfaches Modell für die Funktionsweise von Nervenzellen, auch Neuronen genannt, postulierten. [2] Sie wiesen nach, dass mit einer endlichen Anzahl der nach ihnen benannten McCulloch-Pitts-Neuronen alle berechenbaren mathematischen Funktionen berechnet werden können. Mit ihrer Erkenntnis legten sie den Grundstein für eine neuartige Technik, für die Neuroinformatik.

Der Natur abgeguckt

Das Prinzip, das McCulloch und Pitts vorschlugen, ist denkbar einfach und lässt sich aus einer vereinfachten Darstellung eines natürlichen Neurons ableiten. Die in **Bild 1** als Dendriten bezeichneten verzweigten Strukturen im oberen Teil der Zelle bilden die Eingänge des Neurons. Dort sind die Verbindungspunkte zu anderen Neuronen im Netz angebracht. In jeder Verbindungsstelle, auch Synapse genannt, wird bestimmt, wie stark das ankommende Signal in das Neuron eingekoppelt wird. Die synaptische Verbindungsstärke oder das synaptische Gewicht bestimmt auch, ob das Signal positiv, also unterstützend, oder negativ, dementsprechend hemmend, auf das Neuron einwirken soll. Alle synaptischen Gewichte zusammen bestimmen die

Funktionen des Gehirns. So sind also alle Erinnerungen in unserem Gedächtnis und alles, was wir jemals im Leben gelernt haben, nicht in den Gehirnzellen abgespeichert, sondern in den synaptischen Verbindungsstärken. Lernen heisst demnach nichts anderes, als die synaptischen Gewichte richtig einzustellen. In der Nervenzelle selber werden die einkommenden, gewichteten Signale aufsummiert. Erreicht das Summensignal im Innern einen bestimmten Schwellenwert, wird ein Signal über den austretenden Faden, Axon genannt, zu den Endverzweigungen weitergeleitet. Man sagt in dem Falle, das Neuron feuert. Die Endverzweigungen führen dann wieder über synaptische Verbindungen zu weiteren Neuronen.

Künstliche Neuronen

Im **Bild 2** ist dieses Prinzip als künstliches Neuron mit drei Eingängen dargestellt. Jeder Eingang e wird mit dem dazu

gehörenden synaptischen Gewicht w multipliziert (gewichtet) und aus allen Eingängen zusammen die Summe gebildet. Ist der Summenwert s kleiner als der Schwellenwert einer Sprungfunktion, steht am Ausgang o des Neurons der Wert Null. Übersteigt aber der Summenwert die Schwelle der Sprungfunktion, schaltet der Ausgang o auf Eins. Häufig und mit gutem Grund wird anstelle der Sprungfunktion eine stetige Funktion, wie etwa die Tangens-Hyperbolicus-Funktion, verwendet. Neuronen mit stetigen Funktionen können dann beliebige Ausgangswerte, zum Beispiel im Intervall $[-1, +1]$, annehmen. Entscheidend ist, dass die eingesetzte Funktion nichtlinear ist. Genau darin liegt der Trick und die Stärke künstlicher Neuroner Systeme – im Zusammenwirken von Nichtlinearitäten.

Künstliche Neuronale Netze

Verbindet man mehrere der eben beschriebenen künstlichen Neuronen miteinander, entsteht ein künstliches Neuronales Netz. Die Frage ist nun: Wie viele solcher Neuronen sollen zusammengefügt werden und in welcher Art? Glücklicherweise können wir uns auf einige einfache Grundstrukturen beschränken, mit denen fast alle Aufgaben gelöst werden können. Zwei Grundtypen werden unterschieden:

- Netzwerke, bei denen die Signale nur vorwärts durchs System laufen (feed forward).
- Netzwerke mit Rückkopplungen (recurrent), bei denen Ausgangssignale teilweise wieder an vorhergehende Eingänge zurückgeführt werden.

