

Deep Learning lernen

Ob als Fachleute, aber auch als Konsumenten oder Bürgerinnen und Bürger: Es erscheint angeraten und nötig, sich ein kompetentes Bild von den neuen Verfahren, seinen Möglichkeiten und Grenzen zu machen.

Stefan Geißler¹

Der Stanford-Ökonom Tony Seba beginnt seine Vorträge über disruptive Entwicklungen gerne mit einem Foto einer Straßenszene in New York vom Beginn des letzten Jahrhunderts. „Wo ist das Auto?“ fragt er seine Zuhörer, und tatsächlich, irgendwo im bunten Treiben von Passanten, Pferden und Kutschen steht eines dieser neuen Fahrzeuge. Dann wird überblendet auf dieselbe Szenerie ein paar Jahre später und die Frage lautet „Wo ist das Pferd?“. In wenigen Jahren hatte sich der Verkehr fast völlig gewandelt, nicht graduell sondern eben disruptiv. Das Neue hatte sich in kurzer Zeit neben das Alte geschoben und es vielerorts bereits hinter sich gelassen.

Derzeit, so legen es viele Indikatoren nahe, erleben wir Vergleichbares in einem zentralen Bereich der Informationsverarbeitung, die als Grundlage ungezählter Geschäftsvorgänge der Wirtschaft und unseres Alltags unser Leben tiefgreifend beeinflusst. Maschinelle Lernverfahren sind intensiv dabei, in vielen Bereichen der Informationsverarbeitung herkömmliche Verfahren zu ergänzen, bisweilen auch zu übertreffen. Unter dem Stichwort „Deep Learning“ finden sich entsprechende Verfahren in unserem Smartphone, auf großen Websites wie Facebook, LinkedIn oder Google und demnächst voraussichtlich am Steuer von Taxen, Bussen und bald auch dem Privat-PKW. Auch das Gebiet der Maschinellen Sprachverarbeitung (NLP – natural language processing), um das es in diesem Text insbesondere gehen soll, erfährt gerade eine stürmische Wandlung.

Begriffsklärung: Deep Learning.

Mit dem Begriff „Deep Learning“ werden Methoden bezeichnet, mit denen Berechnungen nicht durch

Maschinelles Lernen und gerade auch Deep Learning werden derzeit hoch gehandelt: Ob man die Einreichungen zu wissenschaftlichen Konferenzen betrachtet, die Download-Zahlen der einschlägigen Pakete, die Zahl der Studierenden in Online-Vorlesungen zum Thema oder die Stellung von „Deep Learning“ auf dem letzten Gartner Hype Cycle¹, der das Thema direkt auf die Spitze des Hypes platziert: Fast scheint es, als gebe es für das neue Paradigma keine Grenzen. Aber selbst wenn man die überzogenen Erwartungen und Versprechen abzieht, bleibt festzustellen, dass unter der Bezeichnung „Deep Learning“ heute Methoden verfügbar sind, die interessante Ergebnisse bei vielen relevanten Aufgaben liefern. Ob als Fachleute, aber auch als Konsumenten oder Bürgerinnen und Bürger: Es erscheint angeraten und nötig, sich ein kompetentes Bild von den neuen Verfahren, seinen Möglichkeiten und Grenzen zu machen.

Machine Learning and in particular deep learning receive a lot of attention currently: Whether we look at the number of papers submitted at scientific conferences, the numbers of downloads of the relevant software packages, the number of students enrolled in online courses or the position of „Deep Learning“ in the latest edition of the Gartner Hype Cycle², which places the topic right at the peak of the hype: Sometimes it seems almost as if there are no limits to what the new paradigm can do. But even if we take away the inflated expectations and promises, we can acknowledge that under the heading „Deep Learning“ there are by now methods available that deliver truly interesting results on many relevant tasks. We as experts but also as consumers and citizens are invited to develop an informed understanding about this new technology, its perspectives but also its limitations.

das Abarbeiten herkömmlicher Programmcodes erzielt werden, sondern durch das Zusammenwirken vieler vergleichsweise einfacher Elemente, die in vager Anlehnung an die Bauweise unseres Gehirns „Neuronen“ genannt werden. Zusammengeschaltet in großen sogenannten Neuronalen Netzen konnten mit diesen Verfahren zuletzt stark verbesserte Ergebnisse in unterschiedlichen Bereichen wie Spracherkennung, Maschinellem Übersetzung und Bildverarbeitung erreicht werden. Entsprechende Systeme werden dabei nicht durch den menschlichen Experten explizit mit Regeln versehen, um ihre Aufgaben zu lösen, sondern lernen automatisch anhand von großen Mengen von Beispielen.

