

Zeitschrift: Bulletin des Schweizerischen Elektrotechnischen Vereins, des Verbandes Schweizerischer Elektrizitätsunternehmen = Bulletin de l'Association suisse des électriciens, de l'Association des entreprises électriques suisses

Herausgeber: Schweizerischer Elektrotechnischer Verein ; Verband Schweizerischer Elektrizitätsunternehmen

Band: 82 (1991)

Heft: 13

Artikel: Lernen als Regelmechanismus : Neuronale-Netzwerk-Projekte an der Universität Bern

Autor: Schmid, Philipp / Stiefenhofer, Jürg

DOI: <https://doi.org/10.5169/seals-902980>

Nutzungsbedingungen

Die ETH-Bibliothek ist die Anbieterin der digitalisierten Zeitschriften. 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. [Siehe Rechtliche Hinweise.](#)

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. [Voir Informations légales.](#)

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. [See Legal notice.](#)

Download PDF: 29.03.2025

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

Lernen als Regelmechanismus

Neuronale-Netzwerk-Projekte an der Universität Bern

Philipp Schmid, Jürg Stiefenhofer

Die bisherigen Arbeiten am Institut für Informatik und angewandte Mathematik der Universität Bern befassen sich mit den Grundlagen der Lernalgorithmen für neuronale Netze. Schwergewichtig wurden dabei die Verminderung der Abhängigkeit der Musterreihenfolge beim Lernen mit Hilfe des Backpropagation-Lernverfahrens sowie eine Einbettung desselben in die Regeltechnik untersucht.

Les travaux accomplis jusqu'à présent à l'institut de l'informatique et de mathématiques appliquées de l'université de Berne, se concentrent sur les techniques d'apprentissage des réseaux de neurones artificiels. Les recherches se poursuivent principalement en essayant de diminuer l'interdépendence de la séquence des prototypes au cours de la phase d'entraînement à l'aide de la rétro-propagation du gradient ainsi qu'en reliant ce processus à des systèmes asservis.

Adresse der Autoren

Philipp Schmid, lic.phil.nat. und Jürg Stiefenhofer,
Institut für Informatik und angewandte Mathematik,
Länggassstrasse 51, 3012 Bern

Viele Probleme der künstlichen Intelligenz, wie zum Beispiel die Spracherkennung oder das automatische Lesen handgeschriebener Texte, harren trotz intensiver Anstrengungen einer Lösung. Verschiedene Arbeiten, welche in den letzten Jahren veröffentlicht wurden, zeigen auf, dass neuronale Netze der Schlüssel zu vielen der ungelösten Probleme, vor allem auf dem Teilgebiet der Cognitive Science, sein könnten. Die bisherigen Arbeiten auf dem Gebiet der neuronalen Netze, welche an der Universität Bern im Rahmen von Lizentiatsarbeiten erstellt wurden, waren hauptsächlich der Analyse der Lernalgorithmen gewidmet.

Beim Lehren von Mustern mit Hilfe des Backpropagation-Lernalgorithmus stellt man fest, dass der Lernerfolg und die Lernzeit des Netzes stark von der Reihenfolge, in welcher ihm die zu lernenden Muster angeboten werden, abhängig ist; das zuerst gezeigte Muster wird in der Regel schneller gelernt als die restlichen Lernmuster. («Der erste Eindruck prägt das weitere Geschehen.») Es stellt sich deshalb die Frage, mit welchen Massnahmen dieser Reihenfolgeabhängigkeit begegnet werden kann.

Eine erste Möglichkeit ist das Verwenden der sogenannten Batch-Lernvariante, oft auch Epochen-Lernen genannt. Dabei werden die zu bestimmenden Gewichte erst nach einem vollständigen Präsentieren aller Muster angepasst. In der Praxis zeigt sich jedoch, dass dieses Verfahren den Nachteil langer Lernzeiten mit sich bringt.

Die Abhängigkeit von der Reihenfolge der Musterpräsentation kann auch durch die Wahl einer kleinen Lernrate vermindert werden. Dadurch fallen die einzelnen Gewichts-

veränderungen $\Delta\omega$ betragsmässig nur klein aus, das heisst der Einfluss eines einzelnen Lernmusters auf die Gewichtsveränderungen ist klein. Die Verkleinerung der Lernrate¹ η bewirkt jedoch oftmals eine beträchtliche Erhöhung der Lernzeit.

In zwei Lizentiatsarbeiten wurden verschiedenartige Ansätze zur Reduktion der Reihenfolgeabhängigkeit untersucht. Die Grundidee in [1] ist das Aufteilen des Lernprozesses in zwei Phasen: In der ersten Phase werden dem neuronalen Netz die gemeinsamen Mustercharakteristika der zu lernenden Muster eingepreßt, die zweite Phase dient schliesslich der Ausdifferenzierung der einzelnen Mustermerkmale. Leider konnten mit den gewählten Methoden bisher keine signifikanten Verbesserungen im Lernverhalten festgestellt werden. Eine andere Richtung wird in der Lizentiatsarbeit von Jürg Stiefenhofer eingeschlagen. Auf sie soll im folgenden näher eingegangen werden.

