

Woche 10 Theorie: Einführung in neuronale Netze

Skript

Erarbeitet von

Ludmila Himmelpach, Katja Theune

Lernziele	1
Inhalt	1
Einstieg	1
Biologische neuronale Netze	2
Künstliche neuronale Netze - Aufbau	2
Künstliche neuronale Netze - Beispiel	3
Abschluss	5
Quellen	5
Weiterführendes Material	6
Disclaimer	7

Lernziele

- Vorteile künstlicher neuronaler Netze im Gegensatz zu klassischen Machine Learning Verfahren nennen können.
- Erläutern, wie ein künstliches neuronales Netz aufgebaut ist.
- Die Spezialfälle “feed-forward Netz” und “fully-connected layer” erläutern.
- Anhand eines Beispiels Inputs und Output eines neuronalen Netzes erläutern.

Inhalt

Einstieg


Die klassischen Machine Learning Verfahren, wie z. B. Entscheidungsbäume, lernen selbstständig Regeln aus den Trainingsdaten, mit deren Hilfe sich neue Beobachtungen z. B. klassifizieren lassen. Diese Methoden haben jedoch auch ihre Schwächen. Sie arbeiten zwar

zuverlässig auf strukturierten Daten wie Kund*innen- oder Patient*inneninformationen, können aber keine unstrukturierten Daten, wie z. B. Bilder, Texte oder Videos ohne weiteres verarbeiten. Und auch bei sehr komplexen Zusammenhängen in den Daten leidet häufig ihre Prognosegüte. Da kommen sogenannte künstliche neuronale Netze ins Spiel. Sie sind sehr flexibel, können auch unstrukturierte Daten verarbeiten und komplexe Zusammenhänge erkennen.

Biologische neuronale Netze

Das erste der heute so bekannten künstlichen neuronalen Netze wurde bereits 1943 vom Neurophysiologen Warren MacCulloch und vom Mathematiker Walter Pitts entworfen. Hier dienten biologische neuronale Netze bei der Entwicklung von künstlichen neuronalen Netzen zwar als Vorbild, die beiden haben aber nur wenige Gemeinsamkeiten. Aber sowohl die biologischen als auch die künstlichen neuronalen Netze bestehen aus Neuronen, die sich durch die Verbindungen bzw. Kommunikation untereinander zu einem Netzwerk organisieren und so Informationen weiterleiten.

Quelle [1,2]




Quelle [3,4]

Diese Abbildung hier zeigt einen Ausschnitt aus der Darstellung eines biologischen neuronalen Netzes, in dem Neuronen in aufeinanderfolgenden Schichten angeordnet sind. Die Kommunikation zwischen einzelnen Neuronen findet über kurze elektrische Impulse statt, die ein Neuron über seine Dendriten von anderen Neuronen empfängt und über sein Axon an weitere Neuronen sendet. In der Großhirnrinde eines Menschen, die für höhere kognitive Leistungen verantwortlich ist, befinden sich ca. 20 Milliarden Neuronen. Dabei ist jedes Neuron mit Tausenden anderen Neuronen verbunden, was schätzungsweise 100 Billionen Verbindungen insgesamt ausmacht.

Künstliche neuronale Netze - Aufbau

Hier sehen wir nun beispielhaft einen Aufbau eines künstlichen neuronalen Netzes mit mehreren Schichten bzw. Layern, die wiederum aus Neuronen bestehen, die wie im

menschlichen Gehirn Informationen verarbeiten. Bei diesem Modell handelt es sich um ein sequenzielles feed-forward Netzwerk, d. h. Neuronen einer bestimmten Schicht erhalten Informationen von den Neuronen aus der vorangegangenen Schicht und geben sie an die Neuronen der nächsten Schicht weiter.



Im Input-Layer werden die jeweiligen Inputs, das können z. B. die Werte von Features sein, ins Netz gegeben. Die Anzahl an Neuronen entspricht demnach der Anzahl an Inputs bzw. Features.

Die Hidden-Layer entsprechen hier als Spezialfall sogenannten fully connected layers, da jedes Neuron mit allen anderen Neuronen benachbarter Schichten verbunden ist. Man nennt sie auch dense layer. Die Anzahl an Hidden-Layer und der dort enthaltenen Neuronen können wir frei wählen. Haben wir viele Hidden-Layer, dann sprechen wir von Deep Learning.


Der Output-Layer bestimmt die Ausgabe des Netzes. Das können z. B. bei einer Klassifikation Wahrscheinlichkeiten sein, zu bestimmten Klassen zu gehören. Die Anzahl an Neuronen hängt hier vom Anwendungsfall ab.

Die Stärke der Verbindung zwischen einzelnen Neuronen, hier die Pfeile, wird durch sogenannte Gewichte bestimmt. Dazu gibt es der Vollständigkeit halber noch einen Bias, auf den wir hier aber erstmal nicht weiter eingehen. Gewichte und Biases sind Parameter, die während des Trainings optimiert werden.

Künstliche neuronale Netze - Beispiel


Nun wollen wir mal anhand eines Beispiels eine Klassifikation bzw. Prognose mittels eines neuronalen Netzes vornehmen. Nochmal zur Erinnerung: Bei einer Klassifikation wollen wir eine Beobachtung anhand ihrer Features einer bestimmten Klasse zuordnen. Neuronale Netze lassen sich aber u. a. auch auf Regressionsprobleme anwenden.

Nehmen wir an, wir möchten als Kreditinstitut eine Entscheidung darüber treffen, ob ein Kreditantrag von einem neuen Kunden oder einer neuen Kundin genehmigt werden soll oder nicht. Dafür lassen wir ein neuronales Netz anhand von Trainingsdaten trainieren.