Das Attribut „deep“ spielt hierbei darauf an, dass in den entsprechenden Netzen viele aufeinander aufbauende Schichten von Neuronen eingesetzt wer-

¹ Dieser Text ist die Ausarbeitung des Vortrags „Lebenslanges Lernen“ des Autors auf dem DGI-Forum „Am Anfang war das Wort – wer aber hat heute das Sagen? – Sprache, Wahrheit und Datensouveränität in modernen Kommunikationswelten“ am 8. September 2017 in Wittenberg. <https://dgi-info.de/dgi-forum-wittenberg-2017/>

² <http://www.gartner.com/smarterwithgartner/top-trends-in-the-gartner-hype-cycle-for-emerging-technologies-2017/>

³ <http://www.gartner.com/smarterwithgartner/top-trends-in-the-gartner-hype-cycle-for-emerging-technologies-2017/>

den. Bis vor wenigen Jahren war die für das Training solcher „tiefen“ Netze erforderliche Rechenleistung noch ein großes Hindernis für die Ausbreitung dieser Ansätze, aber eine Kombination aus technischen und algorithmischen Fortschritten hat Deep Learning inzwischen auch in die Reichweite kleinerer Budgets gerückt.

Deep Learning ist damit als Teildisziplin von Maschinellern Lernen zu sehen und damit auch ein Teilgebiet der Künstlichen Intelligenz (AI – artificial intelligence).

Zu den Gebieten, in denen Deep Learning intensiv erforscht und mehr und mehr auch erfolgreich angewendet wird, gehören nicht zuletzt auch verschiedene Bereiche der Verarbeitung natürlicher Sprache. Lernverfahren haben hier beim Syntaxparsing, beim Textverstehen, bei Frage-Antwort-Systemen oder bei der Inhaltsschließung und semantischen Anreicherung derart an Popularität gewonnen, dass Experten




Abbildung 1: Entfernt inspiriert durch den Aufbau des Gehirns: Im „Perceptron“ erhalten Elemente Eingaben von vorgeschalteten Neuronen, summieren diese auf und geben das Ergebnis nach Anwendung einer Aktivierungsfunktion an dahinterliegende Neuronen weiter. Moderne Deep Learning Netzwerke führen Vergleichbares aus – nur oft mit Tausenden oder Millionen von Neuronen in Dutzenden oder Hunderten von aufeinander aufbauenden Schichten. Aus <http://commons.wikimedia.org>

wie Christopher Manning beim Betrachten der Einreichungen auf großen NLP-Konferenzen wie ACL, COLING und anderen von einem „Tsunami“⁴ sprechen, der derzeit über die Sprachverarbeitungsszene rollt. Ich bin von der Ausbildung her Linguist. Fasziniert von den Möglichkeiten einer algorithmischen Verarbeitung von Sprache, haben wir uns an der Universität mit formalen Systemen zu Beschreibung von Morphologie, Syntax und Semantik beschäftigt. Später bei IBM und dann einige Jahre danach mit der Gründung des auf automatisierte Datenerschließung spezialisierten Unternehmens TEMIS machte ich dies zu meinem Beruf. Dabei war es viele Jahre bemerkenswert, dass bestimmte Modelle, die die Computerlinguistik

erarbeitet hatte, über eine lange Zeit ihre Gültigkeit und Konkurrenzfähigkeit erhalten haben. Derzeit nun drängen zusätzliche, neue Methoden, Ansätze und Technologien in den Werkzeugkasten von Sprachverarbeitern sowie Anwenderinnen und Anwendern und laden uns ein, Neues zu lernen und uns selbst in die Lage zu versetzen, zu vergleichen, abzuwägen und, wo nötig, die neuen Verfahren so zu lernen, dass wir sie beherrschen und einsetzen können. Dieses Neue ist in diesem Fall mathematischer und formaler als die bisherigen Werkzeuge und ermöglicht neue Herangehensweisen an Aufgaben wie automatisierte Texterschließung, automatische Zusammenfassung, Content Enrichment, Metadatengewinnung, Volltexterschließung.