Eine weitere Vereinfachung besteht darin, dass bei den vorwärtsgerichteten Netzwerken die Neuronen in Schichten




Bild 3 Dreischichtiges, vorwärtsgerichtetes, künstliches Neuronales Netz.

angeordnet sind und nur Verbindungen von einer Schicht zur nachfolgenden vorgesehen sind. Zudem lässt sich zeigen, dass bereits drei Schichten mit Neuronen genügen, um alle möglichen Klassierungs- oder Modellierungsaufgaben zu lösen. Bild 3 zeigt ein solches Netzwerk. Es hat sich eingebürgert, dass bei künstlichen Neuronalen Netzen die Neuronen einfach als Kreise dargestellt werden und die Verbindungslinien die synaptischen Gewichte darstellen. Auch die Eingangswerte werden in Kreisen dargestellt, obschon hier keine aktiven Neuronen vorhanden sind. Darum gilt das Netz in Bild 3, das mit den Eingängen zusammen vier Schichten aufweist, nur als dreischichtig.

Die Anzahl Neuronen in der Eingangs- und der Ausgangsschicht ist durch die Aufgabenstellung gegeben. Stehen beispielsweise in einer Anwendung die Signale eines Distanz- und eines Geschwindigkeitssensors zur Verfügung, genügen zwei Eingänge, und um eine daraus bestimmte Bremskraft zu steuern, genügt ein Ausgang. Unbestimmter dagegen ist die Anzahl der Neuronen in den Zwischenschichten 1 und 2 (hidden layers). Ein Verfahren zur Optimierung der Neuronenzahl beginnt mit einer grösseren Anzahl Zwischenneuronen, um danach – in einem sogenannten Pruning-Verfahren – solche Neuronen auszumerzen, die nichts oder nur wenig zur Lösung der Aufgabe beitragen. Es sei bemerkt, dass auch in unseren Menschengehirnen in der Zeit zwischen Geburt und Adoleszenz ein Pruning-Prozess stattfindet.

Künstliche Neuronale Netze im praktischen Einsatz bestehen aus einigen wenigen bis einigen Tausend Neuronen, wobei jedes zusätzliche Neuron unter Umständen die Anzahl Verbindungen, also die Anzahl synaptischer Gewichte, deutlich erhöhen kann.

Viele einfache Prozessoren

Der Berechnungsvorgang im künstlichen Neuronalen Netz ist durch den einfachen Algorithmus in den einzelnen Neuronen bestimmt: also die Multiplikation eines Eingangswertes mit einem Gewichtswert, das Aufsummieren solcher Produkte und die Bestimmung des daraus resultierenden Funktionswertes in einer nichtlinearen Funktion. Zuerst werden die Ausgangswerte für alle Neuronen berechnet, die direkt mit den Eingängen verbunden sind, danach die Ausgänge der Neuronen in der folgenden Schicht, und so weiter. Da Neuronale




Bild 4 Ein Neuronales Netz wird auf den Zusammenhang zwischen den Systembusdaten und der Belastung der Scharniere trainiert.

Netze sehr oft auf konventionellen Computern implementiert werden, wird in diesem Schritt-für-Schritt-Berechnungsprozess ein wertvolles Potenzial der neuronalen Technik verschenkt. Erst wenn jedem Neuron ein eigener Prozessor zugeordnet wird und diese alle gleichzeitig ihre Berechnung durchführen, kann die hohe Reaktionsgeschwindigkeit von Neuronalen Netzen genutzt werden. Zu diesem Zweck sind verschiedene Hardware-Chips auf dem Markt oder in Entwicklung, auf denen einige zehn bis einige tausend Neuronen realisiert sind. Aktuell werden vermehrt Grafikprozessoren eingesetzt, welche grundsätzlich für die parallele, effiziente Berechnung der Summe von Produkten (multiply accumulate), wie sie für Neuronale Netze benötigt werden, optimiert sind.