Idee: Neuronale Netze als Regelkreise

Nach der Wiederentdeckung der neuronalen Netze Anfang der 80er Jahre, wurden diese nicht nur in der Mustererkennung, sondern auch im Steuerungs- und Regelungsbereich näher untersucht und angewandt. Neuronale Netze haben in der Regelungstechnik den Vorteil, dass sie auch in Situationen, mit denen sie während der Trainingsphase nie konfrontiert wurden, «vernünftige» Entscheidungen treffen können. Dadurch sind sie für alle Regelungsprobleme, für die beim Entwurf des Systems

¹ Die Lernrate η legt die Stärke der Gewichtskorrektur zur Berechnung der neuen Gewichte fest.

nicht alle möglichen Ereignisse bekannt oder modellierbar sind, geeignet. Das bedeutet, dass nach den Begriffen der Regeltheorie, mit neuronalen Netzen nicht nur eine adaptive Regelung, sondern ein lernendes oder sogar denkendes System realisierbar wird. Beispiele dazu finden sich in zahlreichen Publikationen zum Thema Robotik und Kontrolltechnik.

Völlig neu ist hingegen eine ganz andere Betrachtungsweise von neuronalen Netzen und Regelkreisen. Durch ein geschicktes Umformen der Grundgleichungen gewöhnlicher Backpropagation-Netze, lassen sie sich in einen neuen Satz von Grundgleichungen, welche ohne weitere Veränderung als Regelkreisgleichungen interpretiert werden können, überführen. Das dynamische Verhalten eines einzelnen Neurons in einem neuronalen Netz kann dadurch formal exakt mit den Mitteln der Regeltechnik beschrieben werden. Es muss betont werden, dass lediglich das dynamische Verhalten eines Neurons beschrieben wird, nicht ein komplettes Neuron an sich.

Umformung der Grundgleichung

Das Hauptproblem beim Umformen der Backpropagation-Grundgleichung ist das Finden einer geeigneten Variablen, welche als dynamischer Parameter, eigentlich als Variable über der Zeit, dienen könnte. Dieser ganze Schritt geht aus vom Backpropagation-Algorithmus, welcher bei numerischen Anwendungen äusserst einfach ist und nichts anderes als ein diskretes Modell für einen kontinuierlichen Lernvorgang darstellt. Das Ziel ist, in den zeitkontinuierlichen Raum zu gelangen, damit die für analytische Betrachtungen gut entwickelte Regeltheorie angewendet werden kann. Es soll betont werden, dass die Interpretation als Regelkreisgleichungen analytisch sehr günstig, aber der Aufwand bei der numerischen Simulation von grösseren Beispielen enorm ist.

Grundidee: Lernrate η als dynamischer Parameter verwenden. Dieser Ansatz liegt bei näherer Betrachtung eigentlich auf der Hand, da die Lernrate im wesentlichen die Lerngeschwindigkeit und damit die Lerndauer bestimmt, also eigentlich inhärent bereits einen dynamischen Parameter darstellt. Der folgende Teil befasst sich mit dem notwendigen Umformen

Bild 1
Einfacher Regelkreis


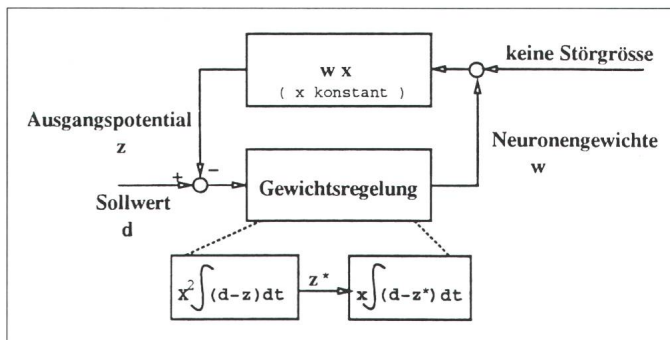


Bild 2
Neuron als einfacher Regelkreis



der Backpropagation-Grundgleichungen in zeitkontinuierliche Gleichungen.