Neuronale Netze: So neu nicht

Beim heutigen Deep Learning geht es im Kern um die Weiterentwicklung von Verfahren, die bereits seit einigen Jahrzehnten diskutiert und angewendet werden, allen voran Neuronale Netze. (Abb.1)

Inspiziert vom Aufbau von Gehirnzellen schlug Rosenblatt bereits 1957 das sogenannte Perceptron vor⁵, das in Abhängigkeit von der Stärke der Signale, die es von den Eingabeelementen erhält, eine einfache Berechnung, im Wesentlichen ein Aufsummieren der ankommenden Aktivierungen der vorgeschalteten Neuronen, durchführt und das Ergebnis an die weiteren nachgeschalteten Elemente meldet. Während damit frühzeitig einfachere Klassifikationsaufgaben modelliert werden konnten, kamen diese „Neuronalen Netze“ bald wieder aus der Mode, unter anderem als Minsky und Papert nachwiesen⁶, dass diese Perceptrons prinzipiell nicht in der Lage sind, viele relevante Klassen von Beobachtungen⁷ zu unterscheiden. Dies führte zum ersten sogenannten „AI Winter“, in dem Neuronale Netze aus der Mode kamen und Forschungsgelder und -aktivitäten in andere Richtungen gelenkt wurden.

Interesse steigt wieder steil an

Diese und einige weitere Phasen des erlahmenden Interesses an Künstlicher Intelligenz sind lange vorbei. Die Beschäftigung mit Maschinellen Lernverfahren gilt derzeit als eines der heißesten Themen in der Informationstechnik überhaupt: Online-Kurse

5 F. Rosenblatt: „The perceptron: A perceiving and recognizing automaton“, Cornell Aeronautical Laboratory Report No. 85-460-1, Jan 1957.

6 Minsky, Marvin Lee, and Seymour Papert. 1969. „Perceptrons: an introduction to computational geometry“. 1st ed. Cambridge, Massachusetts: MIT Press.

7 So genannte nicht linear separierbare Beobachtungen, bei denen die zu unterscheidenden Klassen nicht einfach durch eine Gerade im zweidimensionalen Raum oder eben eine Hyperebene in höherdimensionalen Räumen unterteilt werden können.

4 <http://www.mitpressjournals.org/doi/pdf/10.116 h>

zu diesem Thema gehören zu den bestbesuchten Veranstaltungen dieser Art, die Downloadzahlen der einschlägigen Programmierbibliotheken steigen steil nach oben, ebenso wie die Einstiegsgehälter entsprechend ausgebildeter Absolventen. Drei Gründe sind im Wesentlichen hierfür verantwortlich:

- Maschinelle Lernverfahren sind sehr datenhungrig. Sie profitieren jetzt von generellen Trends (wie Internet, Soziale Medien, Sensordaten), die Trainingsdaten in einem noch vor kurzem nicht vorstellbaren Volumen zur Verfügung stellen.
- Die verfügbare Rechenleistung steigt weiter rapide an. In diesem Bereich sogar noch weit schneller als die unseres jeweiligen Arbeitsrechners es von Modell zu Modell ohnehin tut: Es hat sich gezeigt, dass die für Deep Learning erforderlichen Rechenschritte besonders effizient auf modernen Grafikkarten durchgeführt werden können, die für einige hundert Euro die Rechenleistung eines PC um mehr als den Faktor einhundert steigern können. Die Gaming-Industrie und der Hunger der Computerspiel-Nutzer nach immer realistischeren Grafiken in ihren Videospielen hat hier quasi nebenbei Instrumente in die Elektronikmärkte gespült, mit denen sich aufwändige Berechnungen für einen Bruchteil der bisherigen Laufzeiten und Kosten ausführen lassen.
- Letztlich sind neben diesen eher externen Faktoren auch wichtige Durchbrüche in der ML-Gemeinde selbst zu verzeichnen und neue Architekturen und Netzkonfigurationen erlauben die Anwendung von Lernverfahren auch auf bislang kaum handhabbare (siehe unten).