Lernen

Wie bereits erwähnt, besteht eine Besonderheit Neuronaler Netze in ihrer Lernfähigkeit. Die Aufgabe des Lernprozesses ist es, alle synaptischen Gewichte im Netz so einzustellen, dass das Netzwerk als Ganzes die verlangte Aufgabe erfüllt. In vielen Aufgabenstellungen stehen Muster zur Verfügung, mit denen das Neuronale Netz trainiert werden kann. Ein typisches Beispiel ist die Erkennung von Sprengstoff im Fluggepäck, eine Anwendung, die bereits aus der Frühzeit der neuronalen Technik stammt und die einige Publizität erreicht hat. [3] In dieser Anwendung werden Fluggepäckstücke einer Neutronenstrahlung ausgesetzt und das Spektrum der daraus resultierenden Gammastrahlung gemessen. Die erhaltenen Spektren geben Aufschluss über die Materialien, die im Gepäckstück vorhanden sind. Naturgemäss sind die Spektren der verschiedenen Gepäckstücke sehr unterschiedlich. Enthält ein Gepäck-

stück jedoch Sprengstoff, tritt eine nicht einfach zu erkennende Ausprägung im Spektrum auf. Die Idee ist nun, die Spektren mit Hilfe eines Neuronales Netzes zu interpretieren. Dazu wird für jede der 200 Spektrallinien ein Eingangsneuron festgelegt, darauf folgend zwei Zwischenschichten und ein Ausgangsneuron, das angeben soll, ob Sprengstoff vorhanden ist oder nicht. Wie üblich bei Neuronalen Netzen im Anfangszustand, werden zuerst alle synaptischen Gewichte auf Zufallswerte gesetzt. Das Netz hat also quasi «keine Ahnung» von seiner Aufgabe. Für die nun folgende Trainingsphase stehen eine Menge gemessener Spektren als Lernmuster zur Verfügung, von denen man weiss, ob Sprengstoff darin erscheint oder nicht. Diese Muster werden nun immer wieder in zufälliger Reihenfolge dem Neuronales Netz als Eingangswerte vorgegeben. Die Antwort des Ausgangsneurons – Sprengstoff ja / Sprengstoff nein – ist am Anfang rein zufällig. Stimmt die Aussage zufälligerweise, wird nichts unternommen und das nächste Eingangsmuster angelegt. Stimmt die Antwort nicht, wird jedes synaptische Gewicht im ganzen Netz ein ganz klein wenig verändert, entsprechend seinem Beitrag zum Ausgangswert. Dieser Vorgang wird mit Hilfe der vorhandenen Lernmuster vielleicht mehrere Tausend Mal wiederholt, und zwar möglichst so lange, bis das Neuronale Netz jedes Lernmuster richtig klassiert. Die Strategien, um welchen Wert die Gewichte in jedem Iterationsschritt verändert werden sollen, sind einfach und entsprechen bekannten Optimierungsverfahren, wie zum Beispiel den Gradientenverfahren.

Lernprozesse, bei denen Lernmuster zur Verfügung stehen, von denen man weiss, welche Ausgangswerte das Netz

