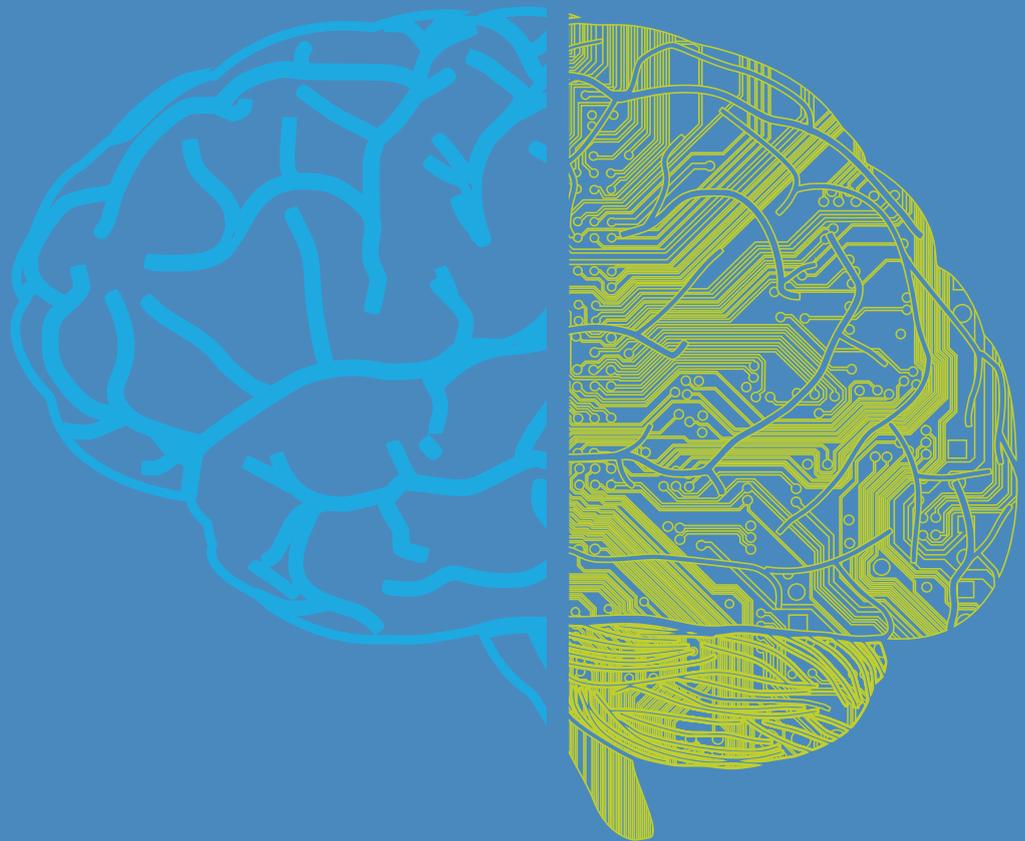




**Bernstein Network
Computational Neuroscience**

Bernstein Feature

2019



*In der Zukunft denken
Thinking in the Future*

in dieser Ausgabe in this issue

Artikel/ Articles

- 16 Künstliche Intelligenz nach dem Vorbild der Funktion des Gehirns/
Artificial Intelligence Modelled on Brain Function,
Fred Hamker, Chemnitz
- 28 **Mathematik bringt Licht ins Dunkel neuronaler Zusammenarbeit/**
Mathematics Sheds New Light on Neuronal Cooperation,
Viola Priesemann, Göttingen
- 18 An der Schnittstelle zwischen KI Anwendung und Entwicklung, das
Institut für Neuroinformatik (INI) der Ruhr-Universität Bochum (RUB)/
At the Interface between AI Application and Developmen. A Short Profile
of the Institute of Neuroinformatics (INI) of the Ruhr-University Bochum
(RUB), Gregor Schöner, Bochum
- 24 Systementwicklung und Engineering für KI/ Eine disziplinübergreifende
Perspektive aus dem Frankfurt Institute of Advanced Studies FIAS/
Systems Science & Engineering for AI. A Transdisciplinary Perspective
from the Frankfurt Institute of Advanced Studies FIAS
- 26 Der Einzug der künstlichen Intelligenz in der Computational
Neuroscience/
The Advent of Artificial Intelligence in Computational Neuroscience
Gastbeitrag/ Guest Article ,Moritz Grosse-Wentrup, Wien

Anwendungsbeispiele/ Applications

- 20 Rotorblattdefekte an Windrädern durch Hören
erkennen/
Hearing Defects in Wind Turbine Blades
 - 20 Spuren der Gedächtnisbildung und Konsolidierung/
Traces of Memory Formation and Consolidation
 - 22 Schwindel und Gleichgewicht. Multimodale
Diagnose mit Hilfe von Maschinellern Lernen und
Deep Learning/
Vertigo and Balance. Multi-modal Diagnosis with
the help of Machine and Deep Learning
 - 22 Tiefe rekurrente neuronale Netze in der Psychiatrie.
Entscheidungshilfen für klinische Einsichten und
Vorhersagen/
Deep Recurrent Neural Networks in Psychiatry.
Helping medical decisions and predictions
- ### Wie können Maschinen Lernen lernen?/ How can Machines Learn to Learn?
- 8 Übertragung von Lernstrategien des Gehirns in
maschinelle Anwendungen/
Transfer of the Brain's Learning Strategies into
Machine Applications
 - 8 Gepulste Neuronale Netze lernen zu lernen/
Spiking Neural Networks that Learn to Learn

Interviews

- 10 **Grenzgänger zwischen Forschung und Industrie/**
Crossing Borders between Science and Industry
Florian Röhrbein, Alfred Kärcher SE & Co KG

- 38 **KI — Herausforderung für unsere**
gesellschaftliche Zukunft/
AI: Challenging our Future Societies
Stefan Heumann, Enquete Kommission KI
des Bundestages

Werkzeuge/ Computational Tools

- 30 Innovative Algorithmen für die Analyse neuronaler Daten/
Innovative Algorithms for Neuronal Data Analysis

- 30 Mit KI elektrische Gehirnsignale interpretieren/
Using AI to Interpret Electrical Brain Signals

- 32 Das Helmholtz Analytics Toolkit (HeAT), Eine High Performance Computing (HPC) Programmbibliothek für wissenschaftliche Big Data Analytik/
The Helmholtz Analytics Toolkit (HeAT). A High Performance Computing (HPC) Library for Scientific Big Data Analytics

- 32 Mit Modellen und Simulationen die Plastizität des Gehirns verstehen/
Understanding the Plasticity of the Brain through Models and Simulations

Forschungszentren/ *Research Centers* Forschungskonsortien/ *Consortia*

- 6 Berliner Kompetenzzentrum für Maschinelles Lernen
Berlin Competence Center for Machine Learning (BZML)

- 14 Tübingen AI Center

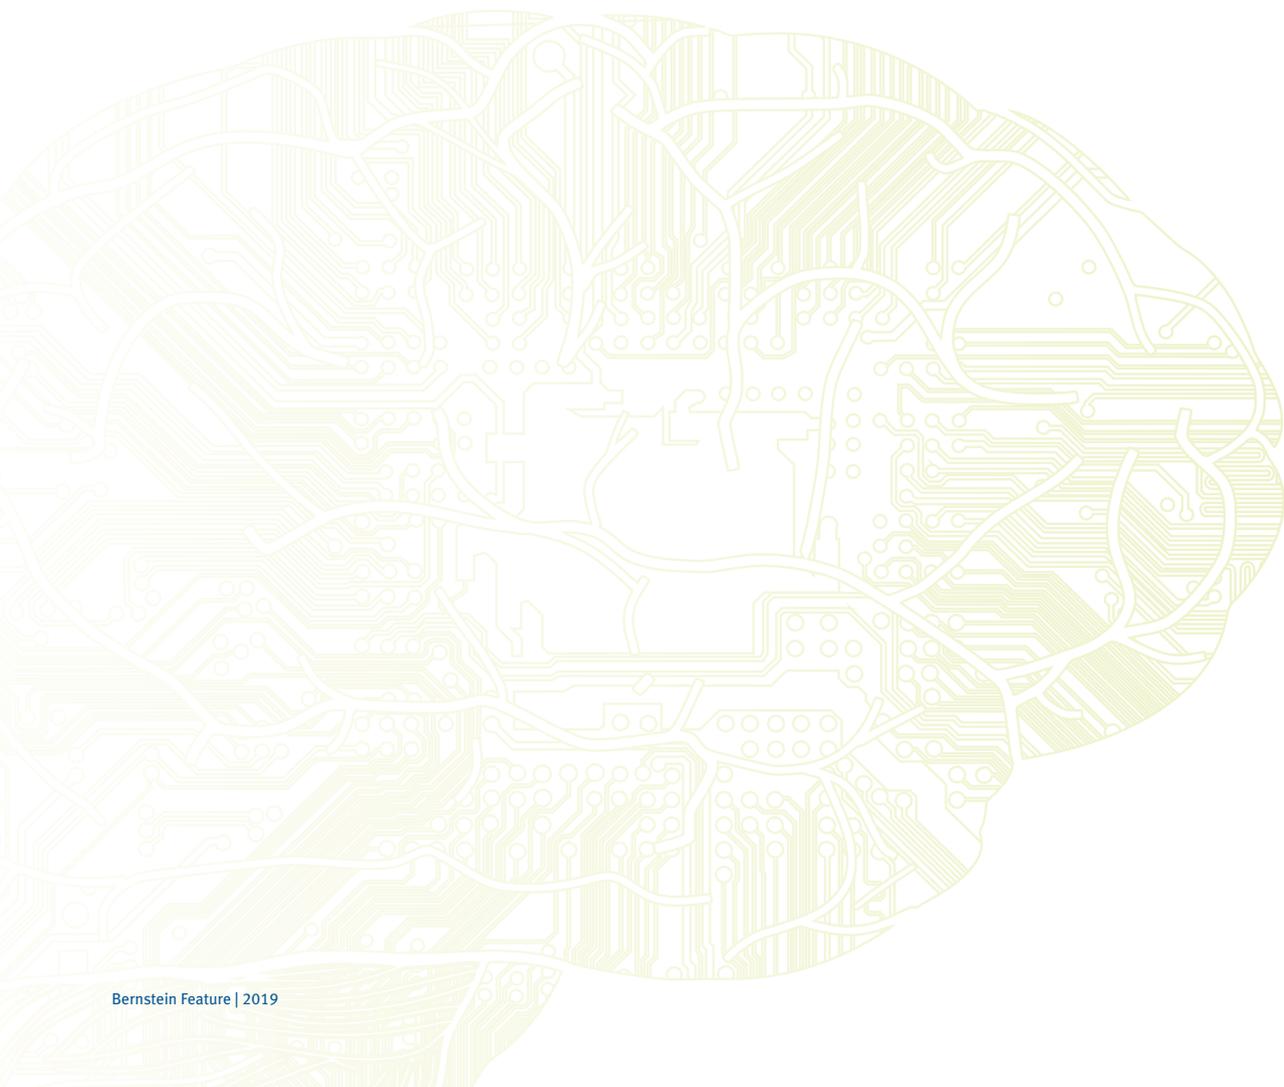
- 34 Bernstein Center for Computational Neuroscience
BCCN Tübingen

- 36 Exzellenzcluster / Excellence Cluster 'Machine Learning: New Perspectives for Science'

Ausblick in die Zukunft/ *Future Prospects*

- 42 **Neuromorphe Hardware für die nächste Generation KI. Markus Diesmann wirft einen Blick in die Zukunft der Computerentwicklung/**
Neuromorphic Hardware for the Next Generation AI. Markus Diesmann Casts a Glance into the Future of Computer Development

- 44 The European Laboratory for Learning and Intelligent Systems ELLIS.



Vorwort/ Preface

Seit Jahrzehnten versuchen WissenschaftlerInnen, das Gehirn zu verstehen und seine Fähigkeiten in Systemen der künstlichen Intelligenz (KI) nachzuahmen. In den letzten Jahren gab es dabei vor allem durch die Erfolge des ‚Deep Learning‘ rasante Fortschritte. Viele neue KI-Anwendungen durchdringen immer mehr unser tägliches Leben. Durch das maschinelle Lernen sind Maschinen viel besser darin geworden, Objekte und Sprache zu erkennen: Sie übertreffen Menschen nicht nur beim Schach, Go oder Starcraft II Spielen, sondern auch bei medizinischen Diagnosen und vielen anderen Mustererkennungsaufgaben.

‚Deep Learning‘ verwendet künstliche neuronale Netze, die von der Computational Neuroscience inspiriert sind. Die Architektur der am meisten verwendeten ‚Convolutional Neural Networks‘ wurde bereits 1980 von dem japanischen Wissenschaftler Fukushima als Modell der Bildverarbeitung des visuellen Gehirns vorgeschlagen, wobei Fukushima sein Modell auf die Erkenntnisse der Nobelpreisträger Hubel und Wiesel stützte. Die Ähnlichkeit zwischen den künstlichen neuronalen Netzen und den Vorbildern im Gehirn besteht aber nur auf einem abstrakten Level. Im Detail lassen sich zahlreiche und zum Teil markante Unterschiede finden.

Da Modelle immer nur Annäherungen an die Wirklichkeit sind, kommt es sehr darauf an, welcher Aspekt der Wirklichkeit mit einem Modell eingefangen werden soll. Modelle des Gehirns unterscheiden sich darin, ob sie vor allem neurophysiologische Beobachtungen wiedergeben oder die kognitiven Funktionen erklären sollen. In der Praxis stehen diese Ziele häufig in Konkurrenz zueinander. Eine möglichst umfangreiche Berücksichtigung neurophysiologischer Details geht auf Kosten einer besseren Leistung bei der Nachahmung von kognitiven Gehirnfunktionen und umgekehrt. Das Feld der Computational Neuroscience versucht sowohl den Ansprüchen der Neurobiologie als auch der Herausforderung der KI gerecht zu werden, die kognitiven Leistungen nachzuahmen. Dieses Spannungsfeld ist manchmal etwas mühselig, bietet aber Chancen für neue Ideen. Gerade wenn es darum geht, grundlegende Eigenschaften wie z.B. die Lern- und Anpassungsfähigkeiten von Maschinen zu verbessern, kann die Computational Neuroscience, wie schon beim Deep Learning, entscheidende Impulse liefern. So ist es auch kein Zufall, dass die wichtigste Machine Learning Konferenz (Neural Information Processing Systems) seine Wurzeln in der Computational Neuroscience hat und ForscherInnen nicht selten zwischen diesen Feldern wechseln.

Dieses Bernstein Feature wirft einen Blick auf die aktuelle KI-Forschung und Anwendung im interdisziplinären Dialog. Die verschiedenen Beiträge von WissenschaftlerInnen aus dem Bernstein Netzwerk beleuchten die KI-Forschung im Netzwerk aus der Sicht ihrer Institute, Forschungsverbände oder einzelner Projekte. Sie zeigen, wie sie fachübergreifend forschen und in die Zukunft denken. Zusätzlich wird diese Ausgabe durch Interviews aus der Industrie sowie der Enquete Kommission KI des Deutschen Bundestages und einem Gastbeitrag bereichert, die den Blick über die Forschungsinhalte im Bernstein Netzwerk hinaus auf die gesellschaftliche Bedeutung der KI-Forschung werfen.

For decades, scientists have been trying to understand the brain and imitate its capabilities in Artificial Intelligence (AI) systems. In recent years, rapid progress has been made in this area, mostly due to the success of ‘Deep Learning’. Many new AI applications are permeating our daily lives. Because of advances in Machine Learning, machines are now much better at recognizing objects and distinguishing language; they surpass humans not only in chess, Go or Starcraft II, but also in medical diagnostics and many other pattern recognition tasks.

Deep Learning uses artificial neural networks inspired by computational neuroscience. The most common architecture of ‘Convolutional Neural Networks’ was proposed as early as 1980 by the Japanese scientist Fukushima as a model for image processing of the visual brain. Fukushima based his model on findings of the Nobel Laureates Hubel and Wiesel. The similarity between artificial and biological neural networks, however, exists on an abstract level only. With increasing detail, numerous and at times striking differences can be found.

Since models are only approximations to reality, it is crucial to specify which aspect should be captured by a model. An important difference between various models of the brain are related to whether they are primarily intended to reproduce neurophysiological observations or to explain cognitive functions. In practice, these goals often compete. When putting highest priority on mimicking as much neurophysiological detail as possible, one often compromises performance in imitating cognitive brain functions and vice versa. The field of computational neuroscience tries to meet both neurobiological demands and the challenge of AI to imitate cognitive performance. This tension can be a little tedious at times, but it offers opportunities for novel ideas; especially when it comes to tackling fundamental problems, such as the learning and adaptation abilities of machines, computational neuroscience can provide decisive impulses just like it did for Deep Learning. It is thus no coincidence that the most important Machine Learning Conference (Neural Information Processing Systems) is rooted in computational neuroscience and researchers often move between these fields.

The present Bernstein Feature takes a look at current AI research and applications from an interdisciplinary perspective. The various articles written by members of the Bernstein Network provide an overview of how they conduct interdisciplinary research at their institutes, in research alliances or in smaller projects. In addition, a guest article and interviews from industry and the Enquete Kommission AI of the German Bundestag discuss the societal impact of AI research beyond academia.

Prof. Dr. Matthias Bethge
Deputy Chairman, Bernstein Network Computational Neuroscience
Leitung/ Head of Tübingen AI Center



Berliner Kompetenzzentrum für Maschinelles Lernen (BZML)

2018 bewilligte das Bundesministerium für Bildung und Forschung (BMBF) Fördergelder zur Etablierung von Kompetenzzentren für Maschinelles Lernen. Berlin und Tübingen, zwei zentrale Standorte des Bernstein Netzwerks, sind dabei.

Klaus-Robert Müller, Professor für Maschinelles Lernen an der Technischen Universität Berlin, setzt sich seit über 25 Jahren dafür ein, Maschinelles Lernen für die ‚wichtigen Dinge‘ wie Medizin, Natur- oder Neurowissenschaften zu nutzen. Seit 2018 ist er Sprecher des Berliner Kompetenzzentren für Maschinelles Lernen (BZML).

6

Die Partner des BZML sind neben der Freien Universität Berlin, der Humboldt-Universität zu Berlin und der Technischen Universität Berlin auch die Charité- Universitätsmedizin Berlin, die Max-Planck-Gesellschaft und das Fraunhofer-Institut für Nachrichtentechnik/ Heinrich-Hertz-Institut, HHI. Ziel des Berliner Zentrums ist es, die Synergieeffekte der Berliner Wissenschaftslandschaft und die Grundlagenforschung im Bereich des Maschinellen Lernens zu bündeln und in praxisrelevante Anwendungen zu übertragen.

Das BZML hat mehrere Schwerpunkte: zum einen geht es darum, die theoretischen und algorithmischen Grundlagen des Maschinellen Lernens weiter voranzutreiben und Berlin entsprechend im internationalen Wettbewerb zu positionieren. Ein weiterer Schwerpunkt wird darin liegen, neue wissenschaftlich-technische Anwendungen des Maschinellen Lernens zu erschließen. Dies beinhaltet auch die effiziente Nutzbarmachung von a priori Wissen in Lernprozessen sowie die Untersuchung der Auswirkungen von fehlerhaften oder unvollständigen Datensätzen. Hier arbeiten unsere WissenschaftlerInnen sehr eng mit KollegInnen aus der Medizin, der Kommunikation und den Digital Humanities (Digitale Geisteswissenschaften – Schnittstelle zwischen Geisteswissenschaften und Informatik) zusammen.

Allen diesen Bereichen ist gemein, dass sie über eine Unmenge von unterschiedlich strukturierten, multimodalen Daten aus verschiedensten Quellen verfügen, deren Informationen sinnvoll und vor allem auch nachvollziehbar fusioniert werden sollen. Auch wenn die Thematik der einzelnen Bereiche sehr unterschiedlich ist, sind die Fragestellungen an das Maschinelle Lernen dabei sehr ähnlich. Wichtige Forschungsziele des BZML sind die Erweiterung der theoretischen und algorithmischen

Grundlagen des Maschinellen Lernens (ML) in wettbewerbsorientierter Weise, sowie das Erschließen neuer wissenschaftlicher und technischer ML-Anwendungen. Neben der interdisziplinären Forschungsarbeit, vor allem im Hinblick auf medizinische Forschung streben die ForscherInnen danach, die ML Methoden für Industrie und Wissenschaft besser und einfacher nutzbar zu machen.

Wir sind der Überzeugung, dass Maschinelles Lernen die Wissenschaft auf vielen Gebieten voranbringen kann. Es ist eines der seltenen Felder, in denen man

durch bessere Grundlagenforschung direkt bessere Anwendungsergebnisse ermöglicht. Dies spiegelt sich in der Zusammenarbeit mit den Pathologen der Charité- Universitätsmedizin Berlin. Hier wird ein sich selbst trainierendes Bilderkennungsverfahren entwickelt, welches Krebszellen genauer identifiziert, sie klassifiziert und ihre zerstörerische Wirkung abschätzen soll. Die Fortschritte sind beachtlich. Eine andere Anwendung im Gesundheitsbereich ist beispielsweise herauszufinden, ob eine Blutvergiftung von Bakterien oder Viren verursacht wurde.

In den Neurowissenschaften haben wir mit dem Fraunhofer Heinrich-Hertz-Institut die sogenannte ‘Layer-wise Relevance Propagation’ (LRP) entwickelt und patentieren lassen. Dies ist eine Methode zum besseren Verständnis neuronaler Netze. Im übertragenen Sinn sind diese aus verschiedenen Schichten von verbundenen, selbstlernenden, algorithmischen Elementen aufgebaut – ähnlich wie menschliche Neuronen. Um solchen Lernsystemen beispielsweise das Erkennen von Bäumen beizubringen, ‚füttert‘ man sie mit Bildern, auf denen unterschiedliche Bäume zu sehen sind. Allerdings wird auf den Bildern nicht der Baum selbst markiert, sondern man gibt dem gesamten Bild ein Label ‚Baum‘ oder ‚Nicht-Baum‘. Nach und nach bündelt das System alle Rückmeldungen und wertet sie aus, bis jeder Baum auf jedem Bild erkannt wird. Mit der LRP werden diese einzelnen Entscheidungsprozesse schichtweise rückwärts betrachtet und dabei berechnet, welche ‚Neuronen‘ welche Entscheidungen getroffen haben und welche Relevanz diese Entscheidung für das Endergebnis hatte. Dargestellt wird das optisch in einer sogenannten ‚Heatmap‘. Diese zeigt, welche Pixel in dem Bild ganz besonders stark zur Eingruppierung des Bildes als Baum oder Nicht-Baum beigetragen haben. Diese Methode, Ergebnisse neuronaler Netze nachträglich interpretierbar zu machen, ist ein entscheidender Schritt nach vorn, vor allem, da das System über die Bilderkennung hinaus einsetzbar ist.

Datensicherheit und Weiterentwicklung im Bereich des Maschinellen Lernens müssen nicht unbedingt ein Widerspruch sein. Als Verfechter von Privatheit im Netz und dem Schutz privater Daten glaube ich, dass durch bestimmte Regulierungsmaßnahmen beides möglich ist. Es gibt technische-algorithmische Optionen, mit denen Informationen für Dienste extrahiert werden können, ohne dass alles gespeichert werden muss. Es gilt, sinnvolle Regulierungen zu finden, in denen Privatheit geschützt wird und technische Rahmenbedingungen ermöglicht werden, sodass mit unseren Daten kein digitaler Schindluder getrieben werden kann.

/K.-R. Müller, TU Berlin/ M. Franke, BCCN Berlin/



Berlin Competence Center for Machine Learning (BZML)

In 2018, the Federal Ministry of Education and Research (BMBF) approved funding for the establishment of Competence Centers for Machine Learning. Berlin and Tübingen, two central locations of the Bernstein Network, are among them.

For more than 25 years, Klaus-Robert Müller, Professor for Machine Learning at the Technical University of Berlin, has been committed to using Machine Learning for 'important matters', like medicine, the natural and the neurosciences. Since 2018, he is spokesman of the Berlin Competence Center for Machine Learning (BZML).

Together with Freie Universität Berlin, Humboldt-Universität zu Berlin, and Technische Universität Berlin, the partners of the BZML include Charité- Universitätsmedizin Berlin, the Max Planck Society, and the Fraunhofer Institute for Telecommunications, Heinrich Hertz Institute, HHI. The aim of the Berlin Competence Center is to bundle the synergy effects of the Berlin scientific landscape and basic research in the field of Machine Learning and to transfer them into practical applications.

The BZML focuses on several aspects: on the one hand, we want to further advance the theoretical and algorithmic foundations of Machine Learning and put Berlin on the map of international cutting-edge research. Another focus will lie on the development of new scientific and technical applications of Machine Learning. This also includes the efficient use of prior knowledge in learning processes and the investigation of the effects of erroneous or incomplete data sets. Here, our scientists work together with colleagues from medicine, communication and digital humanities (the interface between the humanities and computer science).

Common to all these areas is a vast amount of differently structured, multimodal data from various sources. Its information must be merged in a meaningful and, above all, comprehensible way. Even if the topics of the individual areas are very different, the questions of Machine Learning are very similar. Important research goals of the BZML are the competitive expansion of the theoretical and algorithmic foundations of Machine Learning (ML) and the development of new scientific and technical ML applications. In addition to interdisciplinary research work, especially with regard to medical research, the researchers are striving to make ML methods better and easier to use for industry and science.

We believe that Machine Learning can take science a big step forward in many areas. It is one of those rare fields in which better basic research can directly lead to better application results. This is reflected in the cooperation with the pathologists of the Charité. Here, a self-training image recognition method is being developed that will identify cancer cells more precisely, classify them and assess their destructive effect. Here, the progress is remarkable. Another application in the health sector is, for example, to find out whether blood poisoning was caused by bacteria or viruses.

In the field of neuroscience, we have developed and patented layer-wise relevance propagation (LRP) together with the Fraunhofer Heinrich Hertz Institute. This is a method with which neuronal networks can be better comprehended. In the figurative sense, these networks are composed of different layers of connected, self-learning algorithmic elements – similar to human neurons. To teach such learning systems how to recognize trees, for example, they are 'fed' images of different trees. Yet, the tree itself is not marked in these pictures, but the whole picture is either labelled 'tree' or 'non-tree'. Gradually, the system learns from the feedback it receives and evaluates the results until each tree on each image is recognized. With LRP, the individual decisions during this process are examined backwards layer by layer, calculating which 'neurons' made which decisions and estimating the relevance this decision had for the final result. This can be viewed in a so-called 'heat map' revealing which pixels in the image contributed particularly strongly to the classification of the image as a tree or non-tree. Making the results of neural networks interpretable in this way is a decisive step forward, especially since the system can be applied beyond image recognition.

Data security and further development in the field of Machine Learning are not necessarily a contradiction in terms. As an advocate of data privacy and data protection, I believe that both are possible under certain terms and conditions. There are technical-algorithmic options with which service information can be extracted without storing data. Therefore, it is necessary to find sensible regulations which protect private data and set technical boundary conditions, so that our private data cannot be used to make a digital mess of things.

/K.-R. Müller, TU Berlin/ M. Franke, BCCN Berlin/cd/

Pooling the synergy effects of Berlin's scientific landscape



Wie können Maschinen Lernen lernen?

Übertragung von Lernstrategien des Gehirns in maschinelle Anwendungen

Klaus Obermayer am Bernstein Center for Computational Neuroscience (BCCN) Berlin beschäftigt sich intensiv mit den Grundlagen der Informationsverarbeitung in biologischen Systemen. Ihn fasziniert die Komplexität des Gehirns und die Frage, ob auch Maschinen nach ähnlichen Prinzipien arbeiten – und lernen – könnten.

Zentrale Forschungsgebiete seiner Arbeitsgruppe sind deshalb vor allem die Mustererkennung und das Lernen von Zusammenhängen anhand von Beispieldaten. Obermayers Forschungsgruppe entwickelt Verfahren des Maschinellen Lernens mit Anwendungen in der Bild- und Signalverarbeitung mit einem besonderen Fokus auf biomedizinische Daten. Interessant ist die Erkenntnis, dass das Gehirn mit Mustererkennung ‚arbeitet‘, diese Erkenntnisse interpretiert und daraus dann sehr flexibel anhand weniger Beispieldaten die entsprechenden Algorithmen entwickelt. Diese flexible Fähigkeit fehlt Maschinen, und hierfür werden Lösungen gesucht. Außerdem interessiert die ForscherInnen seiner Gruppe die Rolle von Belohnungs- und Bestrafungssignalen bei Lernprozessen, das sogenannte ‚Reinforcement Learning‘. Auch hierfür steht das menschliche Gehirn Modell, und man versucht, Lernprozesse für maschinelle Anwendungen zu entwickeln.