Diese Faktoren zusammengenommen machen das neue Feld sehr zugänglich für Neu- und Quereinsteiger. Große Trainingskorpora sind heute nicht nur vielfach verfügbar, sondern werden bereitwillig geteilt und sind dank schneller Internetverbindungen in Augenblicken heruntergeladen. Die Preise für die erforderliche Rechenleistung auch für viele ernsthafte Experimente sind selbst für Privatpersonen erschwinglich und die nötigen Programmierwerkzeuge sind ebenfalls frei verfügbar⁸, gut dokumentiert und heben die Implementierung von eigenen ML-Experimenten auf ein Abstraktionsniveau, bei dem häufig die Notwendigkeit entfällt, sich mit den Details der Berechnung wie etwa der Ermittlung der partiellen Ableitung der gewählten Loss-Funktion⁹ auseinander-

zusetzen. Um keine Missverständnisse aufkommen zu lassen: Das Gebiet ist und bleibt dennoch stark mathematisch geprägt und dem kann man als Anwenderin oder Anwender nie ganz entgehen. Aber ähnlich, wie höhere Programmiersprachen z.B. eine Sinus-Funktion bereitstellen, die ich verwenden kann, ohne mir jedes Mal über die Herleitung des Sinus Gedanken machen zu müssen, so finden bei der Arbeit etwa mit TensorFlow und Theano viele komplexe mathematische Schritte wie etwa die Berechnung der partiellen Ableitungen quasi hinter den Kulissen statt und erlauben es mir, mich stattdessen mehr auf die Modellierung meiner Aufgabe zu konzentrieren.

Deep Learning in NLP: Zwei Beispiele

Sowohl zu den Grundlagen neuronaler Netze wie auch über die speziellen Einsatzmöglichkeiten in der Sprachverarbeitung (NLP) gibt es hervorragende Einführungen. Verwiesen sei an dieser Stelle insbesondere auf Buch „Deep Learning in Python“ von Francois Chollet¹⁰, das das Gebiet in sehr umfassender Form praktisch, lesbar und zugänglich vorstellt.

Wir wollen an dieser Stelle aus der Fülle von Anwendungsbeispielen exemplarisch zwei Bereiche betrachten, in denen Deep Learning-Ansätze mit einigem Erfolg in der NLP eingesetzt werden.

Die Ermittlung von Wortähnlichkeiten auf Korpora ist eine interessante Aufgabe: Viele Softwareanwendungen, wie z.B. Text-Retrieval-Systeme können profitieren, wenn in großem Stil die semantische Nähe von Wörtern ermittelt und genutzt werden kann. Suchergebnisse können mit den ermittelten Begriffen automatisch angereichert oder Dokumente klassifiziert werden. Unter dem Fachbegriff „Word Embeddings“ sind solche Methoden zur semantischen Wortähnlichkeitssuche inzwischen in den Architekturen von Neuronalen Netzen, in denen Sprache verarbeitet wird, oftmals direkt hinter der Eingabeschicht beteiligt. Die naive Repräsentation von Wörtern oder Dokumenten als hoch-dimensionale, dünn besetzte Vektoren wird dabei überführt in dichter besetzte Vektoren niedrigerer Dimensionalität, mit denen sich nicht nur die semantische Nähe von Wörtern ausdrücken lässt, sondern regelrechte Vektorarithmetik mit Wortbedeutungen betrieben werden kann. Ein häufig zitiertes Beispiel ist hier die Beobachtung, dass sich mit dieser Art von Vektoren zeigen lässt, dass „König“ – „männlich“ + „weiblich“ \sim = „Königin“ ergibt oder „Rom“ – „Italien“ + „Spanien“ \sim = „Madrid“.

8 Die Bibliotheken Tensorflow (<https://www.tensorflow.org/>) und Theano (<http://deeplearning.net/software/theano>) oder Keras (<https://keras.io/>) sind hier gute Einstiegspunkte.

9 Diese Grundlagen werden hier explizit nicht behandelt. Zum einen, weil es hierfür exzellente Einführungen gibt. Zum anderen, weil das Argument ist, dass die einschlägigen Programmierbibliotheken uns genau diese Arbeit abnehmen.

10 Francois Collet: „Deep Learning with Python“, v0.5, MEAP Edition, www.manning.com

gebnisse derzeit noch bei weitem nicht heran. Doch oft sind Zeit und Budgets knapp und die Dokumente zählen nach Millionen: In diesen Situationen haben sich Word Embeddings als bewährtes Verfahren erwiesen.