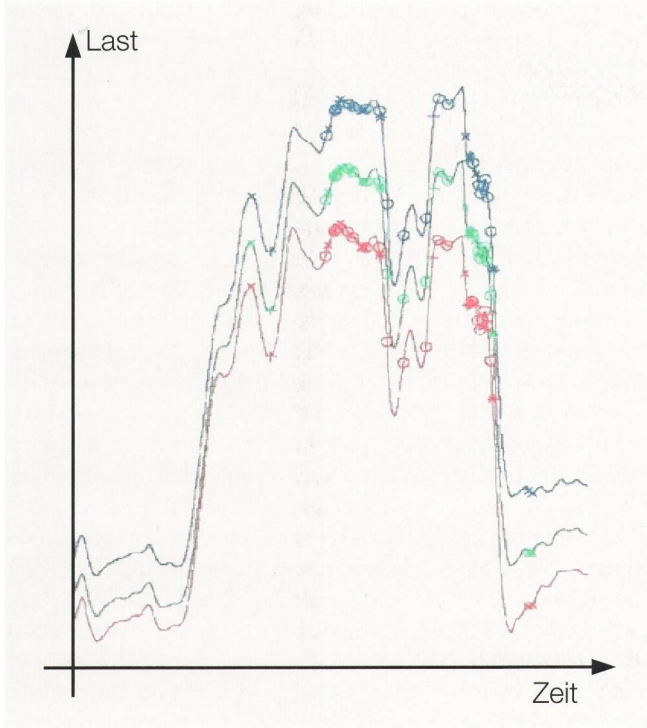


Bild 5 Messung der Scharnierbelastung während eines Flugmanövers und die Ausgangswerte des Neuronalen Netzes (Kreise).

werk liefern muss, werden als überwachte Lernprozesse (supervised learning) oder «Lernen mit Lehrer» bezeichnet. In einem anderen, breiten Anwendungsgebiet Neuronaler Netze steht wohl eine grosse Zahl von Daten zur Verfügung, aber keine dazugehörigen Sollwerte. Die Aufgabe der Neuronalen Netze ist es in diesen Fällen, Strukturen innerhalb der gegebenen Daten festzustellen. Beispiele für solche unüberwachten Lernprozesse (unsupervised learning) sind Bildmustererkennung oder Data Mining.

Neuronale Netze können verallgemeinern


Im Beispiel mit dem erkannten Sprengstoff im Fluggepäck könnte man annehmen, dass das Neuronale Netz im Laufe des Lernprozesses die vielen Lernmuster «auswendig lernt», also einfach zu einem aufgabenspezifischen Gedächtnis wird. Das kann tatsächlich passieren, falls der Lernprozess nicht rechtzeitig abgebrochen wird. Entscheidend für den Nutzen eines Sprengstoffdetektors ist natürlich, dass er im trainierten Zustand nun auch irgendwelche fremden Gepäckstücke mit Sprengstoff sicher erkennt. Das ist auch der Fall, und es ist eine Eigenart trainierter Neuronaler Netze, dass sie nicht nur die Lernmuster richtig einordnen, sondern auch beliebige unbekannte Muster. Neuronale Netze können also verallgemeinern. Das bedeutet, dass das trainierte neuronale Netz die Gesetzmässigkeit erfasst, welche in den Lern-

mustern vorhanden war. Damit können trainierte Neuronale Netze Zusammenhänge aufdecken, die nicht offensichtlich sind. In vielen erfolgreichen Anwendungen wird diese Fähigkeit für Prognose- oder Diagnoseaufgaben genutzt. Anhand früherer Ereignisse, also Lernmuster mit zugehörigem Sollwert, kann ein trainiertes Netz voraussagen, welcher Ausgangswert bei einem zukünftigen Eingangsmuster zu erwarten ist. Anwendungen dieser Art reichen von lokalen Wetterprognosen über Börsenkursvoraussagen oder medizinischen Diagnosen bis zur Qualitätsüberwachung in Produktionsbetrieben.

Modellbildung

Dank der Fähigkeit Neuronaler Netze, anhand eines Lernprozesses den Zusammenhang zwischen Eingangs- und Ausgangswerten eines Systems herzustellen, werden sie oft zur Modellbildung herangezogen. In einem Beispiel aus der Aviatik war es wichtig, die Belastung der Scharniere von Flügelklappen zu bestimmen, um bei zu hoher Dauerbelastung rechtzeitig die nötigen Unterhaltmassnahmen zu treffen. Durch Anbringen von Dehnmessstreifen an den belasteten Teilen der Scharniere kann diese Belastung während dem Flugbetrieb gemessen und aufgezeichnet werden. Diese Messeinrichtung am Flugzeug anzubringen, ist aufwendig, nicht dauerhaft und im Konzept des Flugzeuges nicht vorgesehen. Eigentlich aber hätte man eine ganze Reihe von Messwerten, wie Geschwindigkeiten, Bewegungen, Ruderstellungen usw. grundsätzlich immer an Bord auf dem Systembus zur Verfügung. Hätte man ein genaues Modell, das den Zusammenhang zwischen den Systembuswerten und den Belastungen der Scharniere beschreiben würde, könnte man auf die direkte Messung an den Scharnieren verzichten.