Der Lernprozess im Gehirn wird von Molekülen gesteuert – der eines künstlichen Netzes nicht. Deshalb ist gerade die Erforschung von Lernregeln für künstliche neuronale Netzwerke, die von Neuro-Modulatoren wie z.B. den Neurotransmittern Dopamin oder Acetylcholin inspiriert sind, eine sehr wichtige Grundlage des Erkenntnisgewinns. Obwohl immer gelten wird, dass sich die mechanistischen

Vorgehensweisen von Maschinen und dem menschlichen Gehirn unterscheiden, können die den Lernprozessen zu Grunde liegenden Prinzipien sehr wohl übertragen werden. Davon sind die ForscherInnen überzeugt.

Klaus Obermayer macht sich besonders für die Ausbildung des wissenschaftlichen Nachwuchses stark und hat im Graduiertenprogramm Computational Neuroscience des Bernstein Zentrums Berlin zahlreiche DoktorandInnen ausgebildet, in deren Arbeiten das maschinelle Lernen der Zukunft weiterentwickelt wurde. Die Dissertationen erforschten beispielsweise die Modellierung von Verhaltensänderung bei Alkoholmissbrauch im Hinblick auf Reinforcement Learning. Eine Ausbildung in diesem Feld resultiert nicht nur in exzellenten WissenschaftlerInnen, sondern auch in sehr gut ausgebildeten MitarbeiterInnen in den Branchen Data Science, Maschinelles Lernen, künstliche Intelligenz. Einige der Absolventen haben Start-Ups gegründet oder arbeiten in der freien Wirtschaft als Data Scientists.

In den letzten Jahrzehnten haben Konzepte aus der künstlichen Intelligenz und dem Maschinellen Lernen die Neurowissenschaften befruchtet und zu neuen Einsichten geführt. Jetzt ist es an der Zeit, die Fortschritte in den Neurowissenschaften für die Entwicklung neuartiger lernender Maschinen zu nutzen.

/K. Obermayer, TU Berlin/ M. Franke, BCCN Berlin/ cd/

8

Gepulste Neuronale Netze lernen zu lernen

Obwohl das Lernen bereits seit langer Zeit im Fokus von Neurobiologie und Informatik liegt, entwickelten sich beide Bereiche eigenständig, was zu unabhängigen Durchbrüchen geführt hat. So hat die Neurobiologie Erkenntnisse über Gehirnanatomie und Plastizität hervorgebracht, während die Informatik Deep Learning entwickelt hat. In jüngster Zeit werden diese Fortschritte miteinander verknüpft, was ein gründlicheres Verständnis des menschlichen Lernens und die Entwicklung besserer Lernalgorithmen verspricht.

Ein Beispiel dafür ist ‚Learning to Learn‘ (L2L, Lernen zu Lernen), ein bekannter Ansatz aus Künstlicher Intelligenz und Maschinellem Lernen, der es einem System ermöglicht, eine neue Aufgabe aus nur wenigen Beispielen zu lernen, da das System zuvor in der entsprechenden Aufgabenfamilie geschult wurde. Wolfgang Maass und KollegInnen der Technischen Universität Graz entwickelten ein Framework für die Anwendung von L2L-Methoden für gepulste neuronale Netze. In L2L wird das Lernen in zwei Schleifen (oder Parametersätze) zerlegt: eine innere Schleife, in der ein Netzwerk bestimmte Aufgaben von derselben Familie lernt, und eine äußere Schleife, in der Hyperparameter aktualisiert werden, um die allgemeine Lernkapazität des Netzwerks zu verbessern. Die äußere Schleife verwendet Optimierungsalgorithmen wie evolutionäre Strategien, Filterung und biologische Neuformulierungen der ‚Backpropagation‘ (Rückpropagierung), ein verbreitetes Verfahren für das Trainieren von künstlichen neuronalen Netzen.

Die konzeptionelle Ähnlichkeit dieser äußeren Optimierung und der Optimierung des Gehirns durch die Evolution wirft folgende Frage auf: Sind die Strukturen und Funktionen, welche in diesen trainierten neuronalen Netzwerken entstehen, der Anatomie und Physiologie des Gehirns ähnlich? Diese Idee untersuchen wir in einer Kollaboration, wobei das Institute of Neuroscience and Medicine INM-6 am Forschungszentrum Jülich biologisch strukturierte neuronale Netzwerkmodelle bereitstellt, die TU Graz die Lernalgorithmen beisteuert, und das SimLab Neuroscience am Forschungszentrum Jülich das Berechnen auf den erforderlichen Hochleistungsrechnern ermöglicht. In einer weitläufigeren Forschungs Kooperation erstreckt sich diese Arbeit auch auf den Pilzkörper von Insekten (University of Sussex), Metaplastizität (Universität Bern), mathematische Optimierung (RWTH Aachen) und neuromorphe Hardware (Ruprecht-Karls-Universität Heidelberg). In diesem Projekt tragen die Mitglieder des Bernstein Netzwerks Computational Neuroscience zur Entwicklung Künstlicher Intelligenz bei, unter Einbezug von Lösungen, die die Natur gefunden hat, um unserem Gehirn so anpassungsfähig zu machen.

/S. van Albada; A. Korcsak-Gorzo; A. Yegenoglu; W. Klijn; A. van Meegen; S. Diaz-Pier; A. Peyser, Forschungszentrum Jülich/

How can Machines Learn to Learn?

Transfer of the Brain's Learning Strategies into Machine Applications

At the Bernstein Center for Computational Neuroscience (BCCN) Berlin, Klaus Obermayer works on the basics of information processing in biological systems. He is fascinated by the complexity of the brain and the question whether machines could work – and learn – following similar principles.

His research group chiefly focuses on pattern recognition and the learning of correlations on the basis of sample data sets. Obermayer and his team develop methods of Machine Learning applied in image and signal processing with a particular focus on biomedical data. It is interesting to note that the brain 'works' with pattern recognition, interprets these findings and then develops the corresponding algorithms very flexibly on the basis of a small amount of sample data. Machines lack this flexible capability. Solutions are called for. The research team is also interested in the role of reward and punishment signals in learning processes, the so-called 'reinforcement learning'. Here, the human brain represents the main model to develop learning processes for machine applications.

The learning process in the brain is controlled by molecules – that of an artificial network is not. The research of learning rules for artificial neural networks inspired by neuromodulators, such as the neurotransmitters dopamine or acetylcholine, thus represents a very important basis. The mechanistic approaches of machines and the human brain will always differ, yet, as much as this remains a fact, researchers are convinced that the principles underlying the learning processes can be transferred.

Spiking Neural Networks that Learn to Learn

Although learning has long captured the attention of neurobiology and computer science, these fields have diverged, resulting in independent breakthroughs: For instance, neurobiology has yielded insights about brain architecture and plasticity, while computer science has independently developed Deep Learning. Recently, these advances are starting to be linked, promising a more thorough understanding of human learning, and development of better learning algorithms.

One example in this direction is 'learning to learn' (L2L), a well-known approach from Artificial Intelligence and Machine Learning, enabling a system to learn an unseen task from only a few examples given prior training on the corresponding task family. Wolfgang Maass and colleagues at the Technical University of Graz developed a framework for applying L2L methods to spiking neural networks. In L2L, learning is decomposed into two loops (or sets of parameters): an inner loop in which a network learns specific tasks from the same family, and an outer loop which updates hyperparameters to improve the network's general learning capacity. The outer loop uses optimization algorithms like evolutionary strategies, filtering, and biological reformulations of backpropagation, among others.

The parallels between this outer optimization and the brain's optimization by evolution prompt the question: Are the structures and functions emerging in these trained neural networks similar to the anatomy and physiology of the brain? We investigate this idea in a joint effort between Institute of Neuroscience and Medicine (INM-6) Computational and Systems Neuroscience at the Forschungszen-

Klaus Obermayer is particularly committed to training young scientists. Many doctoral students in the graduate program Computational Neuroscience at the BCCN Berlin graduated under his guidance. Their doctoral theses for instance, investigated modelling of behavioral changes, which are due to alcohol abuse, with regard to reinforcement learning. An education in this field not only brings forward excellent scientists, but also very well-trained employees in the fields of data science, Machine Learning and Artificial Intelligence. Some of the program's graduates have founded start-ups or work as data scientists in industry.



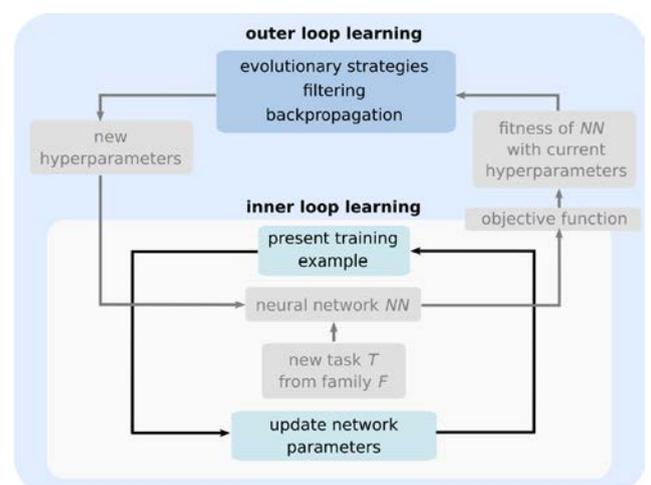
Raphael Holca-Lamarre, alumnus of BCCN Berlin: "During my doctoral thesis at the Bernstein Center Berlin, I learned everything I needed to set up my start-up *Mimica* (mimica.ai): deep specialist knowledge, good presentation skills to get the necessary funding and structured work routines." (© mimica)

Over the past decades, concepts from Artificial Intelligence and Machine Learning fertilized the neurosciences and led to new insights. Now is the time to use these advances in neuroscience to develop a novel type of learning machines.

/K. Obermayer, TU Berlin/ M. Franke, BCCN Berlin/ cd/

trum Jülich, providing biologically structured neural network models, the TU Graz, contributing learning algorithms, and the SimLab Neuroscience, enabling the required high-performance computing. In a larger collaboration, this work extends towards the insect mushroom body (University of Sussex), metaplasticity (University of Bern), mathematical optimization (RWTH Aachen University) and neuro-morphic hardware (Heidelberg University). In this project, members of the Bernstein Network Computational Neuroscience contribute to the development of Artificial Intelligence, incorporating solutions nature has found for rendering our brains highly adaptable.

/S. van Albada; A. Korcsak-Gorzo; A. Yegenoglu; W. Klijn; A. van Meegen; S. Diaz-Pier; A. Peyser, Forschungszentrum Jülich/



Grenzgänger zwischen Forschung und Crossing

Interview mit Florian Röhrbein Alfred Kärcher SE & Co. KG, Intelligent Systems

10

Herr Röhrbein, Sie sind ausgewiesener Experte der Robotik. Seit knapp einem Jahr arbeiten Sie für die Firma Kärcher. Was genau ist Ihre Aufgabe?

Kärcher stellt ja Reinigungsgeräte in allen Größenordnungen her, vom kleinen Staubsauger bis zur kommunalen Kehrmaschine. Bei uns steht die Robotisierung eines großen Teils der Produktpalette an – für mich sehr spannende Zeiten.

Somit sind Sie als erfolgreicher Forscher in die Welt der Industrie gewechselt. Provokant formuliert: Haben Sie die Seiten gewechselt? Oder haben Sie den Sprung geschafft?

(schmunzelt) Ich habe die Seiten in der Tat schon öfter gewechselt und das passiert vielleicht viel zu selten. Meist machen die Leute nach der Promotion diesen Sprung. Es ist aber selten, dass die Leute wieder an die Universität zurückkehren und dann nochmal woanders hinspringen. Ich war vier Jahre lang bei Honda, bin dann wieder zurück an die Universität, zuerst New York, dann München und bin jetzt wieder auf die andere Seite gesprungen – wobei diese Seiten gar nicht so verschieden sind. An der Uni war ich in Lehre und Forschung, hier mache ich jetzt Forschung und Entwicklung.

Was uns zum nächsten Thema führt: Der Ruf nach einer engeren Verflechtung zwischen Industrie und Forschung wird immer lauter. Wie sehen Sie das?

Das trifft einen ganz essentiellen Punkt. Im globalen Maßstab ist die universitäre KI-Forschung in Deutschland ganz hervorragend und international in der Spitzengruppe; woran es aber mangelt, ist die Kapitalisierung all dieser Forschungsergebnisse – sprich Ausgründungen, Start-Ups oder Venture Capitalists. Hier sieht es im Hinblick auf die Umsetzung in Produkte oder generell den Transfer in die Anwendung weniger gut aus.

Dass der Technologietransfer von der Forschung in die Industrie so schlecht funktioniert, hat eine ganze Reihe von

Gründen, zum Beispiel die unterschiedlichen Belohnungssysteme. Im Wissenschaftsbetrieb wird man durch Publikationen oder Drittmittelinwerbung belohnt. Das ist in der Industrie vollkommen irrelevant. In der Industrie kommt es darauf an, dass ein Verfahren in 99,9% der Fälle funktioniert, wohingegen in der Forschung oft der prinzipielle Nachweis, dass es gelingen kann, im Vordergrund steht. Solche systeminhärenten Unterschiede zu überwinden und die Kluft an dieser Stelle kleiner zu machen, funktioniert am besten durch den Austausch von Personen. Das muss nicht im mehrjährigen Wechsel geschehen, wie in meiner Vita – das können auch Kooperationen sein, denn Projekte, die diesen Austausch fördern, sind deutlich erfolgreicher, als andere Kooperationsprojekte.

Was müsste sich denn Ihrer Meinung nach ändern? In den USA scheint die Wertschöpfungskette relativ einfach zu funktionieren. Stehen wir uns in Deutschland, weil bei uns Datenschutz großgeschrieben wird, selbst im Weg?

Ich glaube eher das Gegenteil ist der Fall. Gerade Aspekte des Datenschutzes zeichnen uns aus und dort können wir eine Vorreiterrolle spielen – vor allem in der KI. Es gibt inzwischen an den Universitäten viele Gründungszentren und Kurse mit denen man den NaturwissenschaftlerInnen und IngenieurInnen mit betriebswirtschaftlichem Know-how beiseite steht, so dass sie den Schritt in eine Unternehmensgründung wagen können. Da hat sich in den letzten Jahren viel getan.

Ich sehe die Schwierigkeit momentan an einer späteren Stelle, nämlich dann, wenn es darum geht, Geld einzuwerben, um expandieren zu können. Das funktioniert in Deutschland im Moment eher schlecht. Deshalb zieht es viele Leute in die USA, vor allem an die Westküste, weil man da sehr viel leichter Geld bekommt. Und es macht auch nichts, wenn man mit seinem Start-Up scheitert. Dann versucht man es noch einmal. Ich glaube es ist die



Stelle der Finanzierung, die bei uns noch sehr unterentwickelt ist.

Als globales Unternehmen investiert Kärcher in einige Initiativen an dieser Schnittstelle. Wie stark sehen Sie Ihr Unternehmen mit der Forschung verflochten? Erleben Sie einen Culture Clash zwischen Forschung und Industrie?

Wir sind da ganz gut aufgestellt. Wir haben einen zentralen Bereich F&E mit über 1000 Mitarbeitern. Ich selbst leite die Arbeitsgruppe Intelligente Systeme und würde sagen, dass sich die Arbeitsweise meiner Gruppe nicht groß von einer universitären Arbeitsgruppe unterscheidet. Hier erlebe ich keine unterschiedlichen Kulturen. Sonst würde es mir auch nicht so leicht fallen, von der einen Seite zur anderen zu wechseln. Die Verflechtung kann aber sicher noch weiter ausgebaut werden und das machen wir auch sehr gerne, gerade auch im Bereich der neuen Cyber Valley Initiative.

Im Cyber Valley sind auch ForscherInnen des Bernstein Netzwerks und des Bernstein Zentrums Tübingen sehr stark involviert. Ist das Cyber Valley in ihren Augen eine Art ‚Hoffnungsträger‘ im Bereich KI/ ML?

Es ist auf jeden Fall toll, dass es diese Initiative gibt. Man kann ja immer kla-

Industrie

Borders between Science and Industry



© TU Munich

Mr Röhrbein, you are a renowned robotics expert. A year ago, you started to work for Kärcher. What exactly does your work entail?

Kärcher manufactures cleaning equipment of all sizes, from small vacuum cleaners to municipal road sweepers. Currently, a large part of the product range needs to be equipped with robotic parts – a very exciting task for me as a robotics expert.

Hence, you moved into the world of industry as a successful researcher. To put it provocatively: have you changed sides? Or would you say you succeeded in taking the leap?

(smiles) In fact, I have changed sides several times before, which is still quite uncommon. Usually, people take this step after their doctorate. But people don't often return to university and then change all over again. I was with Honda for four years, then I went back to university, first New York, then Munich and now I returned to industry again – yet, these sides are not as different as they may seem. At university, I was teaching and researching, here I am working in research and development.

Which leads on to another issue: the call for closer integration between industry and research is getting louder. What is your perspective?

This is an essential point. On a global scale, AI research at German universities is outstanding and internationally ranked in the top group; but our researchers do not capitalize on their outstanding results – in other words, we lack spin-offs, start-ups or venture capitalists. The situation here is less favorable with regard to the implementation of ideas into products or the transfer into applications in general.

There are a number of reasons why the

transfer of technology from research to industry does not work well, one reason being the different reward systems. In science, people are rewarded with publications or third-party funding. This is completely irrelevant in industry. In industry, a process must work in 99.9% of all cases, whereas in research, it is the proof of principle that counts. Overcoming such system-inherent differences and narrowing the gap at this point works best through exchanging people. This does not need to be over large periods of time – as in my case – it can also be within cooperations, since projects which promote this kind of exchange are much more successful than others.

How can science and industry cooperate more closely? In the USA, this seems to be relatively simple. Do we, in Germany, stand in our own way because we put a great emphasis on data protection?

I think rather the opposite is the case. Data protection, in particular, is a sign of distinction and we can play a pioneering role – especially in AI. There are many start-up centers and courses at the universities, which support scientists and engineers to gain business management know-how. This might help the step into a business start-up. A lot has happened in recent years.

I see the difficulty on a larger scale, when it comes to raising funds. Currently, this is not working well in Germany, which is why many people are attracted to the USA, especially the West Coast, where it's much easier to get start-up funding. Also, it doesn't matter if your start-up fails. Then you simply try again. I think it is the financing of ideas that is still very underdeveloped in our country.

As a global company, Kärcher invests in a few initiatives in this context. How closely is your company intertwined with research? Are you experiencing a culture clash between research and industry?

We are quite well organized and staffed in this respect. We have a central R&D department with over 1000 employees. I lead

the Intelligent Systems group. I wouldn't say that my team works differently than a university group. I am not experiencing a culture clash here. Otherwise I wouldn't have found it so easy to change sides. Having said that, these interconnections can be expanded further. This is what we intend to do, especially with regard to the new Cyber Valley Initiative.

Researchers from the Bernstein Network and the Bernstein Center Tübingen are also strongly involved in the Cyber Valley. Does the Cyber Valley carry the hopes of the future in the field of AI/ML?

It is definitely great that this initiative exists even though we might still complain that it doesn't suffice. China is certainly working with a much higher intensity on these issues. But it is good to have the Cyber Valley now. Just recently, in my position as the company's AI strategist, I hosted a start-up company in Tübingen to get some strategic input. I would like to use such connections more often in order to establish a close network between Kärcher and research institutions.

This was partly why the company wanted me. I am also well-connected in the European robotics scene. In Brussels, there are various topic groups in the field. I lead the topic group on 'Bio-inspired Robotics'; naturally, I use these network contacts to advance AI and robotics here at Kärcher.

Currently, a hotly debated issue is the shortage of highly qualified workers. What is your experience with regard to young scientists who come straight from university?

I have only had very positive experience with young scientists. In neurorobotics, there are people who are specialized in one area, but they also enjoy thinking outside the box. Especially in bioinspired robotics, one must be open to other ways of thinking, different terminologies and different approaches. This is also one of the key aspects of computational neuroscience, where research can only work cross- and interdisciplinary, because one of the chief goals is to implement findings

gen, dass auch solche Förderinitiativen nicht ausreichend sind. China macht das um viele Größenordnungen intensiver. Aber es ist gut, dass wir das Cyber Valley jetzt haben. Ich hatte gerade kürzlich (in meiner Eigenschaft als Verantwortlicher für die KI Strategie des Unternehmens) ein Tübinger Start-Up zu Gast, um mich strategisch von extern beraten zu lassen. Solche Verflechtungen möchte ich gerne noch öfter einsetzen, um ein enges Netzwerk zwischen Kärcher und Forschungseinrichtungen zu knüpfen. Das war auch einer der Gründe, warum man mich in das Unternehmen geholt hat, denn ich bin auch auf europäischer Ebene ganz gut vernetzt. In Brüssel gibt es verschiedene Topic Groups im Bereich Robotik. Ich leite die Topic Group zum Thema ‚Bio-inspired Robotics‘ und nutze auch diese Netzwerkkontakte, um die Themen KI und Robotik hier bei Kärcher voranzubringen.

Fachkräftemangel ist ja eines der aktuell diskutierten Themen. Wie ist Ihre Erfahrung im Hinblick auf den Nachwuchs, der direkt aus der Wissenschaft kommt?

Also ich habe durchweg nur sehr positive Erfahrung mit NachwuchswissenschaftlerInnen gemacht. In der Neurorobotik finden sich Leute, die auf der einen Seite Spezialisten sind aber auch ganz stark das Bedürfnis haben, über den Tellerrand hinauszuschauen. Gerade in der bio-inspirierten Robotik muss man über das durchschnittliche Maß hinaus gegenüber anderen Denkweisen, anderen Terminologien und auch anderen Herangehensweisen aufgeschlossen sein. Das ist ja auch einer der Kernpunkte der Computational Neuroscience, in der man in einem Schnittstellenbereich forscht. Denn hier geht es unter anderem darum Erkenntnisse aus den Neurowissenschaften für kognitive künstliche Systeme, zum Beispiel Roboter, nutzbar zu machen.

In der Computational Neuroscience wird schon seit den 1990ern mit tiefen neuronalen Netzen gearbeitet und geforscht. Nun ist KI aber doch ein etwas weiteres Feld als das Maschinelle Lernen. Wo sehen Sie die Marktchancen im Bereich KI für Deutschland und Europa im globalen Wettbewerb?

Im Bereich KI gibt es natürlich tausendfache Möglichkeiten. Man muss aber auch aufpassen, dass dieser Bereich nicht überhitzt, dass man nicht zu hohe Erwartungen schürt. Das ist in der Vergangenheit schon öfter passiert, gerade im Bereich der klassischen KI.

Ich denke, Unternehmen sollten daher vorsichtig agieren wenn sie aus ihren Produkten smarte Produkte machen möchten und KI auf ihre Geschäftsprozesse loslassen. Da gibt es schon erste Enttäuschungen – gerade im Bereich Predictive Maintenance, wo man sich durch recht aufwendige KI Methoden viel versprochen hat aber der erhoffte Nutzen dann doch ausgeblieben ist. Ich glaube, wir müssen ein wenig aufpassen, dass dieser Hype nicht zu einer Frustrationswelle führt.

Wie Sie schon angemerkt haben ist Künstliche Intelligenz mehr als Maschinelles Lernen. Das wird häufig sehr verkürzt dargestellt in der öffentlichen Debatte. Meines Erachtens sind wir in Deutschland in der klassischen KI sehr stark aufgestellt und ich denke, dass diese Methoden wieder wichtig werden in naher Zukunft – denn was lernende Systeme typischerweise weniger gut können, ist, zu erklären, warum sie zu diesen oder jenen Schlüssen gekommen sind. Hier kann man klassische KI Verfahren gut einsetzen – oder noch besser hybride Ansätze, in denen man diese beiden Methoden miteinander kombiniert.

Könnten Sie ein griffiges Beispiel nennen?

Nehmen wir mal die medizinische Anwendung von einer Vorselektion von MRT-Bildern mit Krebsverdacht. Man hat ein neuronales Netz, das man mit Millionen von Beispielen trainiert und das ganz toll funktioniert; an dieser oder jener Stelle zeigt das System an, Hinweise für Krebs entdeckt zu haben. Der Arzt muss nun eine Entscheidung treffen aber auf dem MRT-Bild ist für ihn zunächst nichts zu erkennen. Deshalb möchte er genauer wissen, warum die KI zu ihrer Schlussfolgerung gekommen ist. Vielleicht stimmt es und man kann als Arzt dazu lernen aber ohne diesen Hintergrund mag man den Vorschlägen dieses Systems vielleicht nicht folgen.

Es geht also im Grunde um die Nachvollziehbarkeit?

Ja, bei Expertensystemen, wie man früher KI Systeme nannte, gab es immer eine sog. ‚Selbsterklärungskomponente‘, bei der man die Schritte, die das Programm gemacht hat, nachvollziehen konnte. Und das kann man bei lernenden Systemen in der Regel nicht – auf jeden Fall jetzt noch nicht auf eine aussagekräftige Art.

Zum Schluss noch eine provokante Frage. Werden wir in Europa zwischen der Vormachtstellung der beiden großen Player

im Spiel, China und den USA, zerrieben? Oder schaffen wir es wie die Künstliche Intelligenz AlphaGO und setzen uns auf eine Linie, die vom Regelwerk nicht vorgesehen ist?

Ja, das ist ein schöner Vergleich. Wir sollten alles daran setzen dies zu schaffen und wir haben dafür exzellente Voraussetzungen, gerade was die Ausbildung und die universitäre Forschung in diesem Bereich betrifft, aber auch in Bezug auf Maschinendaten. Wir sollten das Gebiet der KI als eine große Chance begreifen. Allzu gerne beklagen wir, dass es den großen Firmen in den USA eben nur um den Profit geht und dass die Firmen in China skrupellos mit den Daten umgehen. Wir sollten es aber nicht bei dem Beklagen lassen, sondern sollten alles dran setzen dem etwas entgegen zu setzen, eben in Europa eine KI Industrie aufzubauen, die mitspielen kann. /cd/

from the neurosciences into artificial cognitive systems such as robots.

Computational neuroscience has been working with deep neural networks since the 1990s. However, AI is a somewhat broader field than Machine Learning. Where do you see the market opportunities in the field of AI for Germany and Europe in terms of global competition?

There are, of course, thousands of opportunities in the field of AI. But we have to make sure that it does not overheat, that you don't raise expectations too high. In classical AI, this has happened many times before. I think companies should therefore act with care when turning their products into smart products or when optimizing their business processes with AI. There are already disappointments with such undertakings – especially in the area of predictive maintenance, where the expectations of elaborate AI methods were high and the hoped-for customer benefit failed to take effect. I think we have to be a little careful that this hype does not lead to a wave of frustration.

As you already mentioned, Artificial Intelligence entails more than Machine Learning. This is often presented in a very abbreviated way in the public debate. I think we are very strong in classical AI in Germany, and I believe that these methods will gain importance in the near future because learning systems are typically less good at explaining why they came to this or that conclusion. Here, it is best to use classical AI methods, or, even better, hybrid approaches, in which these two methods are combined.

Could you give an example?

Let's take the medical application of preselecting MRI images which might indicate cancer. Imagine we have a neural network trained with millions of examples. It is working very well; at this or that

point the system indicates to have detected cancer. Now, the Medical Doctor (MD) should be in the position to make a decision. Yet, the MRI image may not clearly indicate cancerous cells. Naturally, the MD would like to know exactly why the AI system came to this conclusion. It might be correct and help the MD to learn from the results but without knowing the background one might not be inclined to follow the suggestions of this system.

So, it's basically about traceability?

Yes, in expert systems, as these AI systems used to be called, there was always a so-called 'self-explanatory component' where you could track the steps the program took. And this is usually not possible with learning systems – at least not in a conclusive way.

To finish, a provocative question. Are we in Europe being crushed between the two big players in the game – China and the USA – or do we succeed, like the Artificial Intelligence AlphaGO did, and put our token on a line that is not provided for by the rules?

This is a nice comparison. We should do everything in our power to achieve this and we have excellent prerequisites for it, particularly with regard to education and university research but also in relation to machine data. We should see the field of AI as a great opportunity. Often, we are all too happy to complain about the profit orientation of big companies in the USA or the unscrupulous ethics of Chinese companies. We should not, however, leave it at complaining. We should do everything in our power to build up an AI industry in Europe that can join in the playing of the game. /cd/

Tübingen AI Center

BMBF Initiative mit nachhaltiger Zielvorstellung

Matthias Bethge ist Professor für Computational Neuroscience und Maschinelles Lernen an der Eberhard-Karls-Universität Tübingen. Er leitet das Tübingen AI Center, das als eines der vier nationalen Kompetenzzentren für Maschinelles Lernen vom Bundesministerium für Bildung und Forschung (BMBF) gefördert wird und ist Mitbegründer der European Laboratory for Learning and Intelligent Systems (ELLIS) Society.