Eine weitere, eher komplexere Frage ist die des Textual Entailments zwischen zwei Textabschnitten, also die Frage, ob der eine Text den anderen logisch enthält oder ihm widerspricht.

Aussage A	Aussage B	Logisch enthalten?
A dog jumping for a Frisbee in the snow	A pet is enjoying a game of fetch with his owner	Neutral
A dog jumping for a Frisbee in the snow	A cat washes his face and whiskers with his front paw	Widerspruch
A dog jumping for a Frisbee in the snow	An animal is outside in the cold weather, playing with a plastic toy	Enthalten

Tabelle 1: Drei Beispiele aus dem SNLI-Korpus¹², der sich für Experimente zum Textual Entailment anbietet.

Um Fragen dieser Art zu beantworten ist eigentlich umfangreiches Wissen erforderlich. Im Beispiel oben etwa die Tatsache, dass ein Hund ein Tier ist, eine Frisbeescheibe meist aus Plastik, dass Schnee ein Hinweis auf eher kaltes Wetter ist, dass eine Frisbeescheibe zu fangen eine Art Spiel darstellen kann (und nicht etwa eine Arbeit) und vieles andere mehr. Wegen dieser Art komplexer Anforderungen ist die Frage des Textual Entailments notorisch schwierig. Auf dem SNLI-Korpus von 500.000 handannotierten Trainingsbeispielen haben Deep Learning Ansätze bei dieser Aufgabe inzwischen eine Trefferquote von fast 84% erreicht¹³ und sich damit auch in diesem Fall als derzeit führender Ansatz erwiesen.

Beide Szenarien, Word Embeddings wie auch Textual Entailment, zeigen dabei einerseits wie vielseitig das Paradigma Deep Learning auf unterschiedlichsten Gebieten und mit Erfolg angewendet wird. Gleichzeitig werden auch die Limitationen erkennbar: Die Ergebnisse der Vektorarithmetik auf Wörtern wie „König“ und „Königin“ sind eindrucksvoll, aber den Bedürfnissen von Fachleuten in Biologie oder den Rechtswissenschaften werden derartige punktuelle Ergebnisse auf absehbare Zeit wohl nicht gerecht werden. Und so überlegen Deep Learning Netzwerke Schlüsse auf dem SNLI-Korpus ziehen, so ist doch in den wenigsten Situationen in kommerziellen Projekten auch nur ansatzweise ein Korpus von hunderttausenden von relevanten handannotierten Beispielen verfügbar. Während die Ergebnisse auf den beiden oben angeführten Aufgaben interessant aber bisweilen noch

nicht direkt nutzbar erscheinen, sieht es bei einigen klassischen NLP-Fragestellungen bereits anders aus: Beim Satz-Parsing, also der Ermittlung der syntaktischen Struktur von natürlichsprachlichen Sätzen, sind inzwischen Systeme verfügbar, die mit Erkennungsraten von 94-97% Genauigkeit praktisch in den Bereich der menschlichen Leistungsfähigkeit vorstoßen¹⁴. Parsing, eine der zentralen Funktionen vieler NLP-Systeme, ist damit nach Ansicht von Experten für viele praktische Einsatzzwecke gelöst: Die führenden Systeme sind performant und mehrsprachig und, wie so vieles aus den Laboren der Deep Learning Schule, frei verfügbar.

Selber machen: Das Rüstzeug für eigene Deep Learning Erfahrungen

Einem so umfassenden und komplexen Thema kann man sich auf viele verschiedene Arten nähern. Aber ganz sicher ist es von Vorteil, wenn eine dieser Annäherungen über eigene Erfahrungen beim Erstellen, Anwenden und Optimieren von Deep Learning Modellen verläuft.