Ein solches Modell konnte erfolgreich mit einem Neuronalem Netz realisiert werden (Bild 4). Dazu wurde ein einziges Flugzeug mit Dehnmessstreifen an den Scharnieren ausgerüstet. In verschiedenen Flugmanövern wurden dann diese Messdaten gleichzeitig mit den Daten des Systembusses aufgezeichnet. Mit den so gewonnenen Datensätzen konnte ein Neuronales Netz trainiert werden, das heisst, dass die Gewichte im Netz so



Bilder: Rolf Leuenberger

Bild 6 Bewegungsentstehung und -steuerung bei einer 6-beinigen Gehmaschine mit Hilfe Neuronaler Netze.

lange angepasst wurden, bis es an seinem Ausgang in jedem Fall die gleichen Werte lieferte wie die Messeinrichtung an den Scharnieren. Somit stellt das Netzwerk ein Modell dar, das den Zusammenhang zwischen den Flugdaten des Systembusses und der effektiven Belastung an den Klappenscharnieren nachbildet. Von da an war es möglich, die Belastung der Scharniere – bei allen Flugzeugen des gleichen Typs – ohne zusätzliche Messeinrichtung aus den vorhandenen Systembus-Daten zu bestimmen.

Bild 5 zeigt einen Ausschnitt aus den kontinuierlich aufgezeichneten Messwerten an drei Scharnierstellen während eines kurzen Flugmanövers. Die eingezeichneten Kreise entsprechen den Werten, die das trainierte Neuronale Netz anhand der Systembuswerte bestimmte. Die Übereinstimmung ist sehr gut und für die Lastbestimmung durchaus genügend.

Neuronale Netze in der Robotik

Ein Bereich, in dem Neuronale Netze eine zunehmende Bedeutung erlangen, ist die Robotik, insbesondere die Erzeugung und Steuerung von Bewegungen. Gemeint sind nicht die Bahnsteuerungen bei Robotern, die Präzisionsarbeiten in der industriellen Produktion oder im Operationssaal ausführen, sondern die Bewegungen von mobilen, geländegängigen oder humanoiden Robotern. Aus der Natur haben wir gelernt, dass Bewegungen nicht vollständig von einem Nervenzentrum aus gesteuert werden, sondern vielmehr lokal im Zusammenwirken von Körper, Umwelt und Nervenzellen entstehen. [4] Dieses Konzept wird zum Beispiel in einer sechsbeinigen Gehmaschine gemäss **Bild 6** angewendet. Jedem Bein des Gehroboters ist ein sehr kleines Neuronales Netz zugeordnet. Die Eingänge dieses Netzes erhalten als Signale die aktuellen Winkel von Hüft- und Kniegelenken sowie die Information über den Bodenkontakt des Fusses. Die Ausgänge des Netzes steuern die Aktoren an, welche die Bewegung der Beine verursachen. In diesem Falle handelt es sich um ein rückgekoppeltes Neuronales Netz, da die Ausgänge der Neuronen über synaptische Gewichte wieder zu den eigenen Eingängen zurückgeführt werden. Zusätzlich sind alle Neuronen untereinander vernetzt. Ein wichtiger Rückkopplungspfad entsteht aber über die Kraftwirkung der neuronal angesteuerten Aktoren, welche in Wechselwirkung mit dem Boden den Körper des Roboters in