Diese beinhalten bereits bekannte Antragstellende bzw. abgewickelte Kreditanträge und ihre Features, die für die Bewertung der Kreditwürdigkeit relevant sind. Hier z. B. das Einkommen der Antragstellenden und die Dauer des bestehenden Beschäftigungsverhältnisses in Jahren. Die beiden Klassen sind „kreditwürdig“ und „nicht kreditwürdig“.

Wie genau das neuronale Netz trainiert wird, behandeln wir hier erstmal nicht. Nehmen wir aber an, wir hätten jetzt solch ein Netz und wollen nun für eine neue, bisher uns unbekannte Antragsstellende prognostizieren, ob sie kreditwürdig ist oder nicht. Dafür geben wir ihre Werte für die beiden Features ins Netz. Hier sind es z. B. die Werte 4500 für das Einkommen und 26 für die Dauer des Beschäftigungsverhältnisses. Der prognostizierte Output, der vom Netz im Output-Layer ausgegeben wird, sind dann z. B. die Wahrscheinlichkeiten für diese Antragsstellende, zu den beiden Klassen zu gehören. Hier wären es die Wahrscheinlichkeiten 0,7 zur Klasse „kreditwürdig“ und 0,3 zur Klasse „nicht kreditwürdig“ zu gehören. Zusammenaddiert ergeben diese Wahrscheinlichkeiten immer 1 bzw. 100 %. Ordnen wir diese Beobachtung dann der Klasse mit der höchsten Wahrscheinlichkeit zu, dann gehört sie der Klasse „kreditwürdig“ an.



Abschluss

Wir haben gesehen, dass die heute sehr bekannten und beliebten künstlichen neuronalen Netze ihr Vorbild in biologischen neuronalen Netzen im Gehirn haben und wie dort Informationen über Neuronen weitergeben. Durch ihre sehr flexible Struktur können sie in einigen Aspekten klassischen Machine Learning Verfahren überlegen sein, komplexe Zusammenhänge in den Daten erkennen und somit z. B. gute Prognosen liefern. Anwendung finden neuronale Netze insbesondere auch in der Text- und Bildverarbeitung.

Quellen

- Quelle [1] McCulloch, W.S., & Pitts, W. (1943). A logical calculus of the ideas immanent in nervous activity. *Bulletin of Mathematical Biophysics*, 5, 115-133.
<https://doi.org/10.1007/BF02478259>.
- Quelle [2] Géron, A. (2020). *Praxiseinstieg Machine Learning mit Scikit-Learn, Keras und TensorFlow: Konzepte, Tools und Techniken für intelligente Systeme* (2. Auflage). o'Reilly.
- Quelle [3] Drawing of a cortical lamination von S. Ramon y Canal (Public Domain). Reproduziert nach https://en.wikipedia.org/wiki/Cerebral_cortex.
- Quelle [4] Clker-Free-Vector-Images. (2014, April 14). Neuron, Nervenzelle, Axon. Pixabay.
<https://pixabay.com/de/vectors/neuron-nervenzelle-axon-dendriten-296581/>

Weiterführendes Material

Fachbücher:

Guter Einstieg ins Thema, anschaulich erläutert, keine Formeln oder tiefergehende methodische Erläuterungen:

Hetzel, L., & Wangelik, F. (2019). Künstliche neuronale Netze – Ein Nachbau unseres Gehirns? In K. Kersting, C. Lampert, & C. Rothkopf (Hrsg.), *Wie Maschinen lernen* (S. 149-161). Springer, Wiesbaden.

Auch wenn dieses Buch mit R anstatt Python arbeitet, anschauliche Erklärung der Methoden, tiefergehende methodische Erläuterungen:

Lantz, B. (2015). *Machine learning with R* (2. Auflage). Packt Publishing Ltd, Birmingham.
- Chap. 7: Black Box Methods – Neural Networks and Support Vector Machines

Klassisches Werk für Statistisches/Maschinelles Lernen, tiefergehende methodische Erläuterungen:

James, G., Witten, D., Hastie, T., & Tibshirani, R., & Tylor, J. (2023). *An Introduction to Statistical Learning - with Applications in Python*. Springer.
- Chap. 10: Deep Learning

Videos/Kurse:

Kurzer Einstieg ins Thema, anschaulich erläutert:

So lernen Maschinen: #6 Neuronale Netze.
<https://ki-campus.org/videos/solernenmaschinen>

Etwas weitergehender Einstieg ins Thema, anschaulich erläutert:

AMALEA - Angewandte Machine Learning Algorithmen, Woche 4, 1.1: Jetzt geht's in die Tiefe.
<https://moodle.ki-campus.org/mod/videotime/view.php?id=19880>

Elements of AI, Chap. 5: Neural Networks.
<https://course.elementsofai.com/5>

Disclaimer

Transkript zu dem Video „Woche 10 Theorie: Einführung in neuronale Netze“, Ludmila Himmelspach und Katja Theune.

Dieses Transkript wurde im Rahmen des Projekts ai4all des Heine Center for Artificial Intelligence and Data Science (HeiCAD) an der Heinrich-Heine-Universität Düsseldorf unter der Creative Commons Lizenz [CC-BY 4.0](https://creativecommons.org/licenses/by/4.0/) veröffentlicht. Ausgenommen von der Lizenz sind die verwendeten Logos, alle in den Quellen ausgewiesenen Fremdmaterialien sowie alle als Quellen gekennzeichneten Elemente.