Die gute Nachricht hierbei ist, dass dieses Thema in besonderer Art und Weise für eine solche Herangehensweise geeignet ist:

- Die maßgeblichen Werkzeuge, die eigene Experimente von ersten Gehversuchen bis zu ernsthaften Arbeiten erlauben, sind meist frei verfügbar und ausgezeichnet dokumentiert. Das gilt für die Programmiersprache an sich (hier ist an erster Stelle sicher Python zu nennen, aber auch

¹² <https://nlp.stanford.edu/projects/snli/>

¹³ <https://arxiv.org/pdf/1509.06664.pdf>

¹⁴ <https://research.googleblog.com/2016/05/announcing-syntaxnet-worlds-most.html>

R¹⁵) wie auch für die darauf aufsetzenden Bibliotheken (Theano und TensorFlow sowie Keras)

- Die Gemeinde der Deep Learning-Protagonisten pflegt in besonderer Weise einen aktiven Austausch von Papieren, Code, Modellen und Daten. Über arXiv und github kann man ohne großen Aufwand eng an den jeweiligen gerade intensiv diskutierten Entwicklungen Anteil nehmen, sie nachbauen, untersuchen und zum Ausgangspunkt eigener Arbeiten nehmen. So ist es beispielsweise längst üblich, in die eigenen Experimente und Arbeiten vortrainierte Schichten von Neuronen (bzw. deren Gewichtungen) einzubinden, die andernorts mit großem Aufwand errechnet und online gestellt wurden. Selbst wenn ich also nicht die Infrastruktur habe, einige Millionen, manchmal Milliarden von Beispielen durchzurechnen, finden sich bisweilen zum Download angebotene Daten hierzu, die sich oft direkt in die eigenen Versuche einbinden lassen.¹⁶

¹⁵ Python (www.python.org) und R (<https://cran.r-project.org/>) sind zwei Beispiele für Programmiersprachen, die in den Data Sciences und gerade bei der Deep Learning-Gemeinde überaus populär sind. Sie zeichnen sich durch ihre Vielseitigkeit, leichte Erlernbarkeit sowie umfangreiche Dokumentation und eine große, aktive Nutzergemeinde aus.

¹⁶ <https://github.com/BVLC/caffe/wiki/Model-Zoo>

So stellen sich rasch eigene Erfolgserlebnisse ein, die Appetit auf mehr wecken: Einen Handschriften-Klassifikator zur Erkennung von Ziffern zu bauen hätte vor Jahren noch umfangreiche Kenntnisse in Bildverarbeitung und Mustererkennung sowie in hochspezialisierten Programmierparadigmen erfordert. Heute ist ein Modell, das den weit verbreiteten MNIST-Datensatz¹⁷ bewältigt, in wenigen Zeilen Code erstellt und liefert nach einigen Minuten Trainingszeit Ergebnisse ab, die der menschlichen Leistung beim Erkennen von Ziffern praktisch gleichkommen. Ein solcher MNIST-Erkennen wird daher oft bereits als das „Hello World“ der Deep Learning-Gemeinde bezeichnet, also eine eher einfache Aufgabe, die zunächst die prinzipielle Vollständigkeit der Herangehensweise an sich bestätigen soll, bevor man sich an zunehmend komplexere Aufgaben wagt.


Auch dies ist mit dem Titel dieses Beitrags gemeint: Wer zu „Deep Learning Lernen“ bereit ist, und offen dafür, den eigenen Kompetenzen neue Werkzeuge wie diese hinzuzufügen, erschließt sich damit einen ganz eigenen Zugang zu diesem neuen, spannenden

¹⁷ <http://yann.lecun.com/exdb/mnist/>. Der MNIST Datensatz besteht aus 60.000 handannotierten Bildern von handgeschriebenen Ziffern.

Join Brill at the Frankfurt Book Fair!

Ask about our newest online resources

Brill is located in Hall 4.2, Booth M9. If you would like to talk to one of our sales managers, please visit the booth or send an email to marketing@brill.com.




The Hebrew and Aramaic Lexicon of the Old Testament Online

Edited by **Ludwig Koehler**, **Walter Baumgartner** and **Johann Jakob Stamm**

Translated and edited under the supervision of **M.E.J. Richardson**

brill.com/halo
E-ISSN 2352-3433

Purchase Options and 2017 Prices
Online Subscription: EUR 800
Outright Purchase: EUR 4,000




Enzyklopädie jüdischer Geschichte und Kultur Online

Edited by **Dan Diner**, The Hebrew University of Jerusalem

English language content to be added in 2017

brill.com/ejgk
E-ISSN 2468-2845

Purchase Options and 2017 Prices
English and German Combined Bundle
Online Subscription: EUR 750
Outright Purchase: EUR 3,900



U.S. Intelligence on Asia, 1945-1991

Editor: **Matthew M. Aid**

brill.com/usao
E-ISSN 2542-7113

Purchase Options and 2017 Prices
Outright Purchase: EUR 3,910

Available on BrillOnline.com

For more information please contact our Sales department at sales-us@brill.com (the Americas) or sales-nl@brill.com (Europe, Middle East, Africa and Asia-Pacific).