Bewegung bringen. Als Folge dieser Bewegung werden die Winkel der Beine gelenke verstellt, und mit den Winkelsignalen wird der Kreis über das Neuronale Netz geschlossen. Damit entsteht ein nichtlineares, rückgekoppeltes System, das neben stabilen Zuständen auch sogenannte Grenzyklen aufweisen kann, die sich als andauernd wiederholte Bewegungsabläufe manifestieren. Im Idealfall sind die Bewegungsabläufe so, dass der Roboter dem Gelände angepasst vorwärtsschreitet. Eine sinnvolle Bewegung kann durch die richtige Einstellung der synaptischen Gewichte im Neuronalen Netz erreicht werden. Um die Bewegung aller Beine untereinander zu koordinieren, werden auch die Netze der Beine miteinander über synaptische Gewichte verbunden.

Eine Lernmethode aus der Natur

Auch in dieser Anwendung möchten wir die Neuronalen Netze mittels Training auf ihre Aufgabe konditionieren. Das Problem ist, dass uns dazu keine Lernmuster zur Verfügung stehen. Hilfe bietet uns die Natur mit ihrem enorm starken Lernverfahren, der Evolution. Wie üblich werden am Anfang sämtliche synaptischen Gewichte auf zufällige Werte gesetzt. Das verursacht kaum eine sinnvolle Bewegung der Beine, sondern höchstens eine kleine Kniebiegung oder ein Zittern des Körpers. Nun befasst sich aber die Evolution nicht mit dem einzel-

nen Individuum, sondern mit ganzen Populationen von mehreren Lebewesen. Also kreieren wir auch in der technischen Simulation eine Menge von gleichartigen Robotern. Unterschieden sind sie einzig durch die zufälligen Anfangsgewichte in ihren Neuronalen Netzen. Jedem dieser Roboter gestatten wir, «Kinder zu bekommen», die grundsätzlich Kopien ihrer Eltern sind, aber eben nicht ganz. Bei der Reproduktion entstehen kleine Veränderungen, sogenannte Mutationen. Die synaptischen Gewichte der Kinder unterscheiden sich also ganz wenig, aber rein zufällig, von denen ihrer Eltern, was zur Folge hat, dass auch das Bewegungsverhalten der Kinder anders ist als das der Eltern. Hier setzt das Evolutionsprinzip an, das heisst: «survival of the fittest», also «Überleben des am besten Angepassten». Aus der ganzen Kinderschar der Roboter werden diejenigen ausgelesen, welche am besten die Aufgabe erfüllen, die wir von ihnen verlangen. In unserem Falle sind das diejenigen, die ein bisschen vorwärtskommen mit ihren Bewegungen und dabei möglichst wenig Energie verbrauchen. Diesen Auserlesenen gestatten wir, sich wieder, wie ihre Eltern, zu reproduzieren. Alle anderen sterben aus. Der Prozess der Reproduktion, mit zufälligen Mutationen und Selektion der am besten Geeigneten, wird so oft wiederholt, bis nach und nach Individuen auftreten, welche eine sehr natürlich wirkende Gangart aufweisen und zügig vorwärtskommen.

Résumé

Les réseaux de neurones artificiels

Des idées inspirées par la nature pour résoudre des problèmes techniques

La question consistant à savoir comment l'interaction entre des cellules nerveuses dans le cerveau humain peut produire des performances cognitives est loin d'être résolue. Mais il est intéressant de constater que déjà l'utilisation des plus simples principes issus de l'exemple de la biologie permet d'en déduire des solutions techniques. Ainsi, les réseaux de neurones artificiels ont trouvé ces dernières années des applications dans de nombreux domaines où les méthodes traditionnelles ont souvent eu moins de succès. La technologie neuronale permet souvent de résoudre efficacement des tâches telles que la reconnaissance de formes, les pronostics, les diagnostics, ainsi que le contrôle de mouvements dans la robotique. Mais en dépit des nombreuses applications réussies de réseaux neuronaux, il convient de garder à l'esprit les limites de cette technologie. Un point de critique majeur est le comportement de boîte noire. Bien qu'un réseau neuronal soit capable d'apprendre par le biais de l'entraînement les lois d'un système, nous ne recevons jamais une description explicite de ces lois. Tout le savoir est réparti dans le réseau sous forme de poids synaptiques et n'est pas interprétable.