Es sei

$$S := \sum_{i=0}^n x_i w_i \quad (1)$$

die Definition des statischen Eingangspotentials, wobei x_i das Potential auf einem Eingang i und w_i die entsprechende Gewichtung bezeichnet, und entsprechend

$$S(\eta) := \sum_{i=0}^n x_i w_i(\eta) \quad (2)$$

die Definition des dynamischen Eingangspotentials eines Neurons. Die Korrektur des Gewichtes w_i erfolgt nach der bekannten Strategie der Delta-Regel²

$$\Delta w_i := \underbrace{\eta x_i \frac{d\omega}{dS}(d - \omega(S))}_{\text{Delta-Regel}} \quad (3)$$

wobei d der Sollwert für das entsprechende Muster und $\omega(S)$ das Ausgangspotential des Neurons darstellt.³

Das Gewicht $w_i(\eta)$ des Eingangs i zu einem Zeitpunkt η_x erhält man durch Umformung von (3)

² Die meistverwendete Lernregel für mehrschichtige Netze, die Delta-Regel, wurde in den 80er Jahren von Prof. Rumelhart [3] eingeführt.

³ $\omega(S)$ ist die sogenannte Aktivierungsfunktion, normalerweise wird die logistische Funktion

$\omega(x) = \frac{1}{1+e^{-x}}$ oder $\omega(x) = \text{Tanh}(x)$ verwendet.

$$\frac{dw_i}{d\eta} = x_i \frac{d\omega}{dS}(d - \omega(S)) \quad (4)$$

und (2)

$$\frac{dS}{d\eta} = \sum_{i=0}^n x_i \frac{dw_i}{d\eta} \quad (5)$$

und deren Kombination

$$\begin{aligned} \frac{dS}{d\eta} &= \sum_{i=0}^n [x_i^2 \frac{d\omega}{dS}(d - \omega(S))] \\ &= \frac{d\omega}{dS}(d - \omega(S)) \sum_{i=0}^n x_i^2 \end{aligned} \quad (6)$$

mit

$$\sum_{i=0}^n x_i^2 = X^2$$

aus der Differentialgleichung

$$\frac{dS}{d\eta} = X^2 \frac{d\omega}{dS}(d - \omega(S)) \quad (7)$$

Für den einfachen, linearen Fall $\omega(S) = S$, $d\omega/dS = 1$ gilt:

$$\begin{aligned} w_i(\eta) &= x_i \int [d - X^2 \int (d - \\ &\quad \sum_{i=0}^n x_i w_i(\eta)) d\eta] d\eta, \end{aligned} \quad (8)$$

wobei

$$\begin{aligned} S(\eta) &= S(0) + (d - S(0)) \\ &\quad \cdot (1 - e^{-X^2 \eta}) \end{aligned} \quad (9)$$

$$w_i(\eta) = w_i(0) + \frac{x_i}{X^2}(S(\eta) - S(0)) \quad i = 0 \dots n; \quad (10)$$

Allgemein gilt dann:

$$w_i(\eta) = x_i \int [\omega(F) \cdot (d - \omega(F))] d\eta \quad (11)$$

mit

$$F = X^2 \int [\omega(\sum_{i=0}^n x_i w_i(\eta)) \cdot (d - \omega(\sum_{i=0}^n x_i w_i(\eta)))] d\eta, \quad (12)$$

wobei $\omega(x) = \frac{d}{dx}\omega(x)$ die Ableitung der Aktivierungsfunktion an der Stelle x sowie $S(0)$, $w_i(0)$ die Initialbedingungen des Potentials bzw. der Gewichte zum Zeitpunkt $\eta = 0$ sind.

Schematische Gegenüberstellung

Das Grundschaema eines einfachen Regelkreises, so wie es in den meisten Lehrbüchern steht, ist in Bild 1 dargestellt. Grundsätzlich kann Gl. 8 als I-Regelkreis interpretiert werden, für das einfachste Modell eines linearen Neurons, das heisst eines Neurons ohne Schwellwert-Bildung, mit nur einem Eingang, reduziert sich das Problem auf einen I-Regelkreis. Die zugrundeliegende Gleichung ist Gl. 8, wobei jedoch nur das eine Integral verwendet wird. Die Störgrösse kann sogar ganz weggelassen werden (Bild 2).

Ein erstes Problem taucht auf, sobald mehrere Gewichte und Eingänge pro Neuron behandelt werden müssen. In Bild 3 ist ein Modell eines