Online Highlights



Abbildung 3: In ähnlicher Weise wie die zugrundeliegende Vektorrepräsentation es erlaubt, aus der Bedeutung für „König“ den Aspekt „männlich“ herauszurechnen, so kann man auch aus einem Bild von Van Gogh den Inhalt (das Portrait des Künstlers) herausrechnen und der verbliebenen Essenz des Stils des Gemäldes eine Katze hinzufügen. Aus <https://no2147483647.wordpress.com/2015/12/21/deep-learning-for-hackers-with-mxnet-2/>

Gebiet, selbst wenn die konkrete Implementierung neuer Deep Learning-Modelle absehbar nicht zum eigenen Tätigkeitsprofil im Alltag gehören wird. Hat man erste eigene Erfahrungen mit dem neuen Paradigma gesammelt, ist man vielleicht ein wenig gegen lautsprecherische Versprechungen gewappnet, die versichern, dass System X von Hersteller Y angeblich „ganz ohne Aufwand“ und „mit nahezu 100%iger Genauigkeit“ an „lediglich einer Handvoll Beispielen trainiert“ seine Aufgaben versehen kann. Für junge Leute, die eher am Beginn des eigenen beruflichen Weges stehen, gehören praktische Kenntnisse rund um Lernverfahren zudem sicher zu den Qualifikationen, die das eigene Profil in besonderer Art und Weise aufwerten.

Wie wird es weiter gehen?

Der Hype rund um Deep Learning wird derzeit durch die üblichen Mechanismen weiter befeuert: Spezialisierte Start-Ups wetteifern um Aufmerksamkeit und überbieten sich mit Vorhersagen darüber, was bald möglich sein wird. Etablierte Branchengrößen wollen den Zug nicht verpassen und kleben rasch das Label „Deep Learning“ auf ihre Produkte und Aktivitäten. Förderorganisationen erliegen der Versuchung, Anträge bereits für die ausgiebige Verwendung der richtigen Buzzwords zu belohnen.

Die führenden Experten sind da glücklicherweise zurückhaltender. Der US-Amerikaner Andrew Ng, der Maschinelles Lernen selbst an vorderster Front in Stanford, bei Google und Baidu vorangetrieben hat, konstatiert vorsichtig, derzeit sei Deep Learning recht gut darin, Aufgaben zu lösen, die wir Menschen in wenigen Augenblicken leisten können: Die Objekte auf einem Foto zu erkennen, gesprochene Sprache

in geschriebenen Text umzuwandeln oder Text einer Sprache in eine andere etwa. Bei komplexeren Aufgaben, die längerfristiges Planen, Bewerten und Koordinieren erforderten, seien die neuen Verfahren jedoch noch weitestgehend überfordert. François Chollet, Autor der populären Programmbibliothek Keras, nennt als Beispiel die vergebliche Hoffnung, bald werde man von lernenden Systemen auf der Basis einer Spezifikation eines zu implementierenden Programms den lauffähigen Code erwarten können. „Obwohl ein Deep Learning Modell als eine Art Programm gesehen werden kann, gilt dennoch umgekehrt, dass die meisten Programme eben nicht als Deep Learning Modelle ausgedrückt werden können.“

„Wenn alles, was man an Werkzeug zur Verfügung hat, ein Hammer ist, dann erscheint einem jedes Problem als Nagel.“, lautet ein beliebtes Bonmot. Und selbst wenn man nicht nur über einen Hammer, sondern wie im Falle der Verfahren des Deep Learning quasi über ein Schweizer Taschenmesser verfügt und sich damit auch an Schrauben, Äste, Briefumschläge oder Weinflaschen wagen kann, tut man gut daran, sich über die Einsatzmöglichkeiten aber gerade auch über die Grenzen der Reichweite seiner Werkzeuge Gedanken zu machen. **I**



Stefan Geißler

Senior Cognitive Scientist
Expert System Deutschland GmbH
Blumenstr 15
D-69115 Heidelberg
sgeissler@expertsystem.com