Il est vivement conseillé de ne pas utiliser des réseaux neuronaux sans motif, mais de rechercher des solutions techniques dans la mesure du possible sur la base de méthodes basées sur des règles où le rapport entre l'entrée et la sortie peut être formulé en termes clairs et compréhensibles. Toutefois, si ce rapport n'est pas connu, complexe ou hautement non linéaire, des réseaux de neurones apprenant leur tâche au moyen d'un entraînement peuvent en effet constituer une alternative précieuse ou simplement rendre le problème enfin résoluble. No

Neuere Studien mit humanoiden Robotern zeigen, dass die Interaktion der Roboter mit der Umwelt deutlich verbessert werden kann, wenn im Roboter selber zusätzlich ein Modell über seine Wechselbeziehung zur Umwelt vorhanden ist. [5] Solche Modelle werden ebenfalls als lernfähige Neuronale Netze realisiert.

Denn sie wissen nicht, was sie tun ...

Trotz vieler erfolgreicher Anwendungen von Neuronalen Netzen müssen klar auch die Grenzen dieser Technik im Auge behalten werden. Ein wichtiger Kritikpunkt ist das Black-Box-Verhalten. Obschon ein Neuronales Netz die Gesetzmässigkeiten eines Systems durch Training erlernen kann, erhalten wir nie eine explizite Beschreibung dieser Gesetzmässigkeiten. Das ganze Wissen ist in Form von synaptischen Gewichten im Netz verteilt und nicht interpretierbar. Das Neuronale Netz bleibt eine Black-Box. Besonders nachteilig ist in diesem Zusammenhang die Eigenschaft, dass wir keine gesicherten Aussagen über das Verhalten des Netzes machen können. Tritt beispielsweise einmal ein Eingangsmuster auf, das völlig anders ist, als es die Lernmuster je waren, kann auch die Antwort des Neuronalen Netzes vollständig unerwartet sein. Damit ist auch ein zweiter Kritikpunkt angesprochen: nämlich, dass Neuronale Netze «die Gefangenen ihrer Lernmuster» seien. Tatsächlich ist ein Neuronales Netz nur so gut wie seine Lernmuster waren, bei denen man voraussetzt, dass sie den Bereich aller Möglichkeiten möglichst umfassend abdecken.

Es ist durchaus ratsam, nicht grundlos Neuronale Netze einzusetzen, sondern technische Problemlösungen möglichst auf der Basis von regelbasierten

Methoden anzustreben, bei denen der Zusammenhang zwischen Ein- und Ausgang klar und verständlich formuliert werden kann. Viele Aufgaben der Regeltechnik gehören zum Beispiel in diesen Bereich. Ist dieser Zusammenhang jedoch nicht bekannt, komplex oder höchst nichtlinear, können Neuronale Netze, die ihre Aufgabe in einem Training erlernen, sehr wohl eine wertvolle Alternative darstellen oder das Problem überhaupt erst lösbar machen.