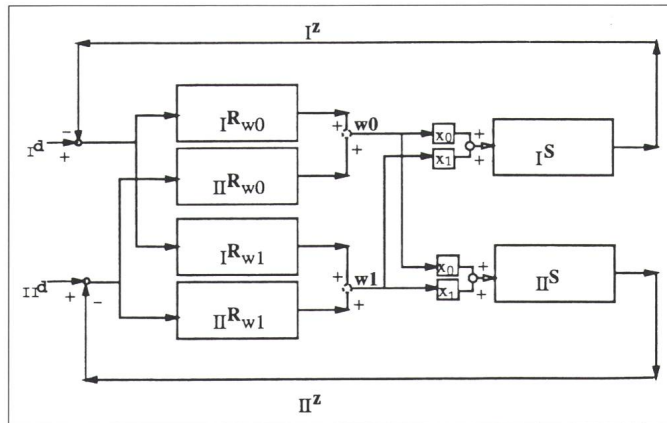


Bild 4
2 Eingänge,
2 Muster




Bild 5
Aufgeschnittener
Regelkreis

Neurons mit 2 Eingängen skizziert. Eine interessante, jedoch auch komplizierte Erweiterung ergibt sich durch die gleichzeitige Verwendung mehrerer Muster. Auf diese Erweiterung kann nicht verzichtet werden, wenn man von Neuronen durch Regelsysteme modellieren will (Bild 4). Zur mathematischen Behandlung eines solchen Systems, insbesondere bei Stabilitätsbetrachtungen, muss der Regelkreis aufgeschnitten werden. Am Eingang des aufgetrennten Regelkreises wird das Signal x_e angelegt, am Ausgang das Signal x_a gemessen. Das Schema des aufgeschnittenen Regelkreises ist in Bild 5 zu finden. Der weitere Verlauf der hier vorgestellten Arbeit wird zeigen, wie stark das Modell von Bild 5 verallgemeinert werden kann. Eine weitere wichtige Frage ist, inwiefern auch die Gleichung 11

als Regelkreisgleichung behandelt werden kann.

Neben den oben beschriebenen Arbeiten des Instituts, welche unter anderem dem Zweck dienen, ein besseres Verständnis für die fundamentalen Eigenschaften der Lernalgorithmen zu erwerben, wurde in einer anderen Arbeit [2] gezeigt, wie mit Hilfe eines neuronalen Netzes die (nahezu) optimale Platzierung von parallelen, miteinander kommunizierenden Prozessen auf einer Multiprozessor-Rechenarchitektur gefunden werden kann. Für die Zukunft ist beabsichtigt, vermehrt Problemstellungen der angewandten Forschung zu bearbeiten, um den verschiedenen Interessen der Studenten und Assistenten entgegenzukommen. In diesem Zusammenhang wird die Zusammenarbeit mit der Industrie gesucht, um praxisbezogene Projekte im Rahmen von Studentenprojekten oder Lizentiatsarbeiten (allenfalls auch Dissertationen) durchführen zu können.




Bild 3
Neuron mit
2 Eingängen

Literaturverzeichnis


- [1] Philipp Schmid: Ein zweistufiges Lernverfahren für mehrschichtige neuronale Netze. Lizentiatsarbeit, 1990. Institut für Informatik und angewandte Mathematik, Universität Bern.
- [2] Philipp Schmid: The Mapping Problem: a Neural Network Approach. In Proceedings of INN. 1990.
- [3] Rumelhart, Hinton, Williams: Learning Representations by Back-Propagating Errors. Nature, 1986.

varintens® Lichtsteuerungen


Die Kombination von varintens-Lichtsteuerungen mit dem varintens-Intensiv-Pulser-System (VIP 90) ermöglicht ein Steuerverhältnis bei 26 mm-Leuchtstofflampen (18-36-58 W) von bis zu 1 : 10 000 mit Sofortstart in jeder Dim-Position.



Weil anspruchsvolle Steuerungen von Plenarsälen, Konferenzräumen und Aulen ein Steuerverhältnis von mindestens 1 : 1 000 erfordern, ist und bleibt das varintens-VIP-90-System die optimale Lösung bei höchster Betriebssicherheit.



Das Beispiel aus der Praxis: Licht-Helligkeitssteuerung varintens für das Auditorium im Forschungszentrum Nestlé in Vevey.



Verlangen Sie unsere Dokumentation.


Praxiserprobte Konzepte und Anlagen für professionelle Anwender

starkstrom-elektronik ag



Güterstrasse 11
CH-8957 Spreitenbach
Telefon: 056 / 70 13 75
Telex: 826 333 sew ch
Telefax: 056 / 71 49 86

Schweizerischer Elektrotechnischer Verein
Association Suisse des Electriciens
Associazione Svizzera degli Elettrotecnici
Swiss Electrotechnical Association



⊕ SICHER MIT ⊕ SICHERHEITSZEICHEN

Gewähr für grösstmögliche Sicherheit bieten elektrische Erzeugnisse, die das Sicherheitszeichen tragen. Es bedeutet, dass sie vom SEV geprüft und vom Eidg. Starkstrominspektorat zugelassen sind.

Dieses Material entspricht den Regeln der Technik. Deshalb lassen Hersteller und Importeure ihr Material beim SEV prüfen, und deshalb achten Konsumenten beim Kauf von elektrischen Erzeugnissen auf das Sicherheitszeichen.

Auskunft:

Schweizerischer Elektrotechnischer Verein, Seefeldstrasse 301, Postfach, 8034 Zürich
Telefon 01 / 384 91 11 – Telex 817431 – Telefax 01 / 55 14 26