14



Die Szene einer Tübinger Flusslandschaft erinnert durch Neural Style Transfer an ein van Gogh-Kunstwerk. /deepart.io/

Maschinelles Lernen ist das Herzstück einer technologischen und gesellschaftlichen Revolution. In den letzten zehn Jahren haben sich aus der Grundlagenforschung heraus viele technologische Innovationen und Anwendungen ergeben, die Wirtschaft und Gesellschaft überall auf der Welt verändern werden. Das lässt leicht vergessen, dass die derzeitigen Methoden des Maschinellen Lernens noch in vielerlei Hinsicht sehr beschränkt sind: sie generalisieren oft nicht auf neue Situationen, benötigen sehr große Datenmengen für das Training, entwickeln kein Verständnis für die kausalen Zusammenhänge ihrer Umwelt und der Weg zu den Entscheidungen ist kaum nachvollziehbar. Die Lösung dieser Defizite und die Entwicklung robuster und kausaler KI-Systeme versprechen einen großen Gewinn für die Gesellschaft, denn Robustheit und Kausalität haben einen doppelten Nutzen: Erstens brauchen wir diese Konzepte, damit Maschinen auch mit relativ wenig Daten in neuen Situationen richtige Entscheidungen treffen können. Zweitens bilden sie die Grundlage für die Erklärbarkeit, Transparenz und Fairness von Entscheidungen.

Wir erforschen die neuronale Bildverarbeitung im Gehirn und in Maschine. Unsere Ergebnisse haben maßgeblich zu den aktuellen Entwicklungen des Deep Learnings, wie z.B. dem Neural Style Transfer beigetragen (siehe Bild). 2017 habe ich an der Universität Tübingen die Leitung der Cyber Valley Unit for AI übernommen, um die Rolle der Wissenschaft als Innovationsmotor und Orientierungshilfe in Wirtschaft und Gesellschaft zu stärken. Schon während des Aufbaus des Start-Ups DeepArt in 2015 und 2016, ist mir dieses Thema sehr wichtig geworden. 2018 habe ich mit Layer7 AI ein Start-Up ins Leben gerufen, das den neuesten wissenschaftlichen Kenntnisstand direkt in Unternehmen einbringt. Um die Schlagkraft der KI-Forschung in Europa im weltweiten Wettbewerb nachhaltig zu verbessern, habe ich zusammen mit Kollegen, wie Bernhard Schölkopf, die European Laboratory for Learning and Intelligent Systems (ELLIS) Society mitbegründet. Viele Top-WissenschaftlerInnen aus ganz Europa haben sich dieser Initiative bereits angeschlossen.

Das Tübingen AI Center ist ein Verbundprojekt der Universität Tübingen und dem Max-Planck-Institut für Intelligente Systeme und ist eingebunden in das Cyber Valley, in dem Amazon und Bosch große Forschungszentren in unmittelbarer Nähe zu den Uni- und Max-Planck-Gruppen aufbauen. An dem Kompetenzzentrum wird an robusten Lernsystemen geforscht, die sich der natürlichen Intelligenz von biologischen Systemen annähern sollen. Die Forschung des Tübingen AI Centers teilt sich in fünf Bereiche auf: (1) Lernen, (2) Wahrnehmen, (3) Handeln (den drei Grundlagen aller intelligenten Systeme) sowie (4) medizinische Anwendung und (5) Privatsphäre, Fairness und Transparenz im ML; letzteres dient vor allem der Stärkung des gesellschaftlichen

Nutzens. Ein Beispiel für das Anwendungspotential robuster Lernsysteme ist das ML-City Projekt, das das Tübingen AI Center zusammen mit der Robert Bosch GmbH und der Stadt Tübingen durchführt. Hier werden Verkehrsströme im Stadtbereich durch Kameras auf Ampeln erfasst, um sie mit ML-Algorithmen zu analysieren und zu optimieren, ohne dabei die Privatsphäre der Verkehrsteilnehmer zu verletzen. Weitere Anwendungen reichen von Aufgaben in der Computer Vision, zum Beispiel der Abschätzung der menschlichen Haltung bis hin zu wichtigen Beiträgen in den Neurowissenschaften, der Medizin (HIV-Forschung), der Behandlung von Unsicherheiten beim Deep Learning für medizinische Anwendungen und Fortschritten bei der Erhaltung der Privatsphäre von ML.

Das Tübinger AI Zentrum bringt mehr als 25 Projektleiter zusammen, die insgesamt ca. 150 DoktorandInnen ausbilden. Zudem engagieren sich Postdocs und Studierende des Tübingen AI Center bei der Ausgründung von Start-Ups und in gesellschaftlichen Projekten wie dem Bundeswettbewerb Künstliche Intelligenz (BwKI), an dem in diesem Jahr bereits mehr als 2500 SchülerInnen teilgenommen haben und derzeit 135 Teams selbsterdachte Projekte verfolgen. Darüber hinaus arbeitet das Tübingen AI Center mit dem Tübinger Verein ‚Women in Tech‘ und der Organisation ‚IT-4-Kids‘ zusammen, um GrundschülerInnen die Grundlagen der Programmierung näher zu bringen. Es zeigt sich, dass das Interesse für diese Kurse bei Mädchen genauso groß ist wie bei Jungs. Auf diese Weise fördert das Kompetenzzentrum das Verständnis für KI-Technologien in der nächsten Generation, die so ganz früh für dieses zukunftsweisende Thema begeistert werden können.

Auf lange Sicht wollen wir das Tübingen AI Center zu einer neuartigen öffentlichen Forschungseinrichtung entwickeln, die durch international sichtbare Spitzenforschung die weltweit besten WissenschaftlerInnen anzieht, kontinuierlich rund 250 DoktorandInnen ausbildet und positiv in Gesellschaft und Wirtschaft hineinwirkt. Um dies zu erreichen, arbeiten wir und mit Top KollegInnen, wie Bernhard Schölkopf Michael Black, Peter Dayan, Andreas Geiger, Matthias Hein, Philipp Hennig oder Ulrike von Luxburg und anderen Top Forschungsstandorten, wie der ETH Zürich, zusammen. Die Zukunft wird maßgeblich durch neue Technologien gestaltet, die nicht an Ländergrenzen halt machen. Eine besonders schlagkräftige Rolle spielt dabei das Maschinelle Lernen, das gerade dabei ist, Industrie und Gesellschaft global im rasanten Tempo zu verändern. Damit Europa die Zukunft gestalten kann, brauchen wir eine europäische Exzellenz-Institution, die in der Lage ist, Spitzenforscher aus aller Welt anzuziehen und in Europa tätig werden zu lassen. Das ist das Ziel der ELLIS Initiative. Vom Kompetenzzentrum erhoffe ich mir, dass es mit dazu beitragen kann, dieses Ziel zu erreichen.

/M. Bethge; M. Lam, Tübingen AI Center/ cd/

Tübingen AI Center

Publicly Funded Initiative with Sustainable Goals

Matthias Bethge is Professor for Computational Neuroscience and Machine Learning at the University of Tübingen. He is head of the Tübingen AI Center, which is funded by the Federal Ministry of Education and Research (BMBF) as one of four national Competence Centers for Machine Learning. He is co-founder of the European Laboratory for Learning and Intelligent Systems (ELLIS) Society.

Machine Learning is at the heart of a technological and societal revolution. In the last ten years, basic research sparked many technological innovations and applications that are changing the economy and society worldwide. However, current methods of Machine Learning are still very limited in many respects: they often do not generalize to new situations, they require very large amounts of data for training, they do not develop an understanding of how their environment functions and their decisions can be changed with minimal perturbations. The solution of such deficits and the development of robust and causal AI systems promises a great benefit for societies, since robustness and causality promise a twofold improvement: First, these concepts can enable machines to make correct decisions in new situations even with relatively little data. Second, they provide the basis for explainability, transparency and fairness of decisions.

We investigate visual processing in brains and machines and we have contributed significantly to current developments in Deep Learning, such as neural style transfer (see picture on the left). Since 2017, I am leading the Cyber Valley Unit for AI at the University of Tübingen which aims at strengthening the role of science for innovation of industry and orientation for society. I became particularly interested in this topic, when co-founding the start-up DeepArt in 2016. In 2018, I co-founded Layer7 AI, a start-up that puts companies in touch with top Machine Learning researchers and develops custom-made AI solutions. With the goal to build a sustainable eco-system for global impact and competitiveness of European AI research, I joined other colleagues, like Bernhard Schölkopf, in founding the European Laboratory for Learning and Intelligent Systems (ELLIS) Society. Many top scientists from all over Europe have already joined the initiative.

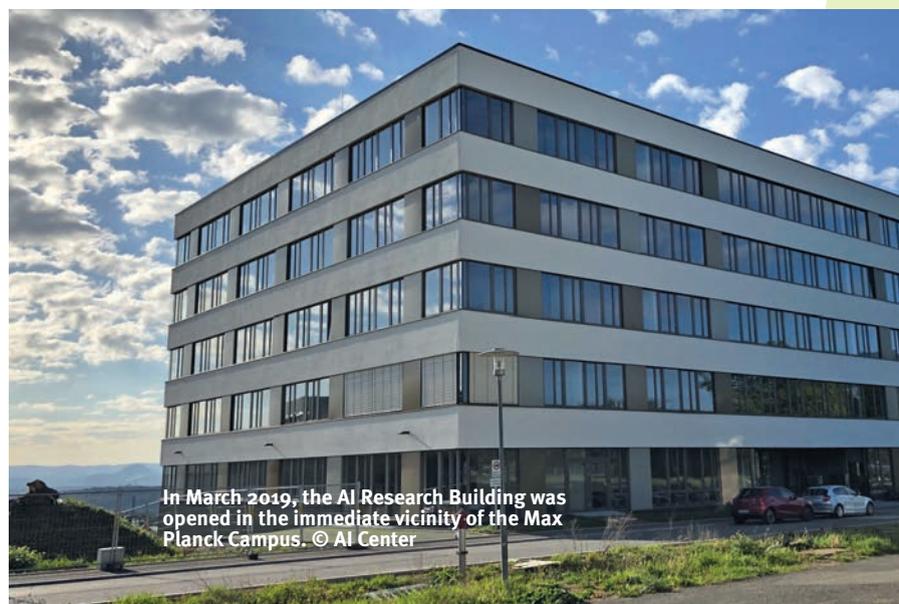
The Tübingen AI Center is a joint project between the University of Tübingen and the Max Planck Institute for Intelligent Systems. It is a central part of the Cyber Valley eco-system that attracted Amazon and Bosch to establish large research centers in the immediate vicinity of the university and Max Planck research groups. The research focus of the Competence Center is to build robust learning systems that approach the robustness of natural intelligence as evident in biological systems. The research projects are divided into five areas: (1) Learning, (2) Perception, (3) Action (the three basics of all intelligent systems) as well as (4) Medical Application and (5) Privacy, Fairness and Transparency in ML. The applied research topics are particularly beneficial for society. A good example of the application potential of robust learning systems is the ML-City project: Together with BOSCH and the Tübingen City Council, the Tübingen AI Center is going to study and optimize traffic flow in urban areas with privacy-preserving ML algorithms. Further applications range from computer vision tasks, such as human pose estimation, to important contributions in the neurosciences, medicine (HIV re-

search), the treatment of uncertainties in Deep Learning for medical applications.

The Tübingen AI Center brings together more than 25 project leaders who train about 150 PhD students. Post-docs and students at the Tübingen AI Center are also pursuing start-ups and projects like the German National Competition for Artificial Intelligence (BWKI), in which more than 2,500 students have already participated this year and 135 teams are currently working on their own projects. The Tübingen AI Center also cooperates with the Tübingen association 'Women in Tech' and the organization 'IT-4-Kids' to teach elementary school students the basics of programming. It turns out that the interest in these courses is equally great amongst girls as it is amongst boys. In this way, the Competence Center promotes understanding and enthusiasm for AI research and technology at an early stage of education.

The long-term perspective of the Tübingen AI Center is to become an innovative public research institution, which attracts the world's best scientists through internationally visible cutting-edge research; an institution, which trains about 250 doctoral students and has a positive impact on society and economy. Together with top colleagues like Bernhard Schölkopf, Michael Black, Peter Dayan, Andreas Geiger, Matthias Hein, Philipp Hennig and Ulrike von Luxburg, as well as top institutions, like ETH Zürich, we are collaborating on this goal. The future will be shaped to a large extent by new technologies which do not stop at national borders. Machine Learning, which is currently in the process of changing industry and society globally at a rapid pace, is already playing a particularly powerful role. For Europe's future, we need a European institution of excellence that is capable of attracting top researchers from all over the world and letting them work effectively in Europe. This is the aim of the ELLIS initiative. I hope that the Competence Center can contribute to achieving this goal.

/M. Bethge, M. Lam, Tübingen AI Center/ cd/



In March 2019, the AI Research Building was opened in the immediate vicinity of the Max Planck Campus. © AI Center

Künstliche Intelligenz nach dem Vorbild der Funktion des Gehirns

Eine Beitrag von Fred Hamker, Chemnitz

16

Die wissenschaftliche Berichterstattung dreht sich beim Thema KI nach dem Vorbild des Gehirns häufig um neurowissenschaftliche Forschungen, in denen das Gehirn in Modellen mit Millionen von Neuronen simuliert wird. Nun mag man denken, dass Modelle bestimmter Prozesse im Gehirn einfach zusammengesteckt werden können, um dieses Zusammenwirken zu beschreiben. Das funktioniert in der Regel jedoch nicht, da die potentielle Funktion eines Bereichs des Gehirns häufig nicht verstanden wird, wenn man ihn isoliert betrachtet. Außerdem können diese Modelle, auch wenn damit interessante neurowissenschaftliche Fragestellungen untersucht werden, in der Regel keinerlei konkrete Aufgaben bewältigen. Auch für das Verständnis der menschlichen Intelligenz reichen isolierte Modelle nicht aus, denn Intelligenz beruht auf dem Zusammenwirken vieler Gehirnregionen und verlangt Anpassungs- und Lernfähigkeit, damit das hohe Maß an Flexibilität erreicht werden kann, das intelligentes Handeln möglich macht.

Um besser zu verstehen, was uns mit unserem Gehirn intelligent macht, arbeiten wir an der Technischen Universität Chemnitz, eng mit ForscherInnen aus den Neurowissenschaften, der Psychologie und der Medizin zusammen. Denn anders als die Forschung der klassischen KI oder des Maschinellen Lernens, will man die Intelligenz im Gehirn verstehen und nachbilden und nicht irgendeine Intelligenz erzeugen. Ohne Daten zur Anatomie und Physiologie können diese Modelle jedoch nicht entwickelt werden.

Im Gegensatz zu Großprojekten, wie dem EU Flagship ‚Human Brain Projekt‘, folgen die Forschungen meines Teams allerdings eher einem top-down Ansatz und berücksichtigen bei der Modellbildung von vornherein die potentielle Funktion des Modells im Gehirnnetzwerk. Um intelligentes Verhalten zu verstehen, ist es deshalb erforderlich, Generalist zu sein. Erst durch das Zusammenwirken verschiedener Bausteine des Gehirns entsteht intelligentes Verhalten. Beispielsweise haben wir zusammen mit weiteren ForscherInnen aus Europa untersucht, wie wir unsere Umwelt subjektiv als stabil wahrnehmen, obwohl wir jede Sekunde etwa drei Mal unsere Blickrichtung ändern und somit das Retinabild ständigen Änderungen unterworfen ist. Das ent-

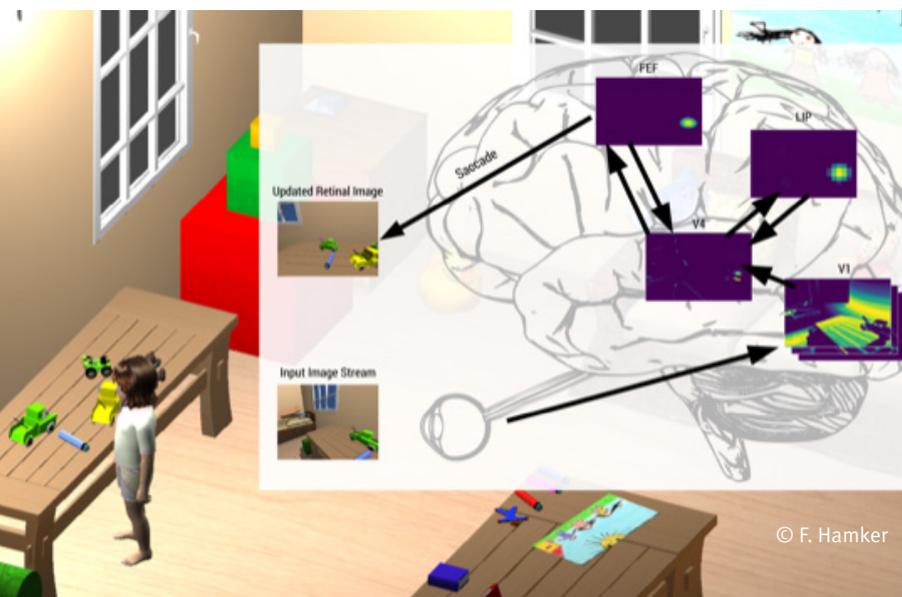
wickelte Modell legt nahe, dass die wahrgenommene Stabilität der Umwelt über das Zusammenwirken von mindestens zwei dynamischen Signalen der Augenposition und antizipativen Änderungen der Aufmerksamkeit vor einem Blickwechsel erreicht werden kann. Neben Simulationen, die experimentelle Daten replizieren, wurden auch Simulationen einer aktiv handelnden Person in virtueller Realität durchgeführt, um zu testen, inwieweit diese Modelle hilfreich für Wahrnehmung und Verhalten sein können.

Einige dieser Ergebnisse fließen nun in das Schwerpunktprogramm ‚The Active Self‘ der Deutschen Forschungsgemeinschaft (DFG) ein, worin Fragen der Selbstrepräsentation des Körpers sowie die Erzeugung eines Konzeptes der Wirksamkeit von eigenen Aktionen (Agency) untersucht werden. Dies wird möglich durch Modelle, die wir mit einem iCub-Roboter unter zusätzlicher Verwendung des Tastsinns mit künstlicher Haut verknüpfen: Denn auch wenn heutige Roboter zwar sehr faszinierend sind, haben sie kein wirkliches Verständnis von den kausalen Zusammenhängen unserer Welt. Diese wichtigen Vorarbeiten zur Modellierung dieser motorischen Zusammenhänge wurden vorab im Rahmen einer klinischen DFG Forschergruppe unter Leitung der Charité- Universitätsmedizin Berlin sowie innerhalb von deutsch-japanisch und US-deutsch-israelischen Projekten zur Erforschung der Parkinson Krankheit und des Tourette-Syndroms entwickelt.

Im Rahmen von neurowissenschaftlichen Forschungsprojekten kommen Fragen nach der Funktion und dem Zusammenwirken von Teilen des Gehirns meist erst dann auf, wenn wirklich intelligentes Verhalten durch Lernen in den Vordergrund der Modellierung gerückt wird. Meine Forschungsansätze mögen deshalb oft exotisch anmuten, weil ich durch die Brille eines Informatikers auf die Zusammenhänge blicke; sie befasst sich aber mit den zentralen Zukunftsfragen der Computational Neuroscience. Wir suchen nach neuen Computing Architekturen, die in Zukunft intelligente Agenten, wie Roboter, steuern könnten. Um junge Forscher auf dieses Themenfeld besser vorzubereiten, wurde an der TU Chemnitz in diesem Jahr der Masterstudiengang Neurorobotik eingerichtet, der auf das hochgradig interdisziplinäre, also generalistische Spektrum dieser Forschungen vorbereitet. Ich freue mich, dass ich hier federführend die neue Generation von interdisziplinären WissenschaftlerInnen ausbilden kann, um sie für die Herausforderungen der KI Forschung fit zu machen.

/F. Hamker, Technische Universität Chemnitz/

EU Projekt: Spatial Cognition,
finanziert im Rahmen des Programms ‚Future Emerging Technologies: Neuro-bio-inspired systems‘



© F. Hamker

In einer virtuellen Realität wird die Blickbewegung des Auges antizipiert. In der Folge kann die Wahrnehmung vor der Blickbewegung mit der danach fusioniert werden.

Artificial Intelligence Modelled on Brain Function

An Article by Fred Hamker, Chemnitz

Scientific reporting on the subject of AI based on brain function often revolves around neuroscientific research, in which the brain is simulated in models with millions of neurons. Thus, one might conclude that models of brain processes can simply be plugged together to get a notion of their interaction. Yet, this is a misapprehension, because most times the potential function of an area of the brain cannot be understood when viewed in isolation. Even if these models are used to investigate interesting neuroscientific questions, they are generally unable to perform specific tasks. Having said this, isolated models are not sufficient for the understanding of human intelligence, since intelligence is based on the interaction of many brain regions and requires the ability to adapt and learn in order to achieve the high degree of flexibility that makes intelligent action possible.

To better understand what makes us intelligent, we are working closely with neuroscientists, psychologists and medical researchers at Chemnitz University of Technology. Unlike classical AI research or Machine Learning, we seek to understand intelligence in the brain and reproduce it rather than generating just any kind of intelligence. These models, however, cannot be developed without data on anatomy and physiology.

In contrast to large-scale projects, such as the EU Flagship ‘Human Brain Project’, the research of my AI lab follows a top-down approach and takes the potential function of the model in the brain network into account from the very beginning. In order to understand intelligent behavior, one must be a generalist as it can only develop through the interaction of different components of the brain. Together with other researchers from Europe, we investigated, for instance, how the perception of our surroundings remains stable, even though our gaze, and thus the retinal image shifts, about three times every second. The developed model suggests that the perceived stability of the surroundings is achieved through the interaction of at least two dynamic signals of eye position and anticipatory changes of attention before a gaze shift. To test the extent to which these models can be helpful for perception and behavior, simulations of an active person in virtual reality were carried out in addition to simulations, which use experimental data.

Some of these results are now used in the Priority Program ‘The Active Self’ of the German Research Foundation (DFG), in which we investigate questions of self-representation of the body as well as the generation of a concept of the effectiveness of one’s own actions (agency). This is made possible by models which we combine with the sense of touch using an iCub robot and artificial skin. Although today’s robots are very fascinating, they have no real understanding of the causal relationships of our world. This important preliminary work to model these motor correlations was developed as part of a DFG Clinical Research Unit led by the Charité-Universitätsmedizin Berlin as well as within German-Japanese and US-German-Israeli projects to investigate Parkinson’s disease and the Tourette’s syndrome.

In neuroscientific research projects, questions about the function and interaction of parts of the brain usually arise when the issue of learning puts truly intelligent behavior into the foreground of modeling. My research may thus often seem exotic because I look at these interrelationships through the eyes of a computer scientist. Yet, it deals with the central questions of the future of computational neuroscience. We are looking for new computing architectures that could control intelligent agents, such as robots, in the future. In order to better prepare young researchers for such topics, the Chemnitz University of Technology has established a Master’s program in Neurorobotics, which focuses on the highly interdisciplinary spectrum of this research. I am pleased that my chair is in charge of training the new generation of interdisciplinary scientists to make them fit for the future challenges of AI research.

/F. Hamker, Chemnitz University of Technology/ cd/

17

Masterstudiengang Neurorobotik
TU Chemnitz



Read on

Spitzhirm, M., Dinkelbach, H.Ü., Kronfeld, Th., Nicholas, H. M., Truschinski, M., Brunnett, G., Hamker, F. H., Ohler, P., Protzel, P., Rosenthal, P., Bullinger, A.C. (in press)
“The Smart Virtual Worker - Digitales Menschmodell für die Simulation industrieller Arbeitsvorgänge.” In: Homo sapiens Digitalis. Springer.

An der Schnittstelle zwischen KI Anwendung und Entwicklung

*Ein Kurzportrait des Instituts für Neuroinformatik (INI) der Ruhr-Universität Bochum (RUB)
von Gregor Schöner*

18

Das Institut für Neuroinformatik (INI) der Ruhr-Universität Bochum (RUB) positioniert sich genau an der Schnittstelle zwischen der Theorie neuronaler und natürlicher kognitiver Systeme auf der einen und der Entwicklung neuronal inspirierter Lösungen für künstliche kognitive Systeme auf der anderen Seite. Im aktuell explosionsartig wachsenden Bereich des Deep Learning werden Prinzipien neuronaler Informationsverarbeitung vor allem im Sinne von ‚input-output‘ Funktionen genutzt, die also von sensorischer Information gesteuert, am Ausgang ‚Antworten‘ geben. Wir verfolgen dagegen den Ansatz, neuronale Prinzipien zu nutzen um eine durchgängig neuronale Form Künstlicher Intelligenz zu entwerfen. Dabei sollen also auch kognitive Leistungen wie das Planen von Handlungen, das Fällen von Entscheidungen, die Steuerung von Denkprozessen, der Aufbau von Gedächtnis und die Generierung von Bewegung mit neuronalen Prozessmodellen beschrieben und synthetisiert werden.

Dies geschieht am INI in verschiedenen Arbeitsgruppen und Projekten auf einer Reihe von Beschreibungsebenen, die von neurophysikalisch detaillierten Modellen über Modelle neuronaler Dynamik auf Populationsebene bis hin zu abstrakten Prinzipien neuronalen Lernens und Maschinellen Lernens reichen. Ein Teil unserer Arbeit konzentriert sich daher auch auf die Grundlagenforschung zur Methodenentwicklung im Bereich Machine Learning. Wir arbeiten mit Kognitions- und NeurowissenschaftlerInnen zusammen, aber auch mit Anwendern im Bereich des autonomen Fahrens und der Fahrerassistenz.

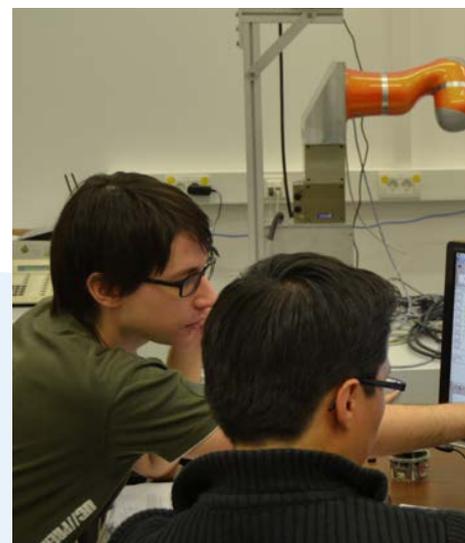
Einerseits studieren wir die räumliche Navigation in strukturierten Umwelten unter gleichzeitiger Erzeugung und Nutzung von episodischem Gedächtnis, das dabei aus Sequenzen neuronaler Zustände aufgebaut wird. Andererseits studieren wir Bewegungen, die auf Objekte gerichtet sind, wie etwa das Greifen und Handhaben von Objekten. Dabei interessiert uns auch die sprachliche Kommunikation im Kontext solcher Handlungen, also z.B. wie ein Satz wie „greife das rote Objekt links neben dem blauen“ neuronale Prozesse so anstoßen kann, dass die entsprechende Handlung ausgelöst wird.

Unser Forschungsprogramm ist mit dem klassischen Ziel der Künstlichen Intelligenz insofern verknüpft, als wir Agenten entwickeln wollen, die sich intelligent und autonom in Umwelten verhalten, die mit Menschen geteilt werden oder die menschlichen Umgebungen nachempfunden sind. Dies können sogenannte kognitive Assistenten sein, die mit Menschen im Dialog stehen, oder robotische Assistenten, die im gemeinsamen Arbeitsraum objekt-orientierte Bewegungen ausführen. Solche künstlichen kognitiven Systeme müssen kognitive Konzepte in ihrer Wahrnehmung verankern können. Ein Agent soll also wissen, wovon menschliche Benutzer in der visuellen Szene sprechen. Dies beinhaltet das Referenzproblem, also die Verknüpfung der Erkennung von Objekten mit der Steuerung von Aufmerksamkeit auf einen bestimmten Ort in der visuellen Szene, an dem sich das Objekt befindet. Dabei müssen Relationen verstanden

werden, etwa wenn ein Objekt durch eine räumliche Relation (wie „links von x“) oder eine Bewegungsrelation (wie „das y, das sich auf x zubewegt“) bezeichnet wird. Und es beinhaltet das Problem der Inferenz, etwa wenn ein Agent aus einer Sequenz von Beobachtungen und Wechselwirkungen schließt, was der Nutzer erwartet oder was als Nächstes geschieht. Unser Ansatz ist hierbei weniger, durch große Mengen von Beispieldaten Objekte und Relationen zu lernen. Uns geht es vielmehr darum, die neuronalen Prozesse, die diese Form von visueller Kognition ermöglichen, in stark rückgekoppelten neuronalen Netzen so zu realisieren, dass der gesamte Ablauf des Denkens und Handelns autonom geschieht.

Damit hoffen wir, die Bereiche der Künstlichen Intelligenz, in denen neuronale Konzepte genutzt werden können, zu erweitern: über die klassischen Prozesse der Klassifikation und Regression hinaus zur Organisation von Inferenz* und zu Sequenzen kognitiver Entscheidungen. Dies soll den künstlichen kognitiven Systemen die Anbindung an sensorische und motorische Prozesse erleichtern und solche Prozesse der Anpassung durch neuronale Methoden des Lernens zugänglich machen. Ein durchgängig neuronal konzipierter intelligenter Roboter würde also (in ferner Zukunft) aus sprachlichen Äußerungen seines Benutzers und aufgrund seiner Wahrnehmung der Szene, das notwendige Handeln erschließen und auch eigenständig umsetzen. Die Erzeugung von zielgerichteten Bewegungsabläufen in Robotern wäre also eine mögliche Anwendung für solche Formen neuronaler Prozessorganisation. Mit Methoden des Maschinellen Lernens verbinden wir diese Ideen in Szenarien, in denen Navigation und Handeln in virtuellen 3D Umgebungen simuliert werden, so dass Lernverfahren auch ohne Wechselwirkung mit menschlichen Nutzern in realer Zeit zum Training solcher Systeme genutzt werden können.

/G. Schöner, Ruhr-Universität Bochum/



At the Interface between AI Application and Development

A Short Profile of the Institute of Neuroinformatics (INI) of the Ruhr-Universität Bochum (RUB) by Gregor Schöner

The Institute of Neuroinformatics (INI) at the Ruhr-Universität Bochum (RUB) positions itself at the interface between the theory of neuronal and natural cognitive systems on the one hand and the development of neuronally inspired solutions for artificial cognitive systems on the other. Currently, the field of Deep Learning is growing explosively. It models neuronal information processing most often as ‘input-output’ mappings, where sensory information provides input and the neural networks generate ‘answers’ as their output. We aim, instead, at a pervasively neuronal form of Artificial Intelligence in which all aspects of cognition such as planning actions, making decisions, controlling thought processes, building memory and generating movement are understood and synthesized on the basis of neural process models.

At the INI, this is done in various groups and projects on different levels of description which range from neurophysically detailed models via models of neuronal dynamics at the population level to abstract principles of neuronal and Machine Learning. Part of our work is thus focused on basic research in the field of Machine Learning. We cooperate with cognitive scientists and neuroscientists, but also with R&D engineers in the field of autonomous driving and Driver Assistance Systems.

On the one hand, we study the neural processes underlying spatial navigation in structured environments and the simultaneous generation and activation of episodic memory that consists of sequences of neuronal states. On the other hand, we study arm movements that are directed at objects to grasp and then handle them. We are also interested in the verbal communication about such actions and objects, for instance how the phrase “grasp the red object to the left of the blue one” may trigger neuronal processes that generate the corresponding action.

Our research program pursues the classical goal of AI in the sense of developing agents that behave intelligently and autonomously in surroundings they share with humans or in surroundings which resemble typical human environments. Such agents may be cognitive assistants, who interact with humans, or robotic assistants, who perform object-oriented movements in a shared workspace. Such artificial cognitive systems must be able to anchor cognitive concepts in their perception. An agent should therefore know what human users are talking about in the visual scene. This entails the reference problem, that is, linking the recognition of objects to the attentional selection of their location in space, so that action can be directed at the objects. This also entails understanding relations, such as when an object is defined by a spatial relation (“left of x”) or a motion relation (“the y moving toward x”). Inference is also a challenge, when an agent deduces from a sequence of observations

and interactions which action will be required next. We do not focus primarily on learning objects and relations through large amounts of sample data. Instead, we would like to uncover the neuronal processes that enable this kind of visual cognition and implement them in strongly recurrent neuronal networks so that the entire process of thinking and acting unfolds autonomously within the neural system.

We thus aim to expand the areas of Artificial Intelligence in which neuronal concepts can be used: beyond the classical processes of classification and regression toward the organization of inference* and of sequences of cognitive decisions. This should facilitate the connection of artificial cognitive systems to sensory and motor processes and make such processes accessible to adaptation by neuronal methods of learning. A pervasively neuronal intelligent robot would thus (in the distant future) act based on what its user says and what the robot itself perceives and infers. The generation of task-oriented motion sequences in robots would thus be a possible application for such forms of neuronal process organization. We combine these ideas with methods of Machine Learning in scenarios in which navigation and action are simulated in virtual 3D environments, so that learning processes can be used in real time to train such systems even without human interaction.

/G. Schöner, Ruhr-Universität Bochum/

Recent Publications

Fang, J., Rüter, N., Bellebaum, C., Wiskott, L., & Cheng, S. The Interaction between Semantic Representation and Episodic Memory. *Neural Computation*, 30(2), 293–332

Knips, G., Zibner, S. K. U., Reimann, H., & Schöner, G. A Neural Dynamic Architecture for Reaching and Grasping Integrates Perception and Movement Generation and Enables On-Line Updating. *Frontiers in Neuroinformatics*, 11(March), 9:1–14

Richter, M., Lins, J., & Schöner, G. A neural dynamic model generates descriptions of object-oriented actions. *Topics in Cognitive Science*, 9(1), 35–47

* Inferences are steps in reasoning, moving from premises to logical consequences. Various fields study how inference is done in practice. Human inference (i.e. how humans draw conclusions) is traditionally studied within the field of cognitive psychology; artificial intelligence researchers develop automated inference systems to emulate human inference.

(Source: Wikipedia, accessed July 30, 2019)



Anwendungen

Rotorblattdefekte an Windrädern durch Hören erkennen

Maschinen zum Hören von Klang einzusetzen hat eine lange Tradition. Schon in den 1960er Jahren konnten Maschinen ausgewählte Wörter verstehen, obwohl Spracherkennung erst vor kurzem (mit dem Aufkommen robuster und vielseitiger Ansätze für mobile Geräte) eine weite Verbreitung fand. Weniger bekannt ist, dass Maschinen auch dazu verwendet werden, Fehler in mechanischen Systemen zu identifizieren, indem sie auf ihre akustische Signatur achten. Die meisten Tests wurden für rotierende Maschinen entwickelt, um die Amplitude von sog. Oberwellen zu überwachen.

Die Gruppe Audio Information Processing von Bernhard Seeber an der Technischen Universität München (TUM) beschäftigt sich mit dem Verständnis und der Modellierung des normalen und beeinträchtigten Hörsystems durch psychophysikalische Experimente sowie neuronale und phänomenologische Modelle. Solche Hörmodelle imitieren die Verarbeitung des menschlichen (peripheren) Hörsystems und reproduzieren Fähigkeiten und Grenzen des Hörens. Sie können beispielsweise vorhersagen, wie laute Geräusche wahrgenommen werden, was dazu beiträgt, die Verarbeitung in neuronalen Hörprothesen (Cochlea-Implantaten) zu optimieren. Aber können sie auch Fehler in technischen Systemen hören?

Es gibt zahlreiche Beispiele, bei denen Menschen Produkte testen, indem sie ihnen „zuhören“: Man hört, ob Glas einen Riss oder ob der PKW-Motor ein Problem hat. In der professionellen Qualitätskontrolle werden die Räder eines Zuges abgeklopft, um zu überprüfen, ob sie intakt sind. In ähnlicher Weise können interne Strukturfehler an Rotorblättern von Windkraftanlagen bei der jährlichen Inspektion erkannt werden: man lauscht dem Geräusch der Rotorblätter nach dem Hämmern. Der Klang unterscheidet sich jedoch stark von Modell zu Modell und hängt vom Ort des Testpunktes auf dem Rotorblatt ab. Erfahrene Tester kennen die gängigen Modelle und sie wissen, wo typischerweise Fehler auftreten und welche zu erwarten sind.

Auch ohne zu wissen, welchen Klang man erwarten kann, ist es nun möglich, Fehler an Rotorblättern mit einem einzigen Klopfen zu erkennen. Ein neues Testsystem nutzt robuste Merkmale, die sich aus Wahrnehmungsmodellen ableiten, wie z.B. die spezifische Lautstärke des Klangs. Es ist so zuverlässig wie menschliche Prüfer und kann außerdem die Größe des Defekts mit nur einem Klopfen vorhersagen — und das bei einem sehr kleinen Trainingsdatensatz. Entwickelt wurde das System von Gaetano Andreisek und Bernhard Seeber von der Gruppe Audio Information Processing der TUM in Zusammenarbeit mit Christian Grosse (TUM) und DTU Wind Energy.

/B. Seeber, Technische Universität München TUM/



Project

Perception-inspired testing of wind turbine blades, unter der Leitung von Bernhard Seeber, Technische Universität München

Spuren der Gedächtnisbildung und Konsolidierung

Lernen und Gedächtnisbildung gehen mit physikalischen Veränderungen im Gehirn einher. Der überwiegende Teil der Forschung konzentriert sich hierbei auf mikroskopische Veränderungen in einzelnen Nervenzellen und deren synaptischen Kontakten. Es gibt aber auch großskalige Effekte die vermutlich von netzwerkweiten Veränderungen herrühren; sie sind im Detail wenig verstanden aber selbst mit nichtinvasiven Messverfahren (z.B. Diffusionstensor, MRT) im menschlichen Gehirn nachweisbar.

Allerdings sind diese Effekte sehr klein und werden von sehr vielen anderen Signalen überlagert, so dass die Suche nach diesen Gedächtnis korrelierten Veränderungen erhebliche Schwierigkeiten mit sich bringt. Die zugrundeliegenden Daten sind extrem merkmalsreich und hoch variabel (abhängig von Probanden, experimentellem Design, Wiederholungen, etc.), so dass das Auffinden einer Gedächtnisspur ein wenig der Suche nach der Nadel im Heuhaufen gleicht. An dieser Stelle

nützen uns Machine Learning Algorithmen, speziell Klassifikatoren, die hervorragend geeignet sind, Regelmäßigkeiten in derartig unübersichtlichen Daten zu erkennen.

In der Vergangenheit haben wir Verfahren entwickelt, um lerninduzierte Effekte mit Hilfe von solchen Klassifikatoren statistisch verlässlich nachzuweisen. Gegenwärtig arbeiten wir an Methoden, die uns helfen, zu erkennen, wo diese Veränderungen auftreten, welcher Gestalt diese sind und wie sie von Lernparadigmen abhängen. Das gemeinsame Forschungsinteresse an Mechanismen der Gedächtniskonsolidierung verbindet in dieser interdisziplinären Kooperation das Feld der Psychologie und der Computational Neuroscience. Die gemeinsame Zielstellung fördert den beidseitigen Austausch zwischen experimentellen und theoretischen, inklusive Machine Learning Aspekten des Projekts und überwindet so die klassische Trennung zwischen experimenteller Wissenschaft und Statistik. Die in diesem Projekt entwickelten Techniken sind universell auf hochdimensionale Daten anwendbar und nicht auf MRT Daten beschränkt. Sie können auch wertvolle Erkenntnisse über Gedächtnis assoziierte Aktivitätsmuster mit zellulärer Auflösung liefern.

/S. Gais, Universität Tübingen/ C. Leibold, LMU München/



Applications

Hearing Defects in Wind Turbine Blades

Making machines listen to sound has a long tradition: early systems to understand selected words go back to the 1960s, though the widespread use of speech recognition came only recently with the advent of robust and versatile approaches for mobile devices. Less known is that machines are also used to identify faults in mechanical systems from listening to their acoustic signature. Most tests were developed for rotating machinery to monitor the amplitude of harmonics.

The Audio Information Processing group of Bernhard Seeber at the Technical University of Munich (TUM) focuses on understanding and modeling the normal and impaired auditory system through psychophysical experiments and neuronal and behavioral models. Such auditory models mimic the processing of the human (peripheral) auditory system and thus reproduce capabilities and limitations of hearing. They can, for instance, predict how loud sounds are perceived, which helps to optimize the processing in neuronal auditory prostheses, such as cochlear implants. But could they hear faults in technical systems?

There are numerous examples where humans test products by listening to their response: we hear if glass has a crack or if the car engine has a problem – simply by listening. In professional quality control, the wheels of a train are tapped to verify their integrity. Similarly, internal structural faults in rotor blades of wind turbines can be spotted in the yearly inspection by listening to



Jacqueline D. auf Pflüger

the blades' sound after hammering on it. However, the sound differs strongly from model to model and depends on the location of the test point on the blade. Experienced testers know the common blade models and they know where faults typically occur and which sound to expect.



Even without this prior knowledge, it is now possible to identify faults in rotor blades by a single tap. A new perception-inspired test system incorporates robust features, which derive from perceptual models, such as the specific loudness of sounds. It is as reliable as the human tester and it can additionally predict the size of the defect from a single tap – all with a very small training data set. The system was developed by Gaetano Andreisek and Bernhard Seeber of TUM's Audio Information Processing group in collaboration with Christian Grosse (TUM) and DTU Wind Energy. /B. Seeber, Technical University of Munich TUM/

Traces of Memory Formation and Consolidation

Learning and memory formation go hand in hand with physical changes in the brain. The majority of research in this area focuses on microscopic changes in individual nerve cells and their synaptic contacts. However, there are also large-scale effects that result most likely from changes in the entire network; though poorly understood in detail, they can be detected in the human brain even with non-invasive measurement methods (e.g. diffusion tensor imaging, MRI).

Yet, these effects are very small. As they are superimposed by many other signals, the search for these memory-related changes is very difficult. The underlying data reveal extremely many features and they are highly variable (depending on subjects, experimental design, repetitions, etc.). Thus, finding a memory trace is a little like looking for a needle in a haystack. At this point we use Machine Learning algorithms, especially classifiers, which are perfectly suited to detect regularities in such confusing data.

We have developed methods to reliably prove learning-induced effects statistically with the help of such classifiers. Currently, we are working on methods that help us to recognize where these changes occur, what they are, and how they depend on learning paradigms. In this interdisciplinary cooperation, psychology and computational neuroscience share the common interest of researching mechanisms of memory consolidation. Seeking a

common goal promotes the mutual exchange between experimental and theoretical aspects of the project, including Machine Learning, which eventually overcomes the classical separation between experimental science and statistics. The techniques developed in this project are universally applicable to high-dimensional data and not limited to MRI data. They can also provide valuable insights into memory-associated activity patterns with cellular resolution.

/S. Gais, University of Tübingen/ C. Leibold, LMU Munich/

Recent Publications

Jamalabadi H, Alizadeh S, Schönauer M, Leibold C, Gais S (2018) Multivariate classification of neuroimaging data with nested subclasses: Biased accuracy and implications for hypothesis testing. *PLoS Comput Biol*, 14:e1006486.

Jamalabadi H, Alizadeh S, Schönauer M, Leibold C, Gais S (2016) Classification based hypothesis testing in neuroscience: Below-chance level classification rates and overlooked statistical properties of linear parametric classifiers. *Hum Brain Mapp*, 37:1842-55.

Nach Kopfschmerzen ist Schwindel das zweithäufigste grundlegende, kardinale Symptom in der Neurologie. Im Deutschen Zentrum für Schwindel und Gleichgewichtsstörungen (DSGZ) werden die sorgfältige Anamnese und die körperliche Untersuchung durch zusätzliche Untersuchungen mit technischen Geräten ergänzt. Besonders schwierige Diagnosefälle können so von Messdaten profitieren; man benötigt aber ebenso hoch spezialisierte Ärzte, um die Signale von technischen Geräten richtig zu interpretieren.

Hier kann Maschinelles Lernen die Entscheidung eines Arztes durch die objektive Interpretation und Klassifizierung komplexer Sensordaten unterstützen. Die Nachwuchsgruppe um Seyed-Ahmad Ahmadi untersucht im DSGZ und dem BCCN München die Umsetzung modernster maschineller und tiefer Lernansätze in die klinische und neurowissenschaftliche Forschung. Künstliche neuronale Netze lernen, relevante anatomische Strukturen in medizinischen Bildern zu ‚sehen‘, ähnlich wie Menschen ihre Umgebung durch ihren visuellen Kortex wahrnehmen und verarbeiten.

Gleichzeitig verarbeiten diese Netzwerkmodelle medizinische Bilder in Sekundenschnelle, im Vergleich zu herkömmlichen Algorithmen, die hierfür im Idealfall Minuten oder gar Stunden benötigen. Anwendungsbeispiele am DSGZ sind künstliche neuronale Netze, die bei Videountersuchungen am Auge Pupille und Iris analysieren und relevante vestibuläre Ereignisse wie Sak-

kaden oder unwillkürliche Augenbewegungen wie einen Nystagmus* aufdecken.

In der Ganganalyse wird das bisherige Gehverhalten eines Patienten mittels Fußkontaktanalyse an teuren und spezialisierten Geräten wie Druckteppichen beurteilt. Auch hier werden erstmals tiefe neuronale Netzwerke eingesetzt, um die Schwankung des Oberkörpers mittels Skelett-Extraktion aus einfachen Videos in Webcam- oder Handyqualität verlässlich zu erfassen. Die Bewegung des Oberkörpers gibt Ärzten wichtige Hinweise auf die zugrunde liegenden Ursachen von Schwindel und Gleichgewichtsstörungen. Übergeordnetes Ziel ist es, Patienten ganzheitlich zu beurteilen und Ärzte bei der Diagnose zu unterstützen. Durch die Kombination wichtiger traditioneller Patientenparameter, klinischer Ergebnisse und neuartiger Parameter aus der Analyse von Augenbewegungen und Gangbildern wird ein sogenannter multimodaler Fingerabdruck jedes Patienten erstellt. Dies ermöglicht den Vergleich eines Patienten mit anderen untersuchten Patienten am DSGZ und führt letztlich zu einer schnelleren und klareren Interpretation von Ursache und Grad des wahrgenommenen Schwindels eines Patienten.

/A. Ahmadi, Technische Universität München TUM/cd/

Jüngste Publikation

Yiu, Y.-H., Aboulatta, M., Raiser, T., Opey, L., Flanagan, V.L., zu Eulenburg, P., Ahmadi, S.-A., 2019. DeepVOG: Open-source pupil segmentation and gaze estimation in neuroscience using deep learning. *Journal of Neuroscience Methods* 324, 108307. doi.org/10.1016/j.jneumeth.2019.05.016

Tiefe rekurrente neuronale Netze in der Psychiatrie. Entscheidungshilfen für klinische Einsichten und Vorhersagen

Biomedizinische Daten und Gehirndaten liegen oft als Zeitreihen vor, d.h. als Mehrfachmessungen an aufeinanderfolgenden Zeitpunkten, beispielsweise bei der funktionellen Magnetresonanztomographie (fMRT) oder der Elektroenzephalographie (EEG), bei denen Hirnsignale, die sich über die Zeit entwickeln, zu Diagnose- oder Forschungszwecken aufgezeichnet werden. Zeitreihendaten erhält man auch von Smartphones oder anderen Mobilgeräten, z.B. GPS- oder Beschleunigungssensordaten, oder aus sogenannten Ecological Momentary Assessments (EMA), mit denen Stimmungsschwankungen, Schlafqualität und viele andere psychologische Parameter bei psychiatrischen Patienten täglich über einen Zeitraum von vielen Wochen oder Monaten digital verfolgt werden. Häufig weisen solche Daten eine komplexe zeitliche Struktur auf, deren Informationsgehalt jedoch nur selten genutzt wird, obwohl er sowohl für die Differentialdiagnose als auch für die langfristige Vorhersage und individuelle Prognose des Verlaufs einer psychiatrischen oder neurologischen Erkrankung von großem Wert sein könnte.

Tiefe rekurrente neuronale Netze (Deep Recurrent Neural Networks, DRNN) sind mächtige Werkzeuge aus der Toolbox des Maschinellen Lernens, die komplexe zeitlichen Strukturen extrahieren und lernen können. Sie wurden überaus erfolgreich in verschiedenen Bereichen eingesetzt, in denen sich Signale über lange Zeit entwickeln, wie z.B. bei der Verarbeitung natürlicher Sprache, der automatischen Textvervollständigung oder der Erkennung verdächtiger Bewegungsmuster in Videosequenzen. Unsere Gruppe

nutzt und entwickelt solche Ansätze weiter, um aus fMRT-, EEG- oder Smartphone-basierten Daten dynamische Modelle einzelner Gehirne oder menschlichen Verhaltens zu lernen. Einmal auf die Gehirn- bzw. Verhaltensdaten eines einzelnen Probanden trainiert, können DRNN selbstständig neue künstliche Daten mit der gleichen raum-zeitlichen Struktur erzeugen, wie sie in den Originalableitungen bzw. -daten zu finden ist (siehe Abbildung). Das heißt, sie können das Verhalten eines einzelnen Gehirns oder Subjekts auf dieser Ebene imitieren.

Unsere Forschung konzentriert sich derzeit auf die mathematischen und algorithmischen Grundlagen, die es ermöglichen, aus solchen Zeitreihendaten Modelle herzuleiten, die die zugrundeliegenden dynamische Prozesse effizient erfassen. Weiterführendes Ziel ist es jedoch, diese Systeme für die klinische Forschung und Anwendung zu nutzen. Über die Computersimulation von zuvor trainierten DRNN-Modellen könnten längerfristige Prognosen einzelner Krankheitsverläufe ermöglicht und frühe Warnsignale zukünftiger Risiken erkannt werden. Außerdem könnten über solche Modellsimulationen die möglichen Auswirkungen therapeutischer Interventionen oder verschiedener pharmakologischer Wirkstoffe auf das Gehirn vorhergesagt werden: Zukünftig können Ärzte bei ihrer medizinischen Entscheidungsfindung durch Differentialdiagnosen und Vorschläge für personalisierte Behandlungspläne unterstützt werden.

/D. Durstewitz, G. Koppe, A. Meyer-Lindenberg, U. Reininghaus, Zentralinstitut für Seelische Gesundheit, Medizinische Fakultät Mannheim der Universität Heidelberg/

Vertigo and Balance.

Multi-modal Diagnosis with the Help of Machine and Deep Learning

In neurology, vertigo is the second most common cardinal symptom after headache. At the German Center for Vertigo and Balance Disorders (DSGZ), careful analyses of patients' medical history and physical examination are complemented with additional examinations using technical equipment. Particularly difficult diagnostic cases can benefit from measured data: at the same time, we need highly specialized physicians to properly interpret the signals from technical devices.

Here, Machine Learning can augment a doctor's decision-making through objective interpretation and classification of complex sensor data. As part of the DSGZ and the BCCN Munich, the Young Scientist Group around Seyed-Ahmad Ahmadi investigates the translation of state-of-the-art Machine and Deep Learning approaches into clinical and neuroscientific research. Artificial neural networks learn to 'see' relevant anatomical structures in medical images, similar to the way that humans see and process their environment in their visual cortex.

At the same time, these network models process medical images in a matter of seconds, compared to conventional algorithms, which ideally take minutes and often even hours for the process. Example applications at the DSGZ include artificial neural networks which analyze the pupil and iris in video examinations of the eye and reveal relevant vestibular events like saccades or involuntary eye movements such as a nystagmus.*

In gait analysis, a patient's walking pattern so far is often assessed through foot contact analysis on expensive and specialized equipment like pressure carpets. Here, too, deep neural networks are used for the first time in order to reliably record the fluctuation of the upper body by skeleton extraction from simple videos in webcam or mobile phone quality. The upper body motion gives doctors important clues about the underlying causes of dizziness and balance problems. The overall aim is to assess patients holistically and aid the physician during the diagnosis process. By combining important traditional patient parameters, clinical scores and novel parameters from eye motion and gait pattern analysis, a so-called multi-modal fingerprint of each patient is created. This allows the comparison of a patient to the entire history of examined patients at the DSGZ, ultimately leading to a faster and clearer interpretation of a patient's source and degree of the perceived vertigo.

/A. Ahmadi, Technical University of Munich TUM/

*Nystagmus is a condition of involuntary eye movement, acquired in infancy or later in life, that may result in reduced or limited vision. Due to the involuntary movement of the eye, it has been called 'dancing eyes'. (Source: Wikipedia, July 16, 2019)

Project

Deep Learning and Big Data Mining in Vestibular Multi-modal Imaging and Spatio-temporal Sensor Data, headed by Seyed-Ahmad Ahmadi, TU Munich



Deep Recurrent Neural Networks in Psychiatry. Helping medical decisions and predictions

Biomedical and brain data often come as time series, that is, multiple measurements recorded across consecutive time steps. This is the case, for instance, in functional Magnetic Resonance Imaging (fMRI), or Electroencephalography (EEG), where brain signals evolving across time and cortical volume are acquired for diagnostic or research purposes. Another example are data from mobile devices and smartphone sensors, like GPS or accelerometer data, or so-called Ecological Momentary Assessment (EMA), which is used to track fluctuations in mood, sleep quality, and many other psychological parameters in psychiatric patients, on a daily basis over a period of many weeks or months. Often, such data possesses a very rich temporal structure, which is currently much under-utilized. Yet, it could be exploited for differential diagnosis as well as long-term prediction and individual prognosis of the course of a psychiatric or neurological illness.

Deep Recurrent Neural Networks (DRNN) are advanced AI/Machine Learning tools that can extract and learn such temporal structure.

Hence, they have been successfully applied in various fields where signals evolve over time, such as natural language processing, automatic text completion, or the detection of suspicious movement patterns in video sequences. Our group uses and develops such approaches further in order to learn dynamical

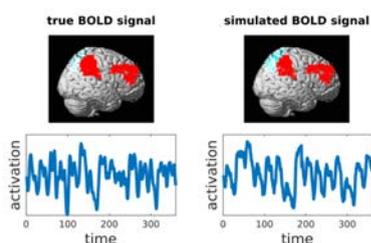
models of individual brains or human behavior from fMRI, EEG or smartphone-based data. Once such DRNN models have been trained on brain or behavioral data from a single subject, they can generate, on their own, new artificial data with the same spatio-temporal structure as the one found in the original recordings or observations (see figure). That is, they can mimic the behavior of an individual brain or subject.

Our research currently focuses on the mathematical and algorithmic foundations that enable to infer from data such models that efficiently capture the underlying dynamical process. However, the ultimate aim is to use these systems for clinical research and applications. By simulating previously trained DRNN models on the computer, long-term predictions of individual disease trajectories could be generated and thus early warning signs of future risks may be detected. Besides, the potential effects that therapeutic interventions or different pharmacological agents may have on a subject's brain could be predicted by simulating trained models, thereby guiding clinicians in their medical decision making by yielding differential diagnoses and suggesting subject-tailored treatment plans.

/D. Durstewitz, G. Koppe, A. Meyer-Lindenberg, U. Reininghaus, Central Institute of Mental Health, Mannheim-Heidelberg/

Recent Publication

G. Koppe, H. Toutounji, P. Kirsch, S. Lis, D. Durstewitz, 2019. Identifying nonlinear dynamical systems via generative recurrent neural networks with applications to fMRI. arXiv:1902.07186.



True (left) and model-generated (right) BOLD ('Blood Oxygenation Dependent Signal') activity in time (bottom) and projected onto the cortical surface (top).

Systementwicklung und Engineering von KI

Eine disziplinübergreifende Perspektive aus dem Frankfurt Institute of Advanced Studies FIAS

24

Signifikante Fortschritte in Recheninfrastruktur und großen Datenmengen, gepaart mit Deep Learning und Optimierungsalgorithmen ermöglichen neuerdings eine breite Palette intelligenter und gesellschaftlich relevanter Produkte und Lösungen. In den letzten acht Jahren konzentrierten sich die Bemühungen des Frankfurter Institute for Advanced Studies (FIAS) und der Goethe-Universität auf transdisziplinäre Arbeiten in den Bereichen Computational Neuroscience, Kognitionswissenschaften und Systemtechnik auf Seh-Anwendungen mit Betonung auf Transparenz, Erklärbarkeit und Kontextsensitivität. Folgende Aspekte standen im Vordergrund: Grundlagen neuronaler visueller Architektur, Entwicklung des visuellen Kortex, Neugier-getriebenes kindliches Lernen mit minimalen Mengen an Trainingsbeispielen, modellgetriebene Simulationen und Systemtechnik für KI sowie Systeme und Anwendungen Maschinellen Lernens.

Visuelle Architektur und Systemtechnik

Die dynamische visuelle Architektur von Christoph von der Malsburg beruht auf massiv paralleler Verarbeitung und einer Zerlegung des visuellen Eingangssignals in konstituierende Modalitäten (Farbe, Bewegung, Textur, Schatten, Reflexion, Konturen, usw.), was effiziente Indexierung in eine reiche Gedächtnisstruktur ermöglicht. Aus dieser interdisziplinären Arbeit entstand eine Anwendungsstudie für den Automobilbereich. In dieser Fallstudie wurden zwei parallele Datenpfade entworfen: der eine macht Vorhersagen über Video-Szenenkonfiguration, geleitet durch Modelle früherer Szenengeometrie und -bewegung. Der andere realisiert eine tiefe Pipeline mit Farbinvarianz, Symmetrie und Gruppierungsinformationen für Bremsleuchten. Diese Berechnungsergebnisse werden kombiniert, um Anomalien zu identifizieren, wenn die Bremsleuchten von ‚ein‘ auf ‚aus‘ oder von ‚aus‘ auf ‚ein‘ schalten. Der resultierende Entwurf und die systemtechnischen Gesichtspunkte orientieren sich an der oben genannten architektonischen Sichtweise und haben das Potenzial, dynamische visuelle Intelligenzsysteme der nächsten Generation zu entwickeln, die kompositorisch und hierarchisch funktionieren. Jüngst ist es von der Malsburg gelungen, die Lücke zwischen neuronalen und kognitiven Beschreibungen von Gehirn und Geist durch die Formulierung einer neuronalen Architektur zu schließen. Grundlage ist eine Datenstruktur in Form von strukturierten Netzen, die auf der langsamen Zeitskala von Lernen und Selbstorganisation erzeugt werden und auf der schnellen, funktionalen Zeitskala aktiviert werden können. Im Gegensatz zu herkömmlichen tiefen neuronalen Netzwerken bietet diese Architektur eine natürliche Interpretation für kognitive Prozesse wie die Fokussierung von Aufmerksamkeit, schema-basiertes Verstehen (einschließlich invarianter Objekterkennung) und die kompositorische Darstellung komplexer kognitiver Gebilde.

Lernen wie Kleinkinder mit kleinsten Datenmengen

Durch unsere Untersuchungen zur Entwicklung des visuellen Kortex konnten wir zeigen, dass das Gehirnnetzwerk bereits vor dem ersten Augenöffnen im Leben eines Menschen stark strukturiert ist. Dies wird die KI der nächsten Generation inspirieren, deren Ziel es ist, Systeme zu entwickeln, die aus begrenzten Er-

fahrungen im Alltag lernen können. Ein Gerüst bereits bestehender Aktivitätszustände könnte das Lernen robuster gegenüber unausgewogenen oder wenigen Trainingsdaten machen. Es wird auch möglich sein, die Grenzen des Maschinellen Lernens in Richtung von Systemen zu verschieben, die mit deutlich weniger Trainingsbeispielen auskommen und so autonom, wie Kinder, lernen. Auf der Basis von intrinsisch motiviertem Lernen entwickeln wir insbesondere Computermodelle und Roboter, deren Ziel es ist, ihre Umgebung zu verstehen und mit ihr zu interagieren. Das Lernen mit kleinen Datenmengen kann auch durch eine Kombination von modellbasierten Simulationen und realen Daten erreicht werden. Gemeinsam mit Constantin Rothkopf von der TU Darmstadt ist es uns gelungen, in Simulationen zur Konstruktion und Bewertung von Visionssystemen die Rolle von generativen Modellen zu untersuchen. Diese Arbeit verbindet unsere systemtechnische Arbeit mit modernen computergrafischen Methoden und sogenannten ‚adversarial networks‘, um den Einsatz automatisch annotierter Grafiksimulationen zur Reduktion des Bedarfs an realen Daten zu testen und die Lücke zwischen Simulationen und realen Daten zu schließen. Wir gehören zu den ersten, die diesen Weg gehen.

Anwendungen von Machine Learning

Wir haben Machine Learning eingesetzt, um neuronale Systeme, Tierverhalten und -entwicklung zu verstehen. (Siehe dazu auch den kürzlich erschienenen Artikel inkl. Video in NATURE über die Rolle der Hautbemusterung bei Tintenfischen). Diese Ansätze des Machine Learning und Deep Learning wenden wir auch auf biomedizinische Fragestellungen an, wie z.B. die Vorhersage der Entwicklung von Epilepsie oder die Erkennung von Hirntumoren. Aus systemtechnischer Sicht haben wir unsere Arbeit an der Entwicklung von Automatisierungstools (Meta-Learning) und kognitiven Architekturen fortgesetzt. Es ist unser Ziel inspizierbare, modellbasierte Pipelines mit modernen Deep Learning-Pipelines zu verbinden. Wir haben bereits Fortschritte bei der automatisierten und schrittweisen Auswahl von Merkmalen für tiefe neuronale Netze gemacht. Auch bei der Anwendung von Meta-Learning und der Architektursuche für eine visuelle Inspektion (Anomalieextraktion) von Drohnendaten haben wir neue Erkenntnisse gewonnen.

/M. Kaschube/ C. v.d. Malsburg/ V. Ramesh/ J. Triesch, Frankfurt Institute of Advanced Studies FIAS/

Systems Science & Engineering of AI

A Transdisciplinary Perspective from the Frankfurt Institute of Advanced Studies FIAS

Significant advances in computational infrastructure and Big Data, coupled with Deep Learning and optimization algorithms, have enabled a wide range of intelligent products and solutions impacting society. Over the past eight years, research at the Frankfurt Institute for Advanced Studies (FIAS) and Goethe University focused on a transdisciplinary perspective in computational neuroscience, cognitive science, and systems engineering with an emphasis on transparency, explainability and context-sensitivity. The following aspects stood in the foreground: neural visual architecture foundations, visual cortical development, curiosity driven child-like learning with a minimum number of training samples, model-driven simulations and systems engineering for AI, and Machine Learning systems and applications.

Visual Architectures and Systems Engineering

The dynamic visual architecture by Christoph von der Malsburg advocates that the brain performs massively parallel processing and decomposes the visual input signal into constituent modalities (e.g. color, motion, texture, shadow, reflection, contours, etc.) thus enabling efficient indexing into a rich memory structure. This interdisciplinary work resulted in an application case study in the automotive sector. In this case study, two parallel computational threads were designed. One made predictions about video scene configuration according to prior models of scene geometry and motion. The other realized a deep pipeline with color invariance, symmetry and grouping information for brake lights. These pipeline outputs are combined to identify anomalies when the brake lights switch from 'on' to 'off' or from 'off' to 'on'. The resulting design and the systems engineering aspects are aligned with the architectural viewpoint described above and carry the potential to develop next generation dynamic visual intelligence systems which are compositional and hierarchical. Recently, von der Malsburg succeeded in closing the gap between neural and cognitive descriptions of brain and mind by formulating a neural architecture. Its basis is a data structure in the form of structured networks that are generated on the slow time scale of learning and self-organization and that can activate on the fast, functional time scale. Unlike traditional deep neural networks, this architecture provides a natural interpretation of cognitive processes such as attention focusing, scheme-based understanding (including invariant object recognition), and compositional representation of complex cognitive entities.

Learning, like Children, from Little Data

Our research on the development of the visual cortex has shown that the brain network is strongly structured even before a human being opens the eyes for the very first time. This will inspire the next generation AI the goal being to develop systems that can learn from limited everyday experiences. A framework of existing activity states could make learning more robust against unbalanced or scarce training data. It will also be possible to shift the boundaries of Machine Learning towards systems, which use far fewer training examples and learn as autonomously as children. On the basis of intrinsically motivated learning, we are developing computer models and robots whose goal is to understand their environment and interact with it. Learning from scarce data may also be achieved by a combination of model-based

simulations and real-data. Together with Constantin Rothkopf at TU Darmstadt, we succeeded in examining the role of generative models in simulation for the design and evaluation of vision systems. This work links our systems engineering work with modern computer graphics methods and adversarial networks to test the use of automatically annotated graphics simulation with the goal of reducing the need for real data and bridging the gap between simulations and real data. We are among the first to follow this path.

Machine Learning Applications

We have applied Machine Learning to understand neural systems, animal behavior and development. (See also the recently published article including video in NATURE on the role of skin patterning in cuttlefish). We also apply these Machine Learning and Deep Learning approaches to biomedical questions, such as predicting the development of epilepsy or the detection of brain tumors. From a systems engineering point of view, we have continued our work on the development of automation tools (meta-learning) and cognitive architectures. It is our goal is to combine inspectable model-based pipelines with modern Deep Learning pipelines. We have already made progress in the automated and incremental feature selection for deep neural networks. We have also gained new insights in the application of meta-learning and the search for an architecture for the visual inspection of drone data with regard to anomalies.

/M. Kaschube/ C. v.d. Malsburg/ V. Ramesh/ J. Triesch, Frankfurt Institute of Advanced Studies FIAS/

References

- Klimmasch, L., Schneider, J., Lelais, A., Shi, B. E., & Triesch, J. (2018) An Active Efficient Coding Model of Binocular Vision Development Under Normal and Abnormal Rearing Conditions. In: International Conference on Simulation of Adaptive Behavior (pp. 66-77). Springer, Cham.
- C. von der Malsburg. Concerning the Neural Code. Journal of Cognitive Science, 2018.
- Reiter S, Hülsdunk P, Woo T, Lauterbach MA, Eberle JS, Akay LA, Longo A, Meier-Credo J, Kretschmer F, Langer JD, Kaschube M, Laurent G. (2018) Elucidating the control and development of skin patterning in cuttlefish. Nature; 562, 361-366.
- Smith GB, Hein B, Whitney DE, Fitzpatrick D, Kaschube M. (2018) Distributed network interactions and their emergence in developing neocortex. Nat Neurosci.; 21(11) 1600-1608
- V. S. R. Veeravasarapu, Constantin A. Rothkopf, Visvanathan Ramesh: Adversarially Tuned Scene Generation. IEEE CVPR 2017: 6441-6449
- Tobias Weis, Martin Mundt, Patrick Harding, Visvanathan Ramesh: Anomaly detection for automotive visual signal transition estimation. ITSC 2017: 1-8.

Der Einzug der Künstlichen Intelligenz in der Computational Neuroscience

Ein Gastbeitrag von Moritz Grosse-Wentrup, Universität Wien

26

Zu verstehen, wie neuronale Aktivität Kognition hervorbringt, ist wohl das faszinierendste Problem in den kognitiven Neurowissenschaften. Die Entwicklung mechanistischer Modelle einzelner Neuronen und deren Erweiterung auf neuronale Netzwerke hat unser Verständnis der neuronalen Grundlagen der Kognition maßgebend geprägt. Gleichzeitig scheint das Ziel, zu verstehen, wie neuronale Schaltkreise Kognition erzeugen, so weit entfernt wie eh und je. In diesem kurzen Essay versuche ich, etwas Licht in dieses Rätsel zu bringen und zu diskutieren, wie die jüngsten Entwicklungen in der Künstlichen Intelligenz (KI) einen Paradigmenwechsel in unseren Versuchen, die neuronale Basis der Kognition zu entwirren, einleiten könnten.

Die Erklärungslücke

Wenn wir behaupten, dass wir ein komplexes System verstehen, setzt dies voraus, dass wir die Beziehungsregeln zwischen den verschiedenen Konzepten kennen, mit denen wir das System beschreiben. Die Konzepte sind aber je nach Disziplin unterschiedlich. Wenn zwei Disziplinen unterschiedliche Konzepte anwenden, um das gleiche System zu untersuchen, entsteht eine Erklärungslücke. So kann beispielsweise eine Person auf der neuronalen Ebene oder auf der kognitiven Ebene modelliert werden, wobei jedes Modell andere Konzepte verwendet. Wenn beide Modelle das gleiche System beschreiben, dann müssen deren Konzepte und die Beziehungen zwischen diesen in einem konsistenten Verhältnis zueinander stehen. Um die Erklärungslücke zwischen der Computational Neuroscience und der Kognitiven Neurowissenschaft zu schließen und zu erklären, wie neuronale Aktivität zu Kognition führt, müssen wir konzeptionelle und computergestützte Methoden entwickeln, die konsistente Abbildungen zwischen neuronalen und kognitiven Modellen erlernen können.

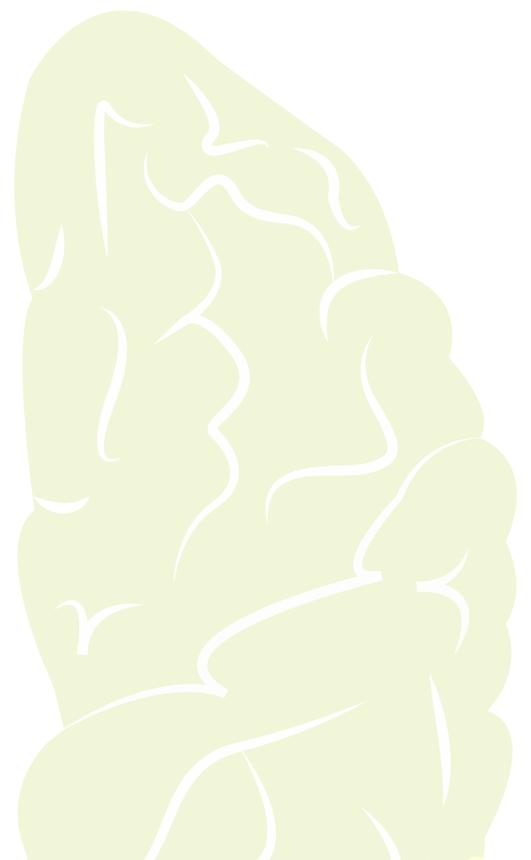
Der Einzug der Künstlichen Intelligenz

Handgefertigte Computermodelle neuronaler Schaltkreise wurden sehr erfolgreich bei der Modellierung neuronaler Daten eingesetzt; Sie konnten aber bisher nicht jene kognitiven Aufgaben bewältigen, die das Markenzeichen menschlicher Intelligenz sind. Aufgrund der jüngsten Entwicklungen im Deep Learning haben wir nun Zugang zu KI-Modellen, die zum ersten Mal in der Geschichte der Menschheit der menschlichen Leistung bei Aufgaben gleichkommt, die kognitive Fähigkeiten wie Objekterkennung, Arbeitsgedächtnis und kontextabhängige Entscheidungsfindung erfordern. Da jedes Modell, das behauptet, die neuronale Schaltung einer kognitiven Fähigkeit darzustellen, auch in der Lage sein sollte, diese kognitive Aufgabe zu erfüllen, sind KI-Systeme eine naheliegende Wahl für die Entwicklung konzeptioneller und algorithmischer Modelle, die konsistente Abbildungen zwischen neuronalen und kognitiven Modellen lernen können.

Was bedeutet ‚Verständnis‘?

Das Max Planck zugeschriebene Diktum „Wissen muss der Anwendung vorausgehen“ prägt die Naturwissenschaften seit mehr als einem Jahrhundert. Die Forschung im Bereich des Maschinellen Lernens und der KI hingegen wurde von Vladimir Vapniks Empfehlung geleitet, „[...] nicht zu versuchen, ein schwierigeres Problem als Zwischenschritt zu lösen“. Die Spannung zwischen diesen beiden Denkkulturen spiegelt sich im Bereich der erklärbaren KI wider: Auch wenn KI-Systeme bereits breite Anwendung erfahren, ist derzeit unklar, wie die Komplexität ihres Innenlebens dem menschlichen Geist intuitiv und doch umfassend vermittelt werden kann. Wenn es KI-Systemen letztendlich gelingt, konsistente Abbildungen zwischen neuronalen und kognitiven Modellen zu lernen, können sie sich als hilfreich bei der Behandlung von Kognitionsstörungen erweisen. Gleichzeitig könnte ihre Komplexität jedoch verhindern, ein intuitives Verständnis der neuronalen Grundlagen kognitiver Prozesse zu erlangen. Als solches könnte das Aufkommen der KI in der Computational Neuroscience einen Paradigmenwechsel ankündigen, der unseren Anspruch, die neuronale Basis der Kognition zu erforschen und zu verstehen, grundlegend verändert.

/M. Grosse-Wentrup, Universität Wien/cd/



The Advent of Artificial Intelligence in Computational Neuroscience

A Guest Article by Moritz Grosse-Wentrup, University of Vienna

Understanding how neuronal activity gives rise to cognition is arguably the most captivating problem in cognitive neuroscience. By building mechanistic models of individual neurons, and extending these models to networks of interconnected neurons, the field of computational neuroscience has advanced our understanding of the circuitry that supports cognition. At the same time, the goal of understanding how neuronal circuitry generates cognition appears as distant as ever. In this brief essay, I attempt to shed some light on this puzzling darkness and argue that recent developments in Artificial Intelligence (AI) herald a paradigm shift in our attempts to unravel the neuronal basis of cognition.

The Explanatory Gap

To claim that we understand a complex system implies that we know the rules that govern relations between the concepts with which we describe the system. The sets of concepts that are employed to represent a system, however, vary across disciplines. If two disciplines apply different concepts to study the same system, an explanatory gap emerges. For instance, a person may be modeled at the neuronal level or on the cognitive level, with each model using a different set of concepts. If both models describe the same system, then their concepts and the relations between them must stand in some consistent relationship to one another. To bridge the explanatory gap between computational- and cognitive neuroscience, and explain how neural activity gives rise to cognition, we need to develop conceptual- and computational frameworks that can learn consistent mappings between neuronal- and cognitive models.

The Advent of Artificial Intelligence

Hand-crafted computational models of neuronal circuits have enjoyed great success in modeling neuronal data, but have so far been unable to perform the cognitive tasks that are a hallmark of human intelligence. Due to recent developments in Deep Learning, we now have access to AI models that, for the first time in human history, match — and in some instances even surpass — human performance in tasks that require cognitive skills such as object recognition, working memory and context-dependent decision making. Because any model that claims to represent the neuronal circuitry of a cognitive skill should also be able to perform the cognitive task, AI systems are an obvious choice for developing conceptual and computational frameworks that can learn consistent mappings between neuronal- and cognitive models.

Relaxing Understanding

The dictum “knowledge must precede application”, attributed to Max Planck, has influenced natural sciences for more than a century. Research in Machine Learning and AI, on the other hand, has been guided by Vladimir Vapnik’s recommendation to “[...] not attempt to solve a more difficult problem as an intermediate step”. The tension between these two cultures is reflected in the domain of explainable AI: While AI systems are already deployed in a broad range of applications, it is presently unclear how the complexity of their inner workings can be communicated in an intuitive and yet comprehensive fashion to the human mind. If AI systems are ultimately successful in learning consistent mappings between neuronal- and cognitive models, they may prove instrumental for treating disorders of cognition. At the same time, their complexity may preclude researchers from gaining an intuitive understanding of the neuronal basis of cognition. As such, the advent of AI in computational neuroscience may herald a paradigm shift that fundamentally alters our ability and limitation to study and understand the neuronal basis of cognition.

/M. Grosse-Wentrup, University of Vienna/



Moritz Grosse-Wentrup
Research Group Neuroinformatics
University of Vienna

© University of Vienna

Mathematik bringt Licht ins Dunkel neuronaler Zusammenarbeit

Ein Beitrag von Viola Priesemann, Göttingen



Ein altes indisches Gleichnis erzählt davon, wie weise Männer einen Elefanten untersuchen und darüber in erbitterten Streit geraten. Der Elefant steht in einem stockdunklen Raum, so dass die Männer den Elefanten nicht sehen können. Der erste, der auf den Elefanten trifft, bekommt sein Bein zu fassen: „Ein Elefant ist wie eine Säule, schlank und stark und hoch!“, ruft er. Der zweite bekommt den Schwanz des Elefanten zu fassen und ist sich sicher: Ein Elefant ist wie ein Pinsel! Der dritte untersucht den Rüssel: „Ein Wasserschlauch!“. Und so untersucht jeder der weisen Männer einen anderen Teil des Tieres, und sie geraten ob ihrer widersprüchlichen Ergebnisse in erbitterten Streit.

Wenn wir das Gehirn untersuchen, dann ist die Situation ganz ähnlich: Von den mehr als 80 Milliarden Neuronen im Gehirn können wir nur einen winzigen Bruchteil, vielleicht einige hundert, mit höchster zeitlicher Präzision messen. Von diesem winzigen Teil wollen wir verstehen, was die kollektiven Eigenschaften des gesamten Gehirns sind. Es ist also kein Wunder, dass es dazu ganz verschiedene, widersprüchliche Theorien und Ergebnisse gibt.

Um Licht in dieses Dunkel zu bringen, haben wir in den letzten Jahren ganz neuartige mathematische Methoden entwickelt. Jetzt können wir das Zusammenarbeiten der Neurone wesentlich präziser bestimmen, und wir haben sogar verstanden, warum es vorher so verschiedene Hypothesen gab.

Kurz gesagt, mit unserer neuen Methode haben wir herausgefunden, dass die Neurone so miteinander verbunden sind, dass schon ein minimaler Input das Netzwerk anregen kann. Das Netz ist also hochsensibel – aber nicht so hypersensibel, dass es instabil und eventuell epileptisch werden kann. Den ‚Grad der Sensibilität‘ können wir mit unserem neuen mathematischen Werkzeug nun sehr genau bestimmen, selbst wenn wir nur rund zehn oder zwanzig Neurone messen. Damit untersuchen wir derzeit, wie das Gehirn – und jedes lokale Areal – diese Sensibilität anpasst, abhängig von Aufgabe und Kontext. Wir sollten das Gehirn also nicht als ‚statischen Elefanten‘ betrachten, sondern als ein hoch-adaptives, dynamisches und vielseitiges Netzwerk. Wie genau sich die einzelnen Areale eines Gehirns den Aufgaben und Gegebenheiten anpassen – welche informationstheoretischen Prinzipien den Arbeitspunkt bestimmen und welche Plastizitätsmechanismen ihn einstellen – das möchten wir in den kommenden Jahren herausfinden.

/V. Priesemann, Georg-August-Universität Göttingen/

Publications

Wiltling & Priesemann, Cerebral Cortex, 2019.
Wiltling & Priesemann, Nature Communications, 2018.
Wiltling et al., Frontiers in Systems Neuroscience, 2018.

Von Gehirnsignalen zu Neuroprothesen

Der Neurophysiker Alexander Gail arbeitet daran, die Großhirnrinde zu verstehen – vor allem jene Region des Gehirns, die für räumliche Kognition wichtig ist. Ein aktueller Schwerpunkt seiner Forschung ist die Hirn-Elektrophysiologie in nicht-humanen Primaten im Kontext von Bewegungsplanung und -kontrolle. Dafür entwickelt er Algorithmen zur Bewegungsanalyse. Diese können beispielsweise für die Diagnose und Therapie von Bewegungsstörungen herangezogen werden – gerade nach einem Schlaganfall oder bei Menschen, die an Parkinson leiden. Hier nutzen Gail und sein interdisziplinäres Kollegium Erkenntnisse aus dem Maschinellen Lernen und der Robotik, um die objektive Beurteilung von Bewegungsmustern zu verbessern.

Egal ob er an grundlegenden Fragen forscht oder Algorithmen trainiert, Alexander Gail behält dabei stets eine spätere Anwendung im Blick. In vielerlei Hinsicht kann er als Brückenbauer bezeichnet werden. In seiner Forschung übersetzt Gail Daten, die an der Innenseite der Großhirnrinde von Primaten aufgenommen werden, in neuronale Aktivitätsmuster, die wiederum Bewegungen zugeordnet werden. Diese Erkenntnisse sollen mittels Lernalgorithmen letztendlich die Steuerung von Neuroprothesen verbessern. Damit Patienten die neurologischen Prothesen als ihre eigenen Gliedmaßen annehmen können, ist es wichtig, dass die Übersetzung von Signalen in Bewegungen in Echtzeit erfolgt. Damit das gelingen kann, führt auch auf dem Weg vom Gehirnsignal zur Neuroprothese am Maschinellen Lernen kein Weg vorbei. /cd/

Alexander Gail,
Professor for Sensorimotor Neuroscience and Neuroprosthetics
Deutsches Primatenzentrum,
Göttingen

Mathematics Sheds New Light on Neuronal Cooperation

An Article by Viola Priesemann, Göttingen

An ancient Indian parable tells of how wise men examine an elephant and get into a bitter argument about it. The room in which the elephant stands is pitch black, so that the men cannot see the elephant. The first one examines the elephant's leg: "An elephant is like a column, slender and strong and high", he says. The second gets a hold of the elephant's tail and states: "An elephant is like a brush!" The third examines the trunk: "A water hose!" Thus, each of the wise men examines a different part of the animal, and they are fiercely disputing their contradictory results.

When we examine the brain, we encounter a similar situation: we can only measure a tiny fraction of the more than 80 billion neurons in the brain – but only about several hundred with highest temporal precision. From this tiny fraction, we endeavor to understand the collective properties of the entire brain. Thus, it is hardly surprising that there are quite different, contradictory theories and results.

We have developed completely new mathematical methods which helped to shed light on this: We can now determine the cooperation of neurons much more precisely, and we even understand why there were so many different hypotheses before.



V. Priesemann
© Joao Pinheiro Neto

With our new method we find that the neurons are connected in such a way that even a minimal input can stimulate the network. The network is therefore highly sensitive – but not hypersensitive to make it unstable and possibly epileptic. With our new mathematical tool, we can now determine the 'degree of sensitivity' very precisely, even if we only measure about ten or twenty neurons. We are currently investigating how the brain – and each local area – adjusts this sensitivity, depending on task and context. Therefore, we should not see the brain as a 'static elephant', but as a highly adaptive, dynamic and versatile information network. Our goal for the years to come is to find out how exactly the individual areas of a brain adapt to the tasks and conditions – which information-theoretical principles determine the working point and which plasticity mechanisms adjust it.

/V. Priesemann, University of Göttingen/



From Brain Signals to Neuroprostheses

The neurophysicist Alexander Gail works towards understanding the cerebral cortex – especially the area of the brain that is important for spatial cognition. A current focus of his research is the brain electrophysiology of non-human primates in the context of motion planning and control. Here, he develops algorithms for motion analysis, which can be used for the diagnosis and therapy of movement disorders – especially after a stroke or with people suffering from Parkinson's disease. Here, Gail and his interdisciplinary team use findings from Machine Learning and robotics to improve the objective assessment of movement patterns.

Whether he is researching fundamental questions or training algorithms, Alexander Gail always keeps an eye on later application. In many ways, he can be considered as a builder of bridges. In his research, Gail translates data recorded on the inside of the cerebral cortex of primates into neuronal activity patterns, which in turn are assigned to movements. These findings should ultimately improve the control of neuroprostheses by means of learning algorithms. It is particularly important to translate signals into movement in real time as this facilitates the patients' acceptance of the neurological prostheses as their own limbs. To achieve this goal, there is no getting around the help of Machine Learning. /cd/

Alexander Gail,
Professor for Sensorimotor Neuroscience and Neuroprosthetics
German Primate Center,
Göttingen

Werkzeuge

Innovative Algorithmen für die Analyse neuronaler Daten

Ob einzelne Nervenzellen oder das ganze Denkgorgan: Die Aktivität des Gehirns kann auf unterschiedlichen Ebenen gemessen werden, im Labor oder für klinische Zwecke. Daten hoher Qualität sind aber nur mit hohem Aufwand zu erheben, und mit Hilfe von Methoden des Maschinellen Lernens können wir solche Daten noch besser und effektiver auswerten.

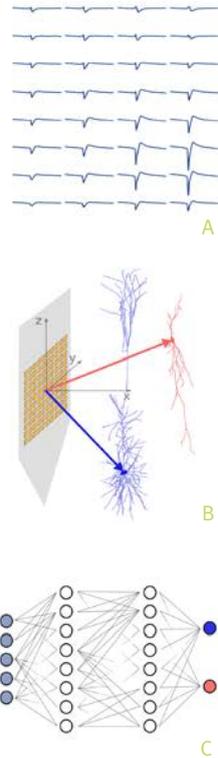
Neuartige Mehrfachelektroden auf Siliziumbasis werden in Versuchstiere implantiert, um die Signale von Tausenden von Neuronen aus verschiedenen Hirnarealen gleichzeitig abzuleiten. Die hohe räumliche Auflösung dieser Instrumente erlaubt zudem die Bestimmung des ‚elektrischen Fingerabdrucks‘ jeder einzelnen Nervenzelle. Dieser ist aussagekräftig genug, um den Typ und die Position der abgeleiteten Zelle mit einiger Präzision zu bestimmen. Die in diesem Fall erforderliche Klassifikation oder Rekonstruktion kann mit Hilfe moderner Verfahren (convolutional neural networks CNN) effizient umgesetzt werden. Voraussetzung ist, dass eine hinreichend große Anzahl von Beispielen zur Verfügung steht, die durch menschliche Spezialisten klassifiziert wurden, und auf deren Basis das Netzwerk trainiert werden kann.

Da geeignete biologische Messdaten aber nur mit sehr hohem Aufwand zu gewinnen sind, haben wir mit Hilfe von Computersimulationen synthetische Trainingsdaten erzeugt. Durch die

Kombination der Methoden konnten wir das große Potential der neuen Elektroden objektiv testen.

Funktionelle Magnetresonanztomographie (fMRT) wird eingesetzt, um berührungsfrei die Aktivität ganzer menschlicher Gehirne abzuleiten. Für diagnostische Zwecke ist es oft wichtig, die genaue Struktur der Hirnnetzwerke zu kennen, die der gemessenen Aktivität zugrunde liegen. Dazu haben wir einen Algorithmus entwickelt, welcher Richtung, Vorzeichen und Stärke von Tausenden Verbindungen gleichzeitig bestimmen kann. Dies gelingt mit Hilfe eines neuartigen Regularisierungsverfahrens aus dem Bereich des Maschinellen Lernens (compressed sensing), das für Netzwerke mit nicht zu vielen Verbindungen hervorragend funktioniert. Letztendlich können damit die verschlungenen Pfade nachvollzogen werden, die ein Signal im Netzwerk nimmt.

/S. Rotter, Bernstein Center Freiburg BCF/



30

Mit KI elektrische Gehirnsignale interpretieren

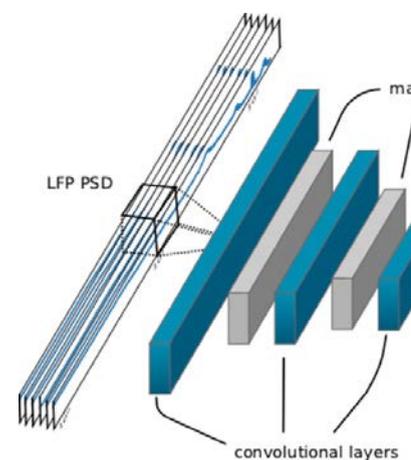
Das meiste, was wir über Gehirnetzwerke wissen, stammt aus der Messung elektrischer Signale durch Elektroden, die im Gehirn platziert sind. Der niederfrequente Teil der aufgezeichneten Signale, das so genannte Local Field Potential (LFP), spiegelt wider, wie Dendriten in neuronalen Populationen synaptische Inputs aus dem umgebenden neuronalen Netzwerk integrieren. Da die Interpretation von LFP-Signalen eine Herausforderung darstellt, hat das LFP-Signal in der neurowissenschaftlichen Forschung bisher eine untergeordnete Rolle gespielt. LFP Daten enthalten jedoch einzigartige Informationen über das Verhalten von Netzwerken und könnten zudem eine robustere Ansteuerung neuroprothetischer Geräte ermöglichen.

Wir fragen uns deshalb, ob das LFP verwendet werden kann, um synaptische Verbindungsgewichte im zugrundeliegenden neuronalen Netzwerk genau zu schätzen. Um dies zu erforschen, haben wir ein gründlich analysiertes gepulstes, neuronales Netz (Spiking Neural Network SNN) betrachtet. Wir arbeiten mit dem sogenannten Brunel-Netzwerk, das exzitatorische und hemmende Populationen von miteinander verbundenen ‚Integrate-and-Fire‘-Neuronen umfasst. Das Brunel-Netzwerk weist eine hohe Netzwerkdynamik auf, die auf den Werten von nur drei Modellparametern beruht, die synaptische Verbindungsgewichte beschreiben. Das von diesem Netzwerk erzeugte LFP wurde mit einem Hybridschema berechnet. Mithilfe des Simulationstools

NEST wurden die Spitzen berechnet und mit den Simulationstools LFPy und NEURON die entsprechenden LFPs.

Um zu beurteilen, wie gut Netzwerkmodellparameter aus dem LFP-Signal gewonnen werden können, haben wir die Genauigkeit der Modellparameter-Vorhersage eines trainierten künstlichen neuronalen Netzes (Convolutional Neural Network, CNN, siehe Abbildung) getestet, einem häufig verwendeten KI-Tool. Wie sich herausstellte, war ein relativ einfaches CNN ausreichend, um die Netzwerkmodellparameter aus dem LFP genau zu schätzen. Die Ergebnisse der Studie sind insofern ermutigend, als sie darauf hindeuten, dass nicht nur Spitzendaten, sondern auch LFPs zur Validierung von Netzwerkmodellen verwendet werden können.

/G. Einevoll, Universität Oslo, Norwegen/cd/



Project: CoBra. Computing Brain Signals, funded by the Research Council of Norway

Computational tools

Innovative Algorithms for Neuronal Data Analysis

Single nerve cells or the whole organ of thinking: Brain activity can be measured on different scales, both in the lab or for clinical purposes. Data of high quality, however, can only be obtained with high effort, and with the help of Machine Learning methods we can make better and more efficient use of such data.

Novel silicon-based multi-electrode arrays are inserted into the brain of laboratory animals to simultaneously record the signals of thousands of neurons from different brain areas. On top of this, the high spatial resolution of these instruments allows to determine the ‘electrical fingerprint’ of each individual neuron. These fingerprints are informative enough to determine type and position of each recorded cell with high precision. The classification or reconstruction that is necessary in this case can be efficiently implemented using state-of-the-art methods (convolutional neuronal networks CNN). Yet, a sufficiently large number of examples classified by human specialists is required to train the network. As suitable biological data can be obtained only with a very high effort, we used computer simulations to generate synthetic train-

Left: Illustration of a new procedure to localize and classify nerve cells based on electrophysiological recordings with modern high-resolution electrodes (Fig. 1B). We train a Convolutional Neuronal Network (Fig. 1C) with example data (Fig. 1A) which have been annotated beforehand by human experts. Facts and relations that were implicitly extracted from these examples during training are stored in the synaptic connections of the network. The emerging ‘artificial expert’ can then use the learned knowledge for a computer-aided and fast classification of new data.

ing data. This combination of methods allowed us to convincingly demonstrate the high potential of the new electrode arrays.

The activity of entire human brains is recorded non-invasively with functional magnetic resonance imaging (fMRI). For diagnostic purposes, it is often important to know, the precise structure of the brain networks that underlie the measured activity. To this end, we have developed an algorithm that can determine direction, sign, and strength of thousands of connections simultaneously. This is achieved with a novel regularization method from the field of Machine Learning (compressed sensing), which works very well for networks that do not have too many connections. With its help, we can finally retrace the intertwined paths that a signal takes through the network.

/S. Rotter, Bernstein Center Freiburg BCF/

Publications

Buccino AP, Kordovan M, Bækø Ness TV, Merkt B, Häfliger PD, Fyhn M, Cauwenberghs G, Rotter S, Einevoll GT. Combining biophysical modeling and deep learning for multi-electrode array neuron localization and classification. *Journal of Neurophysiology* 120: 1212-1232, 2018. <https://doi.org/10.1152/jn.00210.2018>

Schiefer J, Niederbühl A, Pernice V, Lennartz C, LeVan P, Hennig J, Rotter S. From Correlation to Causation: Estimation of Effective Connectivity from Continuous Brain Signals based on Zero-Lag Covariance. *PLOS Computational Biology* 14(3): e1006056, 2018. <https://doi.org/10.1371/journal.pcbi.1006056>

Using AI to Interpret Electrical Brain Signals

Most of what we have learned about brain networks has come from the measurement of electrical signals by electrodes placed inside the brain. The low-frequency part of the recorded signals, the so-called local field potential (LFP), reflects how dendrites in neuronal populations integrate synaptic inputs from the surrounding network of neurons. As the interpretation of LFP signals is challenging, the LFP signal has played a modest role in neuroscience research. This is a missed opportunity as the LFP contains unique information about the behavior of networks and may also be a more robust signal for controlling neuroprosthetic devices.

In the present project, we asked the question whether the LFP can be used to accurately estimate synaptic connection weights in the underlying neural network? To explore this, we considered a thoroughly analyzed spiking network model,

the so-called Brunel Network comprising excitatory and inhibitory populations of recurrently connected, integrate-and-fire’ neurons. The Brunel

network exhibits a high diversity of network dynamics depending on the values of only three model parameters describing synaptic connection weights. The LFP generated by this network was computed using a hybrid scheme, the simulation tool NEST computed the spikes and the simulation tools LFPy and NEURON the corresponding LFPs.

To assess how well network model parameters could be estimated from the LFP signal, we tested the accuracy of the model parameter prediction of a trained convolutional neural net (CNN, see figure on the left), a commonly used AI tool. As it turned out, a relatively simple CNN was found to be sufficient to accurately estimate the network model parameters from the LFP. The results of the study are encouraging as they suggest that not only spiking data, but also LFPs, can be used to validate network models.

/G. Einevoll, University of Oslo, Norway/

Recent Publication

JEW Skaar, AJ Stasik, E Hagen, TV Ness, GT Einevoll: Estimation of neural network model parameters from local field potentials (LFPs), doi: <https://doi.org/10.1101/564765>

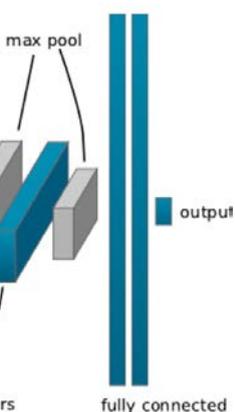


Illustration of convolutional neural network (CNN) used in the project. The LFP spectra from six recording channels are taken as input. The three convolutional layers consist of twenty filters each, and are followed by max pooling. Two fully connected layers precede the output layer.



Das Helmholtz Analytics Toolkit (HeAT) Eine High Performance Computing (HPC) Programmbibliothek für wissenschaftliche Big Data Analytik

Die Datenanalyse ist zu einem wichtigen Instrument geworden, um wissenschaftliche Probleme anzugehen, die sich durch größte Daten- und Rechenkomplexität auszeichnen. Das Simulation Laboratory Neuroscience des Forschungszentrum Jülich, Bernstein Facility for High Performance Simulation and Data Analytics, trägt zum Helmholtz Analytics Framework (HAF) bei, indem es Datenanalytik, Maschinelles Lernen und Deep Learning-Ansätze für Hochleistungsberechnungen (HPC) verallgemeinert und standardisiert: dies geschieht auf Basis konkreter Anwendungsbedarfe aus verschiedenen Wissenschaftsbereichen. Ziel ist es, eine für HPC-Systeme optimierte Softwareplattform zu etablieren, die einem breiten Spektrum von wissenschaftlichen Communities zur Verfügung steht und anwendbar ist.

Ein wichtiger Baustein dieser Softwareplattform ist das Helmholtz Analytics Toolkit (HeAT), eine wissenschaftliche Datenanalytische Bibliothek für HPC-Systeme. Die großen Fortschritte beim Maschinellen Lernen/Deep Learning (ML/DL) wurden durch gut gestaltete Open-Source-Bibliotheken erheblich verstärkt. Trotz der Fülle an vorhandenen Frameworks fehlt aber nach wie vor eine Programmbibliothek, die die spezifischen Bedürfnisse von WissenschaftlerInnen berücksichtigt. So arbeitet beispielsweise keine bereits vorhandene Ressource auf heterogener Hardware wie GPU/CPU-Systemen und ermöglicht gleichzeitig eine transparente Berechnung auf verteilten Systemen.

HeAT baut auf PyTorch auf, das viele erforderliche Funktionen wie automatische Differenzierung, CPU- und GPU-Unterstützung, lineare Algebraoperationen und Grundfunktionalitäten des Message Passing Interface (MPI), einem Standard für verteiltes Rechnen auf HPC-Systemen, bietet. PyTorch hat zudem ein imperatives Programmierparadigma; es ermöglicht ein schnelles Prototyping, das für wissenschaftliche Forschung unerlässlich ist. Verteilte Berechnungen müssen jedoch für jede grundlegende Kommunikation von Hand entworfen werden. Darüber hinaus implementiert PyTorch nur eine Teilmenge der MPI-Funktionalitäten. Hier setzt HeAT an und stellt ein verteiltes Tensor-Datenobjekt zur Verfügung, an dem Operationen durchgeführt werden können. Die Tensor-Datenobjekte befinden sich entweder auf der CPU oder auf der GPU und sind auf Wunsch auf verschiedene Knoten verteilt. Operationen an Tensorobjekten sind für den Benutzer transparent, d.h. sie bleiben gleich, unabhängig davon, ob sich das HeAT-Datenobjekt auf einem einzelnen Knoten befindet oder ob es auf mehrere Knoten verteilt ist. Auf der Grundlage dieser Kernstruktur implementiert HeAT typische Datenanalysemethoden, die aus verschiedenen wissenschaftlichen Anwendungsfällen motiviert sind.

/K. Krajsek, C. Comito, D. Coquelin, B. Hagemeyer, Forschungszentrum Jülich/ M. Götz, S. Hanselmann, Karlsruhe Institute of Technology / C. Debus, P. Knechtges, S. Schmitz, M. Siggel, Deutsches Zentrum für Luft- und Raumfahrt e.V. (DLR), Köln/

32

Mit Modellen und Simulationen die Plastizität des Gehirns verstehen

Lernen und Gedächtnis in biologischen Gehirnen werden ursächlich mit verschiedenen Änderungen der neuronalen Schaltkreise in Verbindung gebracht. Im einfachsten Fall wird die Übertragung an den Synapsen zwischen Nervenzellen verstärkt oder abgeschwächt. Künstliche neuronale Netze und deren Anwendungen in der Künstlichen Intelligenz haben sich dieses Verfahren von der Natur abgeschaut. In biologischen Gehirnen gibt es aber noch andere, viel radikalere Umbauprozesse: Nervenzellen bilden kontinuierlich neue Verbindungen und eliminieren existierende. Im heranwachsenden Gehirn ist dies ein natürlicher Prozess, und im alternden oder kranken Gehirn oft nicht zu vermeiden. Aber es gibt derartige Änderungen in der Netzwerkstruktur sehr wohl auch im gesunden erwachsenen Gehirn, und zwar in drastischem Umfang: Bei erwachsenen Mäusen sind 5% bis 25%, für bestimmte Zelltypen sogar bis zu 50% Erneuerung pro Monat gemessen worden. Man muss also davon ausgehen, dass der ständige Umbau von Netzwerken Teil der normalen Funktion des Gehirns ist.

Die Relevanz dieses ständigen Umbaus für Informationsverarbeitung im Gehirn ist bislang allerdings nicht überzeugend geklärt. Computersimulationen helfen uns bei der Suche nach einer Erklärung. Mit dieser Methode haben wir die Eigenschaften von Netzwerken untersucht, die einer ständigen Umverdrahtung unterliegen. Es stellt sich die interessante Frage, wie ein Organ mit einer derart flüchtigen Struktur überhaupt stabiles Verhalten hervorbringen kann. Wie ist es möglich, dass ein Gehirn bestimmte Erinnerungen oder Fähigkeiten ein Leben lang aufrechterhalten kann, obwohl nach einer gewissen Zeit die meisten Synapsen durch andere ersetzt worden sind? Dazu haben wir eine homöostatisch regulierte Form

von struktureller Plastizität untersucht, die seit langem in der Literatur diskutiert wird. Dabei haben wir festgestellt, dass diese Verdrahtungsregel extrem interessante Eigenschaften hat, da sie zusätzlich eine robuste Form von assoziativem Gedächtnis darstellt (Gallinaro & Rotter 2018). Die Fähigkeit zur Assoziation – also Dinge zu verbinden, die aufgrund gemachter Erfahrungen zusammengehören – ist eine Basisfunktion des Gehirns und bildet die Grundlage für verschiedene Formen des Lernens.

Inwieweit kann so ein Netzwerkmodell auch pathologische Veränderungen der Netzwerkstruktur erfassen, und wie können die Ergebnisse für therapeutische Ansätze genutzt werden? Bei bestimmten Formen von Epilepsie etwa scheint das unregelmäßige Auswachsen neuer Verbindungen eine wichtige Rolle zu spielen. Wir haben daher auch untersucht, wie – unter Ausnutzung der Plastizität des Gehirns – bestimmte neuronale Erkrankungen mit Hilfe externer Stimulation behandelt werden könnten. Bei der transkraniellen Gleichstromstimulation (tDCS) etwa lässt unser Modell vermuten, dass der regulär stattfindende Umbau der Netzwerke durch die Wirkung externer elektrischer Felder beschleunigt oder abgebremst wird (Lu et al. 2019). Ein besseres Verständnis dieser Wirkzusammenhänge kann auf lange Sicht zu einem besseren und zuverlässigeren therapeutischen Ergebnis führen.

/S. Rotter, Bernstein Center Freiburg BCF/



The Helmholtz Analytics Toolkit (HeAT)

A High Performance Computing (HPC) Library for Scientific Big Data Analytics

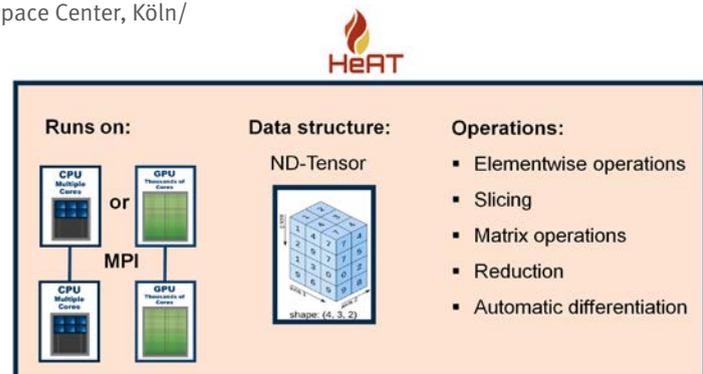
Data analytics has become an important instrument for addressing scientific problems characterized by the greatest data and computational complexity. The Simulation Laboratory Neuroscience at the Forschungszentrum Jülich, Bernstein Facility for High Performance Simulation and Data Analytics, contributes to the Helmholtz Analytics Framework (HAF) by generalizing and standardizing data analytics, Machine Learning, and Deep Learning approaches for high-performance computation, guided by use cases from multiple scientific fields. The objective is to establish a software platform optimized for HPC systems which is available and applicable to a broad range of scientific communities.

A key building block of this software platform is the Helmholtz Analytics Toolkit (HeAT), a scientific data analytics library for HPC systems. The large progress in Machine Learning/Deep Learning (ML/DL) has been considerably enforced by well-designed open source libraries. Despite the abundance of existing frameworks, a library which takes the specific needs of scientists into consideration is still absent. For instance, no pre-existing library operates on heterogeneous hardware like GPU/CPU systems while allowing transparent computation on distributed systems.

HeAT builds on top of PyTorch, which provides many required features such as automatic differentiation, CPU and GPU support, linear algebra operations and basic functionalities of the message passing interface (MPI), a standard for distributed computing on HPC systems. PyTorch also has an imperative programming paradigm, allowing for fast prototyping essential in scientific research. However, distributed computations must be designed by hand for

each basic communication and furthermore PyTorch implements only a subset of MPI functionalities. HeAT starts at this point providing a distributed tensor data object on which operations can be performed. The tensor data objects reside either on the CPU or on the GPU and, if desired, are distributed over various nodes. Operations on tensor objects are transparent to the user, i.e. they remain the same irrespective of whether the HeAT data object resides on a single node or if it is distributed over several nodes. On the basis of this core structure, HeAT implements typical data analytics methods motivated from various scientific use cases.

/K. Krajsek, C. Comito, D. Coquelin, B. Hagemeyer, Forschungszentrum Jülich/ M. Götz, S. Hanselmann, Karlsruhe Institute of Technology / C. Debus, P. Knechtges, S. Schmitz, M. Siggel, German Aerospace Center, Köln/



The basic structure of the HeAT library: A tensor data structure and operations as well as automatic differentiation on top. The operations run transparently on multiple cores of multiple CPUs or on multiple GPUs.

Understanding the Plasticity of the Brain through Models and Simulations

Learning and memory in biological brains are causally linked with various changes in the neuronal circuits. In the simplest case, synaptic transmission between nerve cells is strengthened or weakened. Artificial neuronal networks, applied in Artificial Intelligence, have adopted this method from nature. In biological brains, however, there are other, much more radical modifications: nerve cells continuously assemble new connections and degrade existing ones. In adolescent brains, this remodeling is part of the normal development, and in the aging or diseased brain it is often unavoidable. But such changes in network structure also exist in the healthy adult brain, to a dramatic degree: in adult mice, monthly turnover rates between 5% and 25% (for certain cell types up to 50%) were measured. It can thus be concluded that continuous network remodeling is part of normal brain function.

However, the relevance of this remodeling for information processing in the brain, is not yet clear. Computer simulations can help to find an explanation. Using this method, we analyzed the properties of networks that undergo continuous rewiring. This leads to the interesting question of how an organ with such a volatile structure can exhibit stable behavior at all. How is it possible that a brain can maintain certain memories or skills throughout its life, despite the fact that most synapses are replaced after some time? To this end, we considered a homeostatically regulated form of structural plasticity, which is being discussed for quite some time. We realized that this wiring rule has extremely interesting properties, in particular, as it additionally implements a robust form of associative memory (Gallinaro & Rotter 2018).

The ability to associate – to link things that belong together according to past experience – is a key competence of the brain and fundamental to different forms of learning.

To what extent is such a model capable of conceiving pathological changes of the network structure? And how can these results be implemented in therapeutic approaches? In certain forms of epilepsy, for example, the unregulated growth of new connections appears to play an important role. Thus, we also explored how certain brain diseases could be treated through external stimulation – when we exploit the plasticity of the brain. In the case of transcranial direct current stimulation (tDCS), for example, our model suggests that the normal ongoing network remodeling is accelerated or decelerated through the exposure to external electrical fields (Lu et al. 2019). An improved understanding of the underlying causal relations could lead to a better and more reliable therapeutic outcome.

/S. Rotter, Bernstein Center Freiburg BCF/

Recent Publications

Gallinaro JV, Rotter S. Associative properties of structural plasticity based on firing rate homeostasis in recurrent neuronal networks. *Scientific Reports* 8: 3754, 2018. <https://doi.org/10.1038/s41598-018-22077-3>

Lu H, Gallinaro J, Rotter S. Network remodeling induced by transcranial brain stimulation: A computational model of tDCS-triggered cell assembly formation. *Network Neuroscience*, 2019. https://doi.org/10.1162/netn_a_00097

Bernstein Center for Computational Neuroscience Excellence Cluster 'Machine Learning: New Perspectives for Science'



34

Bernstein Center for Computational Neuroscience (BCCN) Tübingen

Ein Kurzportrait von Judith Lam

Künstliche Intelligenz und Maschinelles Lernen verändern nicht nur unser Leben, sondern auch den Wissenschaftsbetrieb. Die Neurowissenschaften sind hier aufgrund ihrer traditionellen Nähe zum Forschungsfeld des Maschinellen Lernens ganz vorne dabei. In Tübingen sind beide Bereiche durch das Bernstein Center for Computational Neuroscience und den Exzellenzcluster ‚Machine Learning: New Perspectives for Science‘ sehr stark vertreten.

In ihrer langen gemeinsamen Geschichte haben sich die Forschungsdisziplinen immer wieder gegenseitig befruchtet. So lieferte beispielsweise das Gehirn die Blaupause für künstliche neuronale Netze, die heute die Grundlage des sogenannten Deep Learning sind. Convolutional Neural Networks (CNNs) wurden ursprünglich als Modell des visuellen Systems entwickelt – lange bevor sie zum wesentlichen Bestandteil nahezu aller Computer-Vision-Systeme wurden. Umgekehrt helfen Methoden des Maschinellen Lernens dabei, die immer größeren und komplexeren Datenmengen moderner neurowissenschaftlicher Experimente zu analysieren und so die Funktionsweise des Gehirns zu verstehen. Diesen produktiven Austausch auch in Zeiten immer größer werdender Spezialisi-

sierung zu erhalten, bzw. sogar zu intensivieren, ist eine wichtige Aufgabe des BCCN Tübingen. Einerseits widmet sich das Zentrum der Ausbildung des wissenschaftlichen Nachwuchses durch das internationale Master- und PhD-Programm ‚Neural Information Processing‘; andererseits der Förderung von Forschungs Kooperationen, wie zuletzt im Sonderforschungsbereich (SFB) 1233 ‚Robust Vision‘.

Das internationale Master- und PhD-Programm ‚Neural Information Processing‘ wurde am BCCN Tübingen 2010 ins Leben gerufen. Es ist eines von drei Nachwuchsförderprogrammen am Graduate Training Center of Neuroscience in Tübingen. Das Programm genießt den Status einer International Max Planck Research School (IMPRS) und widmet sich primär der interdisziplinären Ausbildung in der Computational Neuroscience. Methoden des Maschinellen Lernens sowie deren Anwendung bilden mit mehreren Pflichtkursen einen wesentlichen Bestandteil des Masterprogramms. Sie gewinnen zunehmend an Popularität in den anderen neurowissenschaftlichen Studiengängen, wodurch das BCCN als Vorreiter in der Ausbildung der nächsten Generation von NeurowissenschaftlerInnen im Hinblick auf moderne Methoden der Datenmodellierung und -analyse fungiert.

Auf Seiten der Forschung setzt sich das BCCN Tübingen intensiv für Kooperationen zwischen experimentellen und theoretischen Neurowissenschaften und angrenzenden Disziplinen, wie Machine Learning und Computer Vision, ein. Ein gutes Beispiel hierfür ist der 2017 gestartete SFB 1233 ‚Robust Vision‘, der das Sehen sowohl aus biologischer als auch technischer Sicht, experimentell und theoretisch in einer Vielzahl von interdisziplinär besetzten Kooperationsprojekten untersucht.

Das BCCN Tübingen bildet die Brücke zwischen verschiedenen neurowissenschaftlichen Forschungszentren und -verbänden in Tübingen (siehe Grafik). Wie stark diese Verbindung ist, zeigt sich nicht zuletzt darin, dass Mitglieder des BCCN Tübingen sowohl den kürzlich eingerichteten Exzellenzcluster ‚Machine Learning: New Perspectives for Science‘ (Philipp Berens) als auch das Kompetenzzentrum für Maschinelles Lernen/ Tübingen AI Center (Matthias Bethge) leiten.

/J. Lam, BCCN Tübingen/

Neuroscience Tübingen/ Learning: New Perspectives for Science'

Bernstein Center for Computational Neuroscience (BCCN) Tübingen

Introduced by Judith Lam

Artificial Intelligence and Machine Learning are not merely changing our daily lives, they also change the way we conduct science. The neurosciences are working at the cutting-edge not least because of their traditional relations with Machine Learning. In Tübingen, both areas are very strongly represented through the Bernstein Center for Computational Neuroscience (BCCN) and the Excellence Cluster 'Machine Learning: New Perspectives for Science'.

Machine Learning and the neurosciences have a long history in which they have enriched each other. The brain provided the initial blueprint for artificial neural networks, which, in turn, are now the basis of so-called Deep Learning. Convolutional Neural Networks (CNNs) were originally developed as a model of the visual system — long before they became an essential part of almost every computer vision system. Conversely, Machine Learning methods help to analyze the ever growing complex data sets of modern neuroscientific experiments and thus help to understand the functioning of the brain. One key focus of the BCCN Tübingen is to maintain or even intensify this productive exchange in times of increasing specialization. The BCCN Tübingen attends to two central tasks: On the one hand, the training of young scientists through the international Master and PhD program 'Neural Information Processing'; on the other hand, the promotion of research cooperations, like the Collaborative Research Center (CRC) 1233 'Robust Vision'.

The international Master and PhD program 'Neural Information Processing' was established at the BCCN Tübingen in 2010. It is one of three programs at the Graduate Training Center of Neuro-

science in Tübingen to promote young researchers. The program enjoys the status of an International Max Planck Research School (IMPRS) and is primarily dedicated to interdisciplinary training in computational neuroscience. Methods of Machine Learning and their application are an essential part of the Master's program. Such modules are increasingly popular in other neuroscientific programs, which shows that the BCCN plays a pioneering role in training the next generation of neuroscientists with regard to modern methods of data modelling and analysis.

With regard to neuroscientific research, the BCCN Tübingen is deeply committed to cooperation between experimental and theoretical neurosciences and related disciplines, such as Machine Learning and computer vision. The CRC 1233 'Robust Vision' is an outstanding example of such interdisciplinary cooperation. Launched in 2017, it investigates vision from a biological as well as a technical point of view, with experimental as well as theoretical approaches in many different projects.

The BCCN Tübingen serves as a bridge between different neuroscientific research centers and collaborative networks in Tübingen (see figure on the left). This tight bond is not least demonstrated by the fact that members of the BCCN Tübingen manage both the recently established Excellence Cluster 'Machine Learning: New Perspectives for Science' (Philipp Berens) and the Competence Center for Machine Learning/ Tübingen AI Center (Matthias Bethge).

/J. Lam, BCCN Tübingen/

35

The Excellence Cluster 'Machine Learning: New Perspectives for Science'

An Article by Nikola Schwarzer

In the current public debate, which revolves around autonomous cars or personalized ads for online stores, Machine Learning is primarily an economic issue. "Certainly, science and industry have different goals in the pursuit of knowledge. In the cluster, we are working on initiating developments tailored to scientific questions," says Philipp Berens, together with Ulrike von Luxburg co-speaker of the Excellence Cluster.

The work of the cluster is not limited to one scientific field, but deliberately chooses an interdisciplinary approach: application potentials, challenges and likely problems of the implementation of Machine Learning are analyzed in different scien-

tific fields such as life sciences, physical-technical sciences, humanities and social sciences. But the cluster not only aims to advance individual fields. Gained insight will be transferred between disciplines to handle problems of similar structure. In the endeavour to combine different research areas, the cluster benefits from the experience gained over the last few years at the Bernstein Center for Computational Neuroscience (BCCN) Tübingen. "The Bernstein Center Tübingen unites neuroscience and Machine Learning on an institutional basis. To us, it serves as a blueprint for what we have in mind for other scientific fields," says Berens.

Exzellenzcluster ‚Machine Learning: New Perspectives for Science‘

Ein Artikel von Nikola Schwarzer

36

In der aktuellen öffentlichen Debatte ist Maschinelles Lernen vor allem im wirtschaftlichen Kontext präsent. Es geht um selbstfahrende Autos oder individuell zugeschnittene Kaufempfehlungen im Internet. „Natürlich unterscheidet sich das wissenschaftliche Erkenntnisinteresse von dem der Industrie. Im Cluster beschäftigen wir uns damit, Entwicklungen anzustoßen, die auf wissenschaftliche Fragestellungen zugeschnitten sind“, sagt Philipp Berens, der zusammen mit Ulrike von Luxburg Sprecher des Exzellenzclusters ist.

Die Arbeit des Clusters beschränkt sich dabei nicht auf einen isolierten Fachbereich, sondern wählt bewusst einen interdisziplinären Ansatz: Anwendungspotentiale, Herausforderungen und mögliche Probleme des Einsatzes von Maschinellen Lernverfahren werden in unterschiedlichen Wissenschaftsfeldern wie den Lebenswissenschaften, den physikalisch-technischen Wissenschaften und den Geistes- und Sozialwissenschaften beispielhaft analysiert. Dabei geht es nicht nur darum, die einzelnen Gebiete voranzubringen. Vielmehr sollen die gewonnenen Erkenntnisse auch auf andere Disziplinen übertragen werden, in

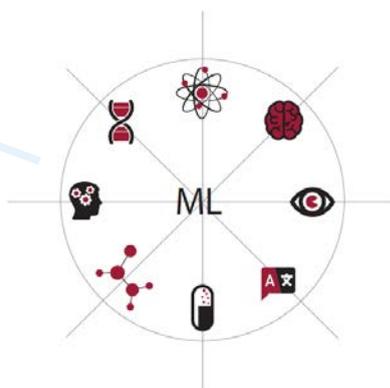
komplexes Wissen über die Prozesse, die während der Bodenformung ablaufen. Nicht zuletzt hinsichtlich der Klimakrise ist es wichtig zu erforschen, wie sich die Zusammensetzung der Böden verändert. Im Cluster soll nun erforscht werden, wie sich komplexe physikalische Modelle und konkrete Daten zusammenbringen lassen. Wie kann man durch den Einsatz von Maschinellern Lernen auf Basis bestehender Daten gezielt vorhersagen, an welchen Stellen gemessen werden muss, um weiterführende Erkenntnisse zu gewinnen und/oder um die Güte eines bestehenden Modells zu verbessern? Dabei geht es nicht nur darum, Routineaufgaben zu automatisieren oder Arbeitsabläufe effizienter zu gestalten. Algorithmen des Maschinellen Lernens sollen dazu eingesetzt werden, ein tieferes Verständnis von Daten zu erhalten und komplexere Schlussfolgerungen zu ziehen, als es ohne ihren Einsatz möglich wäre. „Aus diesen neuen Arbeitsweisen ergeben sich wieder neue Herausforderungen. Die Algorithmen müssen nicht nur für Experten, sondern für alle WissenschaftlerInnen verständlich und nachvollziehbar arbeiten. Eventuelle einseitige Gewichtungen von Daten und dadurch entstehende Verzerrungen müssen erkennbar bleiben“, sagt Berens.

Die Weiterentwicklung von Maschinellern Lernen nimmt Fahrt auf. Doch wie lässt sich das Potential dieses Teilgebiets der künstlichen Intelligenz für die Wissenschaft voll ausschöpfen? Und wie wirken sich die damit einhergehenden Veränderungen auf die zukünftige Art zu Forschen aus?

denen sich ähnlich strukturierte Probleme finden. Bei der Aufgabe, verschiedene Forschungsfelder zu vereinen, profitiert der Cluster von der Erfahrung, die in den letzten Jahren im Tübinger Bernstein Center for Computational Neuroscience gesammelt worden ist. „Das BCCN institutionalisiert den Link zwischen Neurowissenschaften und dem Maschinellen Lernen. Die Art und Weise, wie das Zentrum beide Gebiete zusammenbringt, dient uns als Blaupause für das, was wir auch mit den anderen Wissenschaften vorhaben“, so Berens.

Aber wie kann man sich das in der Forschungspraxis vorstellen? ForscherInnen der Geowissenschaften verfügen beispielsweise dank aufwändiger, flächendeckender Messungen über

Techniken aus dem Maschinellen Lernen werden also mehr und mehr zum Handwerkszeug der Forschung. Doch überall dort, wo Aufgaben von Menschen übernommen oder Prozesse automatisiert werden, eröffnen sich neue, philosophische und wissenschaftsethische Fragestellungen. Welche Rolle werden WissenschaftlerInnen in Zukunft übernehmen? Wie werden sich wissenschaftliche Arbeits- und Herangehensweisen verändern? Um diese Fragen zu erörtern wurde in Zusammenarbeit mit WissenschaftlerInnen aus der Wissenschaftsethik und -philosophie das ‚Ethics & Philosophy Lab‘ gegründet. Philipp Berens verspricht sich daraus für den Cluster in Zukunft „große Chancen auf spannende, weil unkonventionelle Interaktionen.“ /njs/



MACHINE LEARNING
NEW PERSPECTIVES FOR SCIENCE

Looking from a practical point of view, what does this entail? Geoscientists, for instance, gain complex knowledge of soil formation thanks to elaborate and extensive measurements. Not least the current climate crisis requires investigations on how soil composition changes. The cluster investigates how to combine complex physical models and precise measurements. How can Machine Learning techniques help to predict which measurements must be conducted to gain further insights and improve the quality of existing models? This is not only about automating repetitive tasks or making workflows more efficient. Machine Learning algorithms are used to gain a deeper understanding of data and draw more complex conclusions than otherwise possible. “This will lead to new challenges. The algorithms and their potential biases must be coherent and comprehensible. Not only for experts, but for all scientists,” says Berens.

from ethics and philosophy of science. Philipp Berens sees a great chance in this as the cluster will benefit greatly from “these exciting and unconventional interactions”. /njs/

The development of Machine Learning is gathering speed. But how can Machine Learning play a key role in different aspects of scientific discovery? And how will this impact change the way research is conducted in the future?

In the future, Machine Learning techniques will become common tools in science. Yet, wherever computers take over tasks from people and where processes are automatized, philosophical and ethical issues arise. What will be the future role of scientists? How will scientific working methods and scientific approaches change? To tackle such questions, the ‘Ethics & Philosophy Lab’ was founded in cooperation with scientists



Together with Ulrike von Luxburg, Philipp Berens is the co-speaker of the Excellence Cluster ‘Machine Learning: New Perspectives for Science’ at the University of Tübingen.

© Albrecht/ Uni Tübingen

KI – Herausforderung für unsere gesellschaftliche Zukunft



Interview mit Stefan Heumann, Vorstand der Stiftung Neue Verantwortung

38

Herr Heumann. Sie sind Vorstand der Stiftung Neue Verantwortung, einem gemeinnützigen Think Tank in Berlin, der sich mit wirtschaftlichen, gesellschaftlichen und politischen Implikationen des technologischen Wandels befasst. Seit 2018 sind Sie Mitglied der Enquête Kommission ‚Künstliche Intelligenz – Gesellschaftliche Verantwortung und wirtschaftliche, soziale und ökologische Potenziale‘ des Deutschen Bundestages. Wie kam es dazu?

Ich bin 2013 zur Stiftung Neue Verantwortung (SNV) gekommen, um ein Digitalprogramm aufzubauen. Uns war dabei ein kollaborativer Ansatz sehr wichtig. Wir wollten Brücken zwischen Politik, Gesellschaft und Wirtschaft bauen und ExpertInnen aus ganz unterschiedlichen Bereichen zur Entwicklung von Lösungsvorschlägen zusammenbringen. Mit den Snowden Enthüllungen wurde die Debatte um Digitalisierung, Datenschutz und Überwachung in Deutschland dann richtig groß. 2014 kam die digitale Agenda der Bundesregierung. In den folgenden Jahren haben wir die SNV dann strategisch weiterentwickelt und uns das Ziel gesetzt, ein Think Tank für die Gesellschaft im technologischen Wandel zu werden.

Wie führte Sie das zur Enquête Kommission?

Künstliche Intelligenz ist ja kein neues Thema. Öffentliche Aufmerksamkeit erfuhr sie vor allem in den letzten drei Jahren durch Forschungserfolge und technologische Weiterentwicklung, gerade beim Einsatz von Maschinellem Lernen (ML). Wir fragen uns, was diese Technologie gesellschaftspolitisch bedeutet und wie sie internationale Beziehungen verändern könnte – geostrategisch, sicherheitspolitisch oder auch im Bereich Demokratie und Menschenrechte.

In vielen Ländern gibt es bereits nationale Strategien zur KI. 2018 haben wir eigene Eckpunkte für solch eine Strategie für Deutschland veröffentlicht. In diesem Kontext wurde ich gefragt, ob ich als Sachverständiger, neben VertreterInnen aus Wissenschaft und Wirtschaft, in der Enquête Kommission mitarbeiten möchte.

Sind wir durch die die großen Förderwellen des Bundes, und nicht zuletzt durch die Exzellenzstrategie, einer KI Strategie nähergekommen?

Ein Strategieprozess ist auf unterschiedlichen Ebenen wichtig. KI betrifft viele zentrale Bereiche unserer Wirtschaft, Gesellschaft und Politik, und wir brauchen einen übergreifenden Ansatz, wie wir damit umgehen wollen. Die Fördermaßnahmen des BMBF für KI gibt es schon lange, aber KI ist nicht nur für das Forschungsministerium relevant. Der Einsatz dieser Technologie wird Auswirkungen auf die Arbeitswelt und die Wettbewerbsfähigkeit unserer Wirtschaft haben. Dies erfordert zum einen ein Neudenken aller Ministerien bei unterschiedlichen Themen: Im Gesundheitsbereich sind es diagnostische Verfahren, die mit Maschinellem Lernen Ärzte unterstützen; autonomes Fahren ist schon länger ein Thema des Verkehrsministeriums. Zum Zweiten lenkt ein solches Strategiepapier öffentliche Aufmerksamkeit auf das Thema KI und signalisiert, dass es aus politischer Sicht für die BürgerInnen unseres Landes wichtig ist. Und nicht zuletzt müssen wir fragen: Wie gut ist die Strategie? Ist sie zielführend? Ist sie mit genügend Ressourcen ausgestattet? Drei Mrd Euro sollen über einen Zeitraum von sechs Jahren zur Verfügung gestellt werden, also 500 Mio jährlich – viel Geld, aber im internationalen Vergleich als Investition in eine Schlüsseltechnologie noch recht wenig. Abgesehen von der Summe finde ich es aber wichtig, dass ein Anfang gemacht ist.

Aus Forschungssicht ist in dieser Debatte um KI eine Dissonanz entstanden, was die Qualität der Forschung und den Forschungsstandort Deutschland angeht. Wie sehen Sie das, als jemand, der mit Forschenden sehr intensiv im Austausch steht?

Vieles wird zugespitzt. Aus meiner Sicht gibt es zwei Narrative, die miteinander konkurrieren.

Das eine Narrativ ist: Wir sind in Deutschland sehr stark aufgestellt. Wir haben eine starke Grundlagenforschung. Das Themenfeld wird in Deutschland for-

schungspolitisch schon seit vielen Jahren unterstützt. Wir betreten kein Neuland, denn mit dem Deutschen Zentrum für Künstliche Intelligenz (DZKI) oder dem Bernstein Netzwerk Computational Neuroscience gibt es starke etablierte Forschungsverbände zu diesem Thema.

Das andere Narrativ orientiert sich mehr am Wirtschaftssektor. Die großen Tech Unternehmen sind hier vorne dran, weil sie Zugang zu großen Datenmengen haben und auch Geschäftsmodelle, die auf diesen Datenauswertungen basieren. Facebook, Google oder Amazon haben selbst riesige Forschungszentren und werben herausragende Leute an. Auch innovative Start-Ups kommen zum großen Teil aus dem Ausland. Wir hinken hinterher.

Auch hier liegt die Wahrheit dazwischen. Wir haben exzellente Forschung aber wir haben nach wie vor ein Problem was den Transfer in neue Geschäftsideen angeht, die den Wirtschaftsstandort Deutschland voranbringen. Viele gute Nachwuchskräfte gehen nicht allein aus finanziellen Gründen ins Ausland, sondern auch wegen attraktiver Forschungsbedingungen. Eine wichtige Frage ist daher, wie wir die Bedingungen für exzellente Köpfe verbessern können.

Dieser ‚brain drain‘ ist nicht allein ein deutsches, sondern ein europäisches Problem. Die WissenschaftlerInnen initiieren europaweit Aufrufe an ihre Regierungen transnationale Forschung in Europa zu erleichtern.

Auch dies ist ein grundsätzliches Anliegen. Es gibt schon seit längerem Diskussionen, wie wir die Forschungslandschaft in Deutschland weiterentwickeln müssen. Ich sehe auch Reformbedarf im deutschen Forschungssystem – ich denke es geht darum, bessere Bedingungen zu schaffen, um Deutschland als Forschungsstandort im globalen Wettbewerb attraktiv zu machen, damit exzellente WissenschaftlerInnen in Deutschland eine Zukunft sehen.

Beim Lesen von Studien fällt auf, dass wir uns an Publikationsmengen oder Paten-

AI — Challenging our Future Societies

and member of Enquête Commission ‘Artificial Intelligence - Social Responsibility and Economic, Social and Ecological Potentials’ of the German Bundestag

Mr. Heumann. You are a board member of the Stiftung Neue Verantwortung (SNV), a non-profit think tank in Berlin dealing with the economic, social and political implications of technological change. Since 2018, you are a member of the Enquête Commission ‘Artificial Intelligence - Social Responsibility and Economic, Social and Ecological Potentials’ of the German Bundestag. How did this come about?

I joined the Stiftung Neue Verantwortung (SNV) in 2013 to set up a digital program in which a collaborative approach was very important to us. We wanted to build bridges between politics, society and business and connect experts from very different fields to develop solutions. With the Snowden revelations, the debate about digitization, data protection and surveillance reached a peak in Germany. 2014 was the year of the Federal Government’s digital agenda. In the years to follow, we developed SNV’s strategy further and aimed at becoming a think tank for societies in the midst of technological change.

How did this lead to the Enquête Commission?

Artificial Intelligence is not a new topic. Over the past three years, it gained more public attention through research successes and technological development, especially in the use of Machine Learning (ML). We ask what this technology implies socio-politically and how it could change international relations – geo-strategically, in terms of security policy or with regard to democracy and human rights.

Many countries do have national AI strategies already. In 2018, we published our own key points for such a strategy for Germany. In this context, I was asked whether I would like to work as an expert in the Enquête Commission together with representatives from academia and business.

Have we come any closer to an AI strategy as a result of the recent funding initiatives of the federal government, not least the Excellence Strategy?

A strategy process works on different levels. AI affects many central areas of our economy, society and politics, and we need an overarching approach of how we want to deal with it. The Federal Ministry of Education and Research (BMBF) funding initiatives for AI have been around for a long time, but AI is not only relevant for BMBF. The use of this technology will have an impact on the work environment and the competitiveness of our economy. For one, this requires a rethinking of all ministries: In the health sector, Machine Learning supports diagnostic methods; autonomous driving has long been an issue for the Ministry of Transport. Second, such a strategy paper draws public attention to AI and signals that it has a big political impact on our citizens. Last but not least, we must ask: How good is the strategy? Is it effective? Does it have sufficient resources? Three billion euros are to be made available over a period of six years, which is 500 million annually – a lot of money, but still very little as an investment into a key technology by international comparison. Leaving the actual amount aside, I think it is important that a start has been made.

From a research point of view, there is a discernable dissonance in the debate revolving around AI with regard to the research quality and Germany as a research location. What is your point of view as someone who is in very close contact with researchers?

I think many things are tapered. In my view, there are two narratives competing with each other.

One narrative goes as follows: We are well organized in Germany. We have strong basic research. AI has been supported through German research policies for many years. We are not breaking new ground. With the German Center for Artificial Intelligence (DZKI) or the Bernstein

Network Computational Neuroscience, there are strong established research alliances on this topic.

The other narrative is more oriented towards economics. The big tech companies are ahead since they have access to large amounts of data and work with business models that are based on these data analyses. Facebook, Google or Amazon have their own huge research centers and recruit outstanding people. Innovative startups are mainly based abroad, too. We are lagging behind.

Again, the truth lies in between. We have excellent research, but we still have a problem with transferring ideas into businesses to promote Germany as a business location. Many excellent young researchers go abroad, not only for financial reasons, but because of attractive research conditions. Therefore, the question is how we can improve the conditions for excellent minds.

This ‘brain drain’ is not only a German problem, but also a European one. Currently, scientists across Europe unite in appealing to their governments to facilitate transnational research in Europe.

This, too, is a fundamental concern. There have been discussions for quite some time on how we could develop the research landscape in Germany. I see a need for reform of the German research system – I believe we must offer better conditions to make Germany attractive as a research location by global standards, so that excellent scientists can picture their future in Germany.

Reading studies, one notices that their evaluations are guided by the number of publications or patent applications – key figures in everyday research; yet do they suffice to evaluate the actual quality of it? What do you think?

Naturally, the Ministry of Education and Research or the members of the German Bundestag would like to know: What are we good at? Which are our weak points?

tanmeldungen orientieren – Kennzahlen, die in einen Forschungsalltag gehören, aber ob sie ausreichen, ihn qualitativ zu bewerten? Was meinen Sie?

Natürlich möchte das Forschungsministerium oder die Abgeordneten des Bundestages wissen: Wo sind wir gut? Wo sind unsere Schwachstellen? Denn nur wenn man das erkennt, kann man eine gute Strategie entwickeln. Hier ist es m.E. auch wichtig, Klarheit zu schaffen und zu fragen: Wie viele Leute haben wir ausgebildet und wo arbeiten sie heute? Wie viele sind ins Ausland gegangen? Wie viele sind in Deutschland geblieben? Wie viele gehen in die Industrie, wie viele bleiben in der Forschung? Und im Umkehrschluss, wie viele Top Forscher haben wir aus dem Ausland anwerben können? Mit solchen Zahlen könnte man die Attraktivität des deutschen Forschungsstandorts bewerten, aber hierzu gibt es kaum Erhebungen.

Andere Indikatoren wie Patente, Publikationen und Konferenzteilnahmen sind m.E. auch relevant und wichtig, aber hier muss man sie in den Kontext einbetten und kritisch diskutieren. Trotzdem ist es interessant zu wissen, ob deutsche Forschung auf den führenden internationalen ML Konferenzen mit Papern vertreten ist und ob diese international zitiert werden. Das sollten wir uns anschauen und dennoch keinen Fetisch um diese Indikatoren betreiben. Schlussendlich geht es darum, ein empirisches Lagebild dieses KI Ökosystems (Wissenschaft, Wirtschaft, Gesellschaft) zu bekommen, um die Debatte zu fundieren und um Trends zu identifizieren. Dietmar Harhoff interessiert sich z.B. sehr für solche Ansätze. Man findet sie im Gutachten der Expertenkommission Forschung und Innovation oder in unserer Studie, wie man die Umsetzung einer KI-Strategie messbar machen könnte.

Oft wird gesagt, dass wir uns beim Thema KI die Butter vom Brot nehmen lassen. Haben wir uns zu lange auf der Wohlstandsschiene ausgeruht und nun den Zug verpasst? Oder gibt es für uns als Europäer einen dritten Weg im dipolaren Spannungsfeld zwischen China und USA?

Gerade um China gibt es einen großen Hype. Da passiert sehr viel aber man muss gerade bei den Indikatoren etwas vorsichtiger sein. Es gibt dort von Seiten der Regierung viel Druck. Deshalb werden auch viele Publikationen ‚produziert‘ und da sollte man aufpassen, was internationalen Maßstäben genügt. Klar ist aber, dass China im Bereich Forschung und Entwicklung sehr dynamisch ist.

Die entscheidende Frage ist die, die Sie gestellt haben. Wie gehen wir in Europa

damit um? Wir sind uns klar, was wir nicht wollen. Wir wollen nicht den chinesischen datengetriebenen ÜberwachungsKapitalismus. Wir wollen nicht den Einsatz von KI für Zensur oder den gläsernen Bürger. Wir wollen nicht das amerikanische, rein wirtschaftsgetriebene Modell. Wir wollen KI nutzen, um das Wohl der Gesellschaft zu gestalten. Hier ist eine starke öffentliche Forschung aus meiner Sicht wichtig. Deswegen ist auch die Frage der Summe der öffentlichen Förderung eine entscheidende, denn sie konkurriert mit den großen Tech Unternehmen. Dass man nie auf Augenhöhe agieren kann ist klar, aber WissenschaftlerInnen die Entscheidung zu erleichtern, indem man die Bedingungen verbessert, wäre ein wichtiger Schritt.

Eine zweite wichtige Komponente ist das Thema Daten. Wir haben nicht die großen Plattformen mit ihrer Aggregation riesiger Datensätze wie in den USA und China. In Europa haben wir eine sehr viel dezentralisiertere Datenlandschaft. Deshalb ist aus meiner Sicht der Aufbau von Dateninfrastrukturen in der Forschungslandschaft ein ganz wichtiges Thema, in das wir investieren müssen. Datenaufbereitung ist sehr aufwendig und auch der Punkt, an dem viele Anwendungen scheitern, denn oftmals liegen die Daten nicht in der Qualität vor, in der sie genutzt werden können. Einige Forschungsverbände vereinfachen den Austausch von Trainingsdaten, einzelne Institute legen Datensätze zusammen. Über Ähnliches müssen wir auch im Bereich der Industrie nachdenken.

Ein dritter Bereich – neben Forschung und der Frage nach Daten – ist für mich auch das Thema Arbeit. In der Öffentlichkeit wird oft gesagt, dass KI Arbeit ersetzt. Das wird vorkommen, aber es ist dennoch viel zu überspitzt formuliert. Wir haben in Europa und Deutschland sehr hoch qualifizierte Arbeitnehmer. Wie machen wir diese fit für das Arbeiten mit KI? Das ist eine große Herausforderung aber auch eine große Chance, weil sie nicht nur besser qualifiziert sind als in den USA oder China, sondern auch über ihre Betriebsräte starke Mitspracherechte haben. Auch Fachkräfte müssen vielleicht nicht in der Lage sein, ein neuronales Netz zu programmieren, aber sie sollten ein Grundverständnis für die Technologie haben, um produktiv mit ihr umgehen zu können. Hier müssten wir sehr viel stärker darüber nachdenken, wie KI Arbeit verändert und welche Kompetenzen wir brauchen.

Der Tübinger Exzellenzcluster ‚Machine Learning: New Perspectives for Science‘

setzt sich damit auseinander, was ML für das wissenschaftliche Arbeiten bedeutet. Aber auch in Unternehmen stellt man sich die Frage wie man der Entwicklung folgen kann, ohne selbst über passende Daten zu verfügen.

Da passiert zwar Einiges aber viele Unternehmen scheuen sich noch vor Datenkooperationen, weil sie befürchten, dass die Konkurrenz durch sie Einblicke in Geschäftsgeheimnisse erlangen oder Know-how abfließen könnte. Auf der anderen Seite haben wir in den letzten Jahren die Erfahrung gemacht, dass Unternehmen Partner brauchen, um den Mehrwert ihrer Daten überhaupt zu erkennen und Innovationen zu entwickeln. Deshalb veranstaltet beispielsweise die Deutsche Bahn Hackathons, um mit der Entwicklercommunity in Austausch zu kommen.

Lassen Sie uns zum Abschluss noch kurz über Zeit sprechen. Die Zeit drängt – immer. Wir müssen immer schneller sein, schneller auf neue Entwicklungen reagieren, Trends schneller erkennen. Wie schnell müssen wir sein?

Auf jeden Fall viel schneller. Sie hatten ja angesprochen, dass sich das Bild des Forschers wandelt, dass sich die Forschungszyklen beschleunigen, und dass sich diese Zyklen durch ML verkürzen. Wir leben in einer sich beschleunigenden, dynamischen Zeit aber unsere politischen Prozesse und Institutionen sind noch im 20. Jahrhundert verwurzelt. Noch führen wir keine ausreichende Diskussion darüber, wie diese Institutionen agiler werden können.

Auch in der Enquête KI möchten wir andere Austauschformate nutzen, um gemeinsam Ideen zu entwickeln und zu testen. Erste spannende Ansätze gibt es. Das Bundesarbeitsministerium hat eine Denkfabrik ‚Zukunft der Arbeit‘ eingerichtet. Ähnliche Bestrebungen sind in anderen Ministerien zu erkennen. Der politische Wille ist da. /cd/



Only if we are clear on these points, a good strategy can emerge. In my opinion, it is important to gain further clarity and ask: How many people have we trained and where do they work today? How many went abroad? How many stayed in Germany? How many went to industry, how many stayed in research? And by implication, how many top researchers did we recruit from abroad? Such figures could be used to assess the attraction of Germany as a research location, but there are hardly any surveys on this.

In my opinion, other indicators such as patents, publications and conference participation are relevant and important, but they must be embedded in the context and discussed critically. Yet, it is still interesting to know whether German research is represented with papers at the leading international ML conferences and whether these are cited internationally.

We should take a look at this but not create a fetish about these indicators. Ultimately, the aim is to obtain an empirical picture of this AI ecosystem (science, economy, society) in order to substantiate the debate and identify trends. Dietmar Harhoff, for example, is very interested in such approaches; they can be found in the report of the Expert Commission on Research and Innovation or in our study on how to measure the implementation of an AI strategy.

In the context of AI, it is often said that we let the bread be taken from our mouths. Did we rest on our prosperity oars for too long and now missed the boat? Or is there a 'third way' for us Europeans in the dipolar field of tension between China and the USA?

There's a big hype about China. A lot is happening here, but we have to be a little more cautious about indicators. Their government exercises a lot of pressure, which is why a lot of publications are 'produced' and one must carefully check their compliance with international standards. Yet, it is clear that China is very dynamic in research and development.

The crucial question is the one you asked. How do we deal with this in Europe? We are clear about what we do not want. We do not want a Chinese data-driven surveillance capitalism. We do not want AI to be used for censorship or for the transparent citizen. We also don't want the American, purely business-driven, model. We want to use AI to shape the well-being of society. In my view, strong public research is a key factor, here, which is why the question of the amount of public funding is a crucial one, as it competes with the big tech companies.

Clearly, we can never be on an equal footing, but improving conditions for scientists would be an important first step.

A second important component is the issue of data. We don't have the big platforms with their aggregation of huge data sets like the USA and China. In Europe, the data landscape is much more decentralized. I therefore believe that the development of data infrastructures in the research landscape is a very important issue which needs investing. Data editing is very complex and also the point at which many applications fail as it is often not available in sufficient quality to be used. Some research alliances simplify the exchange of training data, individual institutes compile data sets, and we also have to think about similar things for the industrial sector.

In addition to research and the question of data, I consider labor the third area. It is often said that AI replaces jobs. This will happen, but putting it like this is exaggerating the scope. We have very highly qualified workers in Europe and Germany. How do we make them fit for working with AI? This is a great challenge but also a great opportunity, because our workers are not only better qualified than in the USA or China, they also have strong rights of co-determination through their work councils. Even highly qualified employees don't have to be able to program a neural network, but they should have a basic understanding of the technology to be able to deal with it productively. We need to think a lot more about how AI changes work and which skills we need.

The Tübingen Excellence Cluster 'Machine Learning: New Perspectives for Science' focuses on the impact ML will have on scientific work. But companies also ask themselves how they can keep up with the development if they do not own suitable data.

There is a lot going on but some companies are still reluctant to share data because they fear that their competitors might gain insights into business secrets or that their know-how will drain off. On the other hand, we know that companies need partners in order to recognize the added value of their data and to develop innovations. That's why Deutsche Bahn, for example, organizes hackathons to get in touch with the development community.

Finally, let's talk briefly about time. Time is pressing – always. We have to be faster in all sorts of ways, react faster to new developments, recognize trends faster. How fast

do we have to be?

Definitely a lot faster. You mentioned that the profile of the researcher is changing, that research cycles are accelerating, and that these cycles are shortened by ML. We live in an accelerating, dynamic time, but our political processes and institutions are still rooted in the 20th century. We do not lead a sufficient discussion on how to make these institutions more agile.

In the Enquête AI, we are working towards other exchange formats to jointly develop and test ideas. There are first exciting attempts. The Federal Ministry of Labor has set up a 'Future of Work' think tank. Similar efforts can be seen in other ministries – this demonstrates the political intent. /cd/



**Stiftung
Neue
Verantwortung**

Think Tank für die Gesellschaft im technologischen Wandel

Neue Technologien verändern Gesellschaft. Dafür brauchen wir rechtzeitig politische Antworten. Die Stiftung Neue Verantwortung ist eine unabhängige Denkfabrik, in der konkrete Ideen für die aktuellen Herausforderungen des technologischen Wandels entstehen. Um Politik mit Vorschlägen zu unterstützen, führen unsere ExpertInnen Wissen aus Wirtschaft, Wissenschaft, Verwaltung und Zivilgesellschaft zusammen und prüfen Ideen radikal.

New technologies are changing society. Political answers to these challenges must be given in good time. The Stiftung Neue Verantwortung is an independent think tank which provides ideas specifically for current challenges of technological change. We support politics with proposals by joining expert knowledge from business, science, administration and civil society and put ideas to the acid test.

Neuromorphe Hardware für die nächste Generation KI

from science fiction

Markus Diesmann wirft einen Blick in die Zukunft der Computerentwicklung

42

Der Hype um die Science Fiction Serie Star Trek hat ein wenig abgenommen, die Faszination von den Möglichkeiten, die Computer uns in Zukunft eröffnen, bleibt jedoch ungebrochen. Nun mag die Entwicklung neuromorpher Computer Hardware, also von Computern, die nach den Prinzipien des Gehirns funktionieren, zunächst wenig revolutionär und aus Forschungssicht wenig praktikabel erscheinen: Wie kann man sie programmieren? Würden diese künstlichen Intelligenzen die gleichen Fehler machen wie wir? Würden sie in einer Zwischenphase der Entwicklung plötzlich irrationale und risikohafte Entscheidungen treffen? Berechtigte Fragen, die Viele umtreiben. Bei näherer Betrachtung liegt aber in neuromorpher Hardware der Schlüssel zu einem wissenschaftlichen Durchbruch, sowohl im Hinblick auf Maschinelles Lernen, als auch in der Weiterentwicklung von Künstlicher Intelligenz.

Verfahren des Deep Learning sind insbesondere dann gut geeignet, wenn für das Erlernen einer Aufgabe viele Beispiele zur Verfügung stehen. Dennoch ist das menschliche Gehirn im Alltag jeder KI überlegen. Dass man an einer roten Ampel stehen bleiben muss, kann man nicht an allzu vielen Beispielen testen. Auch die Hand-Auge Koordination, die wir wundervoll beherrschen, ist bei Robotern noch eher tollpatschig und unflexibel. Hier lohnt es sich, das Gehirn weiter zu erforschen, um seine komplexen Wechselwirkungen zu verstehen.

Jenseits der Inhalte, gibt es aber noch eine zentrale Herausforderung. Heutige KI Verfahren sind auf modernen Computern sehr schnell. Ihre Berechnungen beruhen auf der vielfachen schnellen Ausführung von Multiplikationen großer Tabellen, in der Mathematik Matrizen genannt. Diese sind dicht an dicht mit sogenannten Fließkomma-Daten, einem Datenformat, mit dem Zahlen mit vielen Stellen vor oder nach dem Komma genau erfasst werden können. Wir bezahlen dafür allerdings einen hohen Preis. Während das menschliche Gehirn etwa 20 Watt benötigt, (die Leistung einer modernen Glühbirne) benötigt ein Supercomputer hierfür 2 Megawatt. Was können wir also vom Energiesparer Gehirn lernen, um eine energie-effizientere Hardware zu bauen?

Das Forschungsgebiet der Computational Neuroscience, in Deutschland organisiert im Bernstein Netzwerk, arbeitet schon seit langem daran herauszufinden, wie das Gehirn funktioniert. Klar ist, dass es radikal anders arbeitet, als unsere heutigen Computer. Stellen wir uns zur Erläuterung die Verbindung von Nervenzellen als eine große Tabelle vor, bei der die Spalten die ausgehenden Verbindungen darstellen und die Zeilen, jene Verbindungen, die bei einem Neuron eintreffen. In solch einer Tabelle beschreibt ein einzelner Eintrag wie stark ein Neuron, das der Spalte ‚j‘ zugeordnet ist, ein Neuron, dem die Zeile ‚i‘ gehört beeinflusst. Gibt es keine Verbindung, ist der Tabelleneintrag null. Ob-

wohl ein Neuron 10.000 Verbindung mit anderen Neuronen hat, weisen diese Tabellen aufgrund der hohen Zahl von Neuronen fast nur Nullen aus. Selbst wenn es eine Verbindung zwischen zwei Neuronen gibt, passiert nur sehr selten etwas, denn Neuronen senden nur wenige Signale pro Sekunde. Die Berechnungen sind also dünn verteilt in Raum und Zeit – das genaue Gegenteil von heutigen KI Systemen. Computational Neuroscience schafft also die Grundlage für die nächste Generation von Künstlicher Intelligenz. Diese neuen Algorithmen können jedoch nur dann effektiv laufen, wenn das Forschungsgebiet Neuromorphic Computing eine dem Gehirn entsprechende Hardware zur Verfügung stellt.

Nun mag die Frage erlaubt sein, ob es denn überhaupt ein realistisches Szenario für die Entwicklung einer neuromorphen Hardware gibt? Die Antwort ist ‚Ja‘. Der Zellkörper eines Neurons hat einen Durchmesser von 20 Mikrometern. Ein moderner Transistor dagegen kommt mit 20 Nanometern aus. Das heißt, wir können heute schon Strukturen produzieren die 1000 Mal kleiner sind als die Strukturen im Gehirn. Auch die Anzahl der Elemente scheint kein fundamentales Problem zu sein. Ein moderner Prozessor kann 10 Milliarden Transistoren haben – das ist in etwa die Anzahl Neuronen im Cortex, jenem Teil des Gehirns, dem die höheren Hirnfunktionen zugeschrieben werden. Ein wesentliches Problem ist die Unterbringung der Leitungen. In einem Kubikmillimeter Gehirn gibt es 100.000 Nervenzellen, aber 3 km ‚Ausgangsleitungen‘ (die Axone) der Neuronen. Diese Dichte der Leitungen ist bis heute technologisch unerreicht. Ein wesentlicher Unterschied ist, dass das Gehirn dreidimensional verschaltet, während die heutige Halbleitertechnologie im Wesentlichen zweidimensional ist. Wie kann man also diese dreidimensionalen Strukturen elektro-nisch zweidimensional nachbilden?

In der Entwicklung konventioneller Prozessoren ist die USA zwar seit vielen Jahren führend, Europa hat aber bei der Entwicklung neuromorpher Systeme die Nase vorn. Das liegt zum einen an der systematischen Förderung durch die Europäische Union, maßgeblich im EU Flagship ‚Human Brain Project‘ (HBP). Zum anderen entwickelt und betreibt das Forschungszentrum Jülich in Deutschland Supercomputer für die deutsche Forschung und industrielle Partner. Neben den Arbeiten an den sogenannten Exascale Systemen (der Weiterentwicklung konventioneller Supercomputer,) werden in Jülich auch Quantum Computing und Neuromorphic Computing erforscht, um die Hardware der nächsten Generation zu entwickeln. Dabei geht es nicht darum einen Typus komplett zu ersetzen, sondern die Rechner der jeweiligen Aufgabe anzupassen und gemeinschaftlich einzusetzen. Kollegen an der Universität in Heidelberg verfolgen seit vielen Jahren eine neuromorphe Technologie, die bis zu 10.000 Mal schneller arbeitet als biologische Gehirne. Damit wäre es dann auch möglich, langsame Prozesse des Lernens und der Entwicklung zu erforschen.



Neuromorphic Hardware for the Next Generation AI

to science fact

Markus Diesmann Casts a Glance into the Future of Computer Development

The hype around the science fiction series Star Trek has waned over the past few years, yet, the fascination of the options computers might provide in the future, remains unbroken. At first glance, the development of neuromorphic computer hardware, i.e. computers that function according to the principles of the brain, may seem less revolutionary and even less feasible from a research point of view: How can they be programmed? Would these Artificial Intelligences make the same mistakes as we do? Would they suddenly make irrational and risky decisions in an intermediate phase of their development? Such questions bother many. When taking a closer look, however, neuromorphic hardware holds the key to a scientific breakthrough, both in terms of Machine Learning and the advancement of Artificial Intelligence.

Deep Learning methods are particularly successful if there are many examples available for learning a task. Still, in everyday life the human brain is superior to any AI. The fact that one has to stop at a red traffic light cannot be tested too often. Also, the robotic hand-eye coordination, something we master wonderfully, is fairly clumsy and inflexible. Here, it is worthwhile investigating the functionality of the brain in order to understand its complex interactions.

Yet, one central challenge remains beyond such topical investigations. Today's AI procedures are very fast on modern computers. Their calculations are based on the multiple rapid multiplications of large tables, the matrices mathematically speaking. These are densely filled with so-called floating point data, a data format accurately expressing numbers with many digits before or after the decimal point. The price we pay is high. While the human brain needs about 20 watts (the power of a modern light bulb), a supercomputer needs 2 megawatts for the same process. What can we learn from our brain, the energy saver, to build more energy-efficient hardware?

In Germany, the field of computational neuroscience, organized in the Bernstein Network, has long been working on finding out how the brain works. One point is set. The brain is working radically differently from today's computers. By way of an explanation, let us imagine the interconnection of nerve cells as a large table in which the columns represent the outgoing connections and the rows, those connections that arrive at a neuron. In such a table, a single entry describes how strongly a neuron assigned to column 'j' influences a neuron to which row 'i' belongs. If there is no connection, the table entry is zero. Although a neuron has 10,000 connections with other neurons, these tables show mostly zeros due to the high number of neurons. Even if there is a connection between

two neurons, very rarely anything happens, because neurons send only a few signals per second. Thus, the calculations are sparsely distributed in space and time — the exact opposite of today's AI systems.

Computational neuroscience thus provides the basis for the next generation of Artificial Intelligence. However, these new algorithms can only run effectively if the research field of neuromorphic computing will provide hardware in correspondence to the brain's functionality.

One may well ask whether the scenario for the development of neuromorphic hardware is realistic at all? The answer is 'yes'. The cell body of a neuron has a diameter of 20 micrometers. A modern transistor, on the other hand, is only 20 nanometers wide. Hence, we can already produce structures that are 1000 times smaller than the structures in the brain. The number of elements is not a fundamental problem either.

A modern processor may contain 10 billion transistors — roughly the number of neurons in the cortex, that part of the brain responsible for higher brain functions. A major problem is the packing of the wires. In one cubic millimeter of brain there are 100,000 nerve cells, but 3 km of 'output lines' (the axons) of the neurons. This density of wires cannot be reproduced by any present technology. One major difference is the fact that the brain is connected three-dimensionally, whereas today's semiconductor technology is essentially two-dimensional. So how can the three-dimensional structures be electronically reproduced in two dimensions?

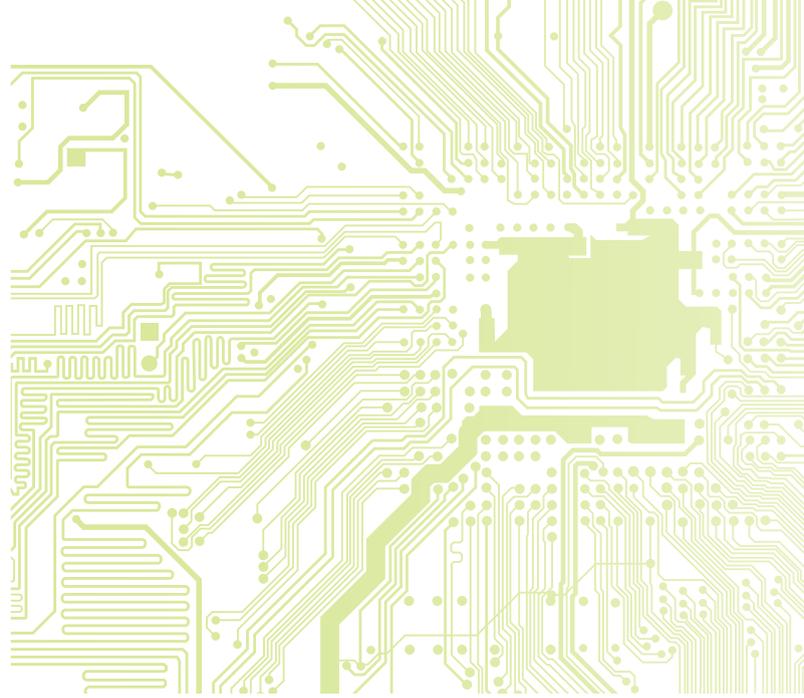
Although the USA has been a leader in the development of conventional processors for many years, Europe is leading the way in the development of neuromorphic systems. On the one hand, this is due to the systematic funding by the European Union, mainly in the EU Flagship 'Human Brain Project' (HBP). On the other hand, the Forschungszentrum Jülich in Germany develops and operates supercomputers for German research and industrial partners. In addition to developing so-called exascale systems (the further development of conventional supercomputers), however, quantum computing and neu-

43



M. Diesmann/ © Forschungszentrum Jülich

In Europa haben sich die Supercomputing und Neuromorphic Computing Experten in Jülich, Heidelberg, und Manchester zusammengeschlossen, um Künstliche Intelligenz mit einer geeigneten Hardware zu unterstützen – sie quasi neu zu denken. Als Leiter des Institute of Neuroscience and Medicine (INM-6) Computational and Systems Neuroscience am Forschungszentrum Jülich, freue ich mich über den kürzlich gelungenen Durchbruch in der Entwicklung neuromorpher Computer. Zusammen mit Partnern an der University of Manchester haben wir mit anderen europäischen Kollegen auf dem neuromorphen Computer SpiNNaker in Manchester ein neuronales Netzwerk natürlicher Dichte entsprechend einem Kubikmillimeter Gehirn simulieren. Dies klingt zunächst kleinräumig, es ist aber ein bedeutender Schritt, da alle größeren Netzwerke weniger dicht verschaltet sind und sich damit leichter simulieren lassen sollten. Vieles rückt dadurch in greifbare Nähe – auch einiges, was vor Jahren noch Science Fiction war. /M. Diesmann, Forschungszentrum Jülich/ cd/



The European Laboratory for Learning

ELLIS Letter

We are at a crossroads where

- 1. machine learning is at the heart of a technological and societal artificial intelligence revolution** involving multiple sister disciplines¹, with large implications for the future competitiveness of Europe,
- 2. Europe is not keeping up:** many of the top labs and top places to do a PhD are located in North America; moreover, AI investments in China and North America are significantly larger than in Europe, and
- 3. the distinction between academic research and industrial labs is vanishing,** with a significant part of the basic research now being done in industry (with substantial research freedom, and higher salaries), rapid commercialization of results, and academic institutions worldwide struggling to retain their best scientists (with negative implications not only for research but also for the education of future talent). This further weakens Europe since most of the companies doing top research in this field are controlled from the US (or China) – many European companies whose future business crucially depends on AI are not perceived as competitive.

There are still a few machine learning & perception research hotspots in Europe that play in the international top league. Virtually all of the top people in those places are continuously being pursued for recruitment by US companies. Even if we only wanted to retain these centers, we would need to increase our investments in line with what other countries are doing. To strengthen our position, we need to build on what is strong in Europe, think big and have the courage to try new models². We believe our best bet is for the outstanding centers in Europe to join forces.

European strength currently lies in its academic culture and well-educated students. There are some top university departments in the field, as well as some centers of excellence at Max Planck and CNRS/INRIA. Large US players

...se places. While a major motivation for ...
...t, the labs also strongly contribute to ...
...ore attractive for students and ...
...f high-level professionals, some of who

...for Learning and Intelligent ...
...LLIS*), involving the very best European ...
...y with basic researchers from industry. ...
...e in two ways:

...be performed in Europe, to enable ...
...ing and modern AI change the world, ...
...and create jobs in Europe, and believe ...
...free basic research, independent of

...ing infrastructure. ...
...ization (like EMBL, the European ...
...le the initial ELLIS letter only listed a ...
...om other countries have meanwhile ...
...very much welcome, along with ...
...excellence in countries such as Switzerland,

...er countries at the top academic sites for ...
...earch. This allows jump-starting ELLIS by ...
...affiliation and/or secondment of ...
...researchers across each country may be ...
...e links to local research institutions are

...archers (both from academia and ...
...nd summer schools for students, ...
...ants. Mobility is facilitated by housing, ...
...assistant professor to that of a full professor. This will ...
...towards avoiding brain drain to the US.

- ELLIS' unique characteristic is outstanding academic

... schools at each site. ...
...an PhD and MSc program in cooper ...
...The participating degree-granting in ...
...students in their MS and PhD program ...
...with no additional tuition charge, and ...
...s at these sites. ELLIS will provide f

...their time between ELLIS and loca ...
...reating an incentive for industry to ...
...s encouraged and structured usin ...
...re that public funding is used in i ...
...ch involving industry and publ

...startups based on IP they gen ...
...rt-term licensing income, and r ...
...Europe. To this end, it owns a ...
...no further rights as long as the ...
...thus generating downstream ir ...
...s startups in terms of (a) ger ...
...se of infrastructure, and (c) l

...financial advice. ...
...eadcount for personnel initi ...
...academics), but it does nee ...
...a plan how the funding rar ...
...the scale of a major Max F ...
...structure and an annual buc ...
...years.

...too slow: ELLIS should s ...
...faculty from the partner ii ...
...nt to outstanding individ ...
...non-academic skills. T ...
...sition from one of the ...
...plete career path within ...
...grams, from the equiva

...08.01.19.09.23 ...
...assistant professor to that of a full professor. This will ...
...towards avoiding brain drain to the US.

- ELLIS' unique characteristic is outstanding academic

...for instance by publicat ...
...field⁵. It does not preclu ...
...focus mainly on applied ...
...mission of excellence in

CHALLENGES

- There is no shortage of f ...
...attract outstanding rese ...
...researchers that determi ...
...people act as true talent ...
...recognized that money sp ...
...Europe, there are currentl ...
...us to attract such top peo ...
...professorships at ETH. Ou ...
...offer positions with outsta ...
...cooperation with Max Plan ...
...universities), with top pack ...
...• Since the field holds great ...
...of different sites to be ho ...
...be academic excellence

VISION

- ELLIS will perform fundame ...
...international industry rese ...
...major players in the future. ...
...and use of machine intelli ...
...improve the lives of people.
- ELLIS will be a top employe ...
...Berkeley, Stanford, CMU, and ...
...trained in the field: in conjun ...
...attractive European PhD prog ...
...graduates within ELLIS to gro ...
...scientists.
- Taken together, this means th ...
...the scientific and societal rev ...
...second industrial revolution n

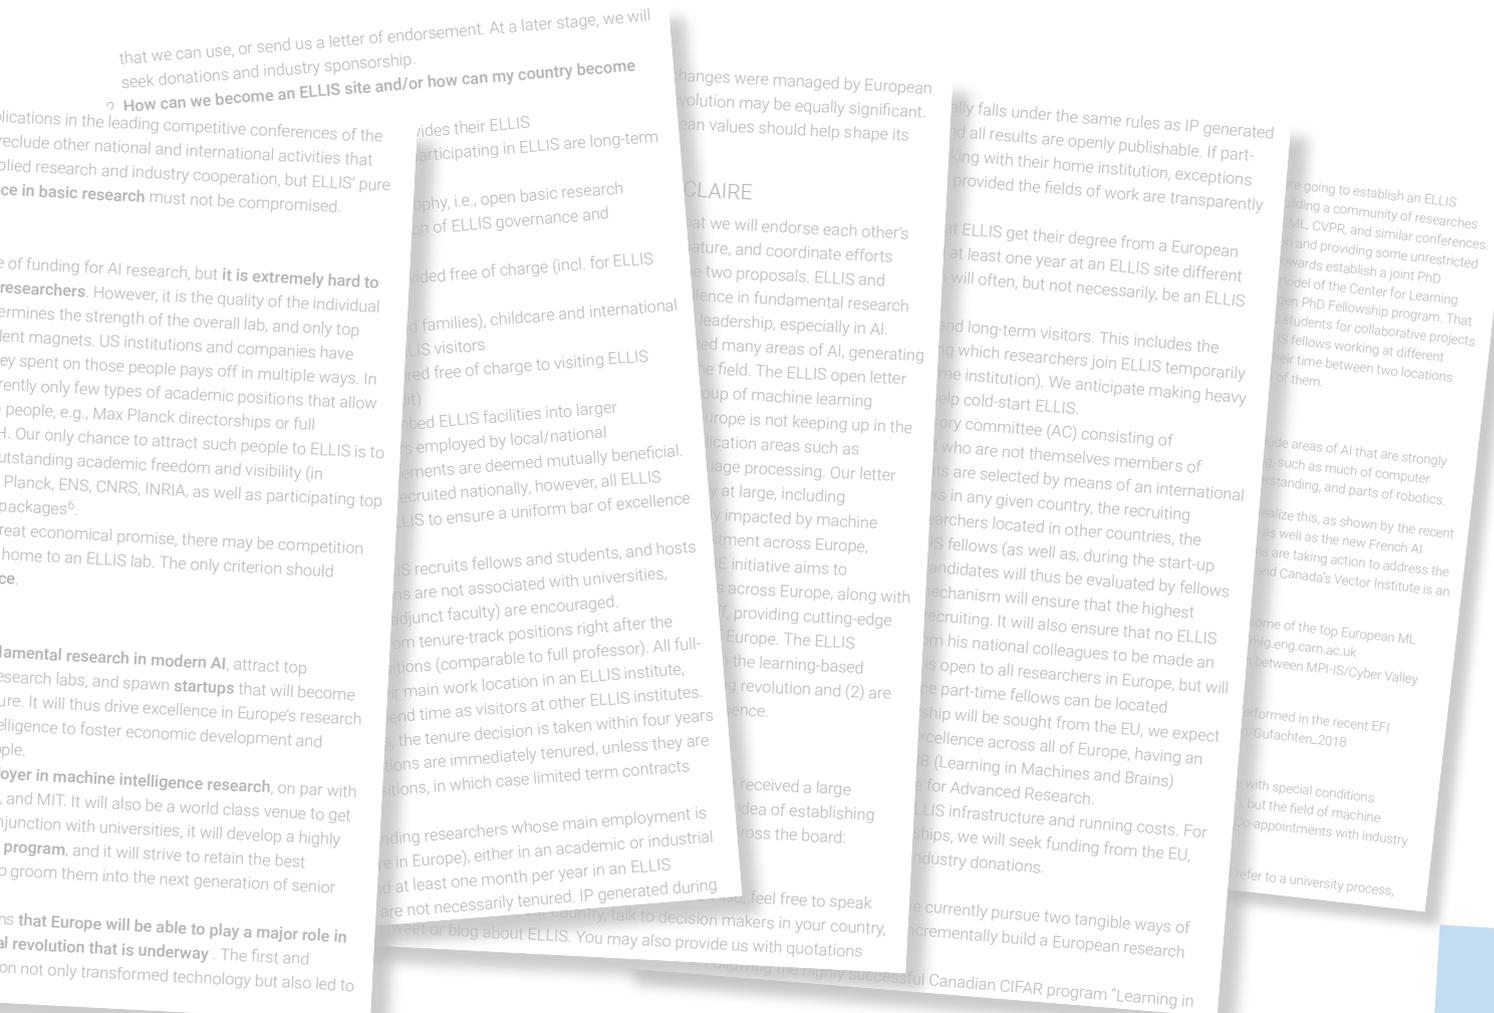
neuromorphic computing are also part of Forschungszentrum Jülich's agenda to develop the next generation of hardware. This is not meant to say that conventional systems will be replaced by the new type of supercomputer. Rather, computers will be adapted to particular tasks and used jointly. For many years, colleagues at Heidelberg University has been pursuing a neuromorphic technology which performs up to 10,000 times faster than biological brains. In turn, this might help to investigate slow processes of learning and development.

In Europe, the supercomputing and neuromorphic computing experts at Jülich, Heidelberg, and Manchester have joined forces to support Artificial Intelligence with suitable hardware – in other words: to rethink them. As head of the Institute of Neuroscience and Medicine (INM-6) Computational and Systems Neuroscience at the Forschungszentrum Jülich, I am delighted by the recent breakthrough in the development of neuromorphic computers. Together with our partners at the

University of Manchester and other European colleagues, we were able to simulate a neural network of natural density, the equivalent of a cubic millimeter of brain, on the neuromorphic computer SpiNNaker in Manchester. This might sound small, but it is an important step since all larger networks are less densely interconnected and should be easier to simulate. This brings much within reach – including things that were science fiction years ago.

/M. Diesmann, Forschungszentrum Jülich/ cd/

and Intelligent Systems ELLIS



European Laboratory for Learning and Intelligent Systems

The ELLIS mission is to create a diverse European network that promotes research excellence and advances breakthroughs in AI, as well as a pan-European PhD program to educate the next generation of AI researchers. ELLIS also aims to boost economic growth in Europe by leveraging AI technologies. /ellis.eu



Das Bernstein Netzwerk ist ein Forschungsnetzwerk auf dem Gebiet der Computational Neuroscience. Es vereint verschiedene wissenschaftliche Disziplinen wie Physik, Biologie, Mathematik, Medizin, Psychologie, Informatik, Ingenieurwissenschaften und Philosophie in dem Bestreben zu verstehen, wie das Gehirn funktioniert. Die enge Verknüpfung von neurobiologischen Experimenten mit theoretischen Modellen und Computersimulation ermöglicht es WissenschaftlerInnen des Bernstein Netzwerks, mit innovativen Ansätzen eine der komplexesten Strukturen zu erforschen, die die Natur im Laufe der Evolution geschaffen hat: das menschliche Gehirn.

Das Netzwerk startete 2004 mit einer Förderinitiative des Bundesministeriums für Bildung und Forschung (BMBF), um Forschungsstrukturen in der Computational Neuroscience bundesweit zu entwickeln und zu vernetzen und den Transfer theoretischer Erkenntnisse in klinische und technische Anwendungen zu fördern.

Das Netzwerk ist nach dem deutschen Physiologen und Biophysiker Julius Bernstein (1839-1917) benannt, dessen ‚Membrantheorie‘ die erste biophysikalische Erklärung dafür lieferte, wie Nervenzellen Informationen durch elektrische Ströme kodieren und übertragen.

***The Bernstein Network** is a research network in the field of computational neuroscience. It unites different scientific disciplines, such as physics, biology, mathematics, medical science, psychology, computer science, engineering and philosophy in the endeavor to understand how the brain functions. The close combination of neurobiological experiments with theoretical models and computer simulations allows scientists of the Bernstein Network to pursue innovative approaches with regard to one of the most complex structures nature has created in the course of evolution: the human brain.*

The network started in 2004 with a funding initiative of the Federal Ministry of Education and Research (BMBF) to develop and interconnect research structures in computational neuroscience throughout Germany and to promote the transfer of theoretical insight into clinical and technical applications.

It is named after the German physiologist and biophysicist Julius Bernstein (1839-1917) whose ‚Membrane Theory‘ provided the first biophysical explanation for how nerve cells encode and transmit information by electrical currents.

Impressum / Imprint

Herausgeber/ Publisher

Dr. Alexandra Stein
Bernstein Koordinationsstelle (BCOS)
eine Außenstelle des Forschungszentrums Jülich
an der Albert-Ludwigs-Universität Freiburg
Bernstein Coordination Site (BCOS)
Branch Office of the Forschungszentrum Jülich
at the University of Freiburg
bernstein.network@fz-juelich.de