Youtube-Links

- Rolf Leuenberger, A robot learning to walk: <http://youtu.be/s12Bln4UXjc>
- Georg Martius, Playful Machines – self-learning robots: <http://www.youtube.com/watch?v=tliKMaMo-t0>

ITG-Statement



Prof. Dr. **Klaus Zahn**,
Leiter Forschungsgruppe Computer Vision, HSLU, 6048 Horw

Eine bewegte Geschichte

Künstliche Neuronale Netze (NN) blicken auf eine bewegte Geschichte zurück. Die Entwicklung des sogenannten Perzeptrons – ein elementares NN mit nur einer Lage von Neuronen – durch Frank Rosenblatt am Ende der 1950er-Jahre stellt sicherlich einen Meilenstein in der KI (künstlichen Intelligenz) dar. Damit konnten auf Basis eines 20x20 Pixel grossen Bildsensors schon einfache OCR-Aufgaben (Optical Character Recognition) gelöst werden. Allerdings führte am Ende der 1960er-Jahre die Erkenntnis, dass selbst einfache Klassifikationsprobleme wie das XOR-Problem nicht mit dem Perzeptron gelöst werden konnten, zu einem schlagartigen Ende des ersten Hypes. Im Verlaufe der 1970er-Jahre konnte dann aber mathematisch gezeigt werden, dass durch die Erweiterung des Perzeptrons zu mehrlagigen NN beliebige Klassifikationsprobleme (u.a. auch das XOR-Problem) gelöst werden können. Und so kam es in den 1980er- und 1990er-Jahren erneut zu einem Boom der NN. Vor allem der Lernvorgang der NN durch den sogenannten Backpropagation-Algorithmus wurde intensiv untersucht. Aufgrund verschiedener Kritikpunkte wurden dann aber am Ende der 1990er- und im Verlaufe der 2000er-Jahre die NN im Bereich der KI durch alternative Klassifikatoren (z.B. Support-Vektor-Maschinen) ersetzt. Jüngst konnten NN mit Rückkopplungen in verschiedenen Kategorien wie z.B. OCR oder der Erkennung von Verkehrsschildern ihre Überlegenheit gegenüber allen anderen Methoden unter Beweis stellen und teilweise Fehlerraten vergleichbar mit menschlichen Leistungen erreichen. Eine aktuell sehr interessante Entwicklung in diesem Bereich stellt – trotz der zunehmenden Kritik – auch das von der EU geförderte «Human Brain Project» dar, in welchem die Modellierung des menschlichen Gehirns als künstliches NN einen Teilaspekt darstellt.

Referenzen

- [1] Der Spiegel, 28/1950, Maschinengehirn.
- [2] Warren S. McCulloch, Embodiments of mind, M.I.T. Press, 1965.
- [3] P.M. Shea, Detection of explosives in checked airline baggage using an artificial neural system, International Joint Conference on Neural Networks, 1989.
- [4] Arndt von Twickel, Frank Pasemann, Reflex-oscillations in evolved single leg neurocontrollers for walking machines, Springer, 2007.
- [5] Ralf Der, Georg Martius, The playful machine, Springer, 2011.

Autor

Dr. **Rolf Leuenberger** studierte Elektrotechnik an der ETH und arbeitete danach als Entwicklungsingenieur und Entwicklungsleiter für Sensorik, Signal- und Bildverarbeitung in der Industrie, später als selbstständiger Berater in verschiedenen Industrieprojekten mit Schwerpunkt «Anwendung Neuronaler Netze». Gleichzeitig war er bis zur Pensionierung 2012 als Lehrbeauftragter an den Fachhochschulen Winterthur und Rapperswil tätig. rolf-leuenberger@sunrise.ch

Anzeige

Kennen Sie www.bulletin-online.ch schon?

Die Beiträge dieser Ausgabe finden Sie auch auf Bulletin-Online. Dort können Sie die Artikel bewerten und Ihren Kommentar abgeben. Damit aus einer Einweg-Kommunikation ein spannender Dialog wird.

Das elektronische Bulletin lädt Sie ein zum Schnuppern, zum «Durchwühlen» des Archivs und zum Lesen der aktuellsten Kurzbeiträge. Wir freuen uns auf Ihren Besuch!

www.bulletin-online.ch

Bulletin
Fachzeitschrift von ElectroSuisse und VSE
revue spécialisée d'électronique et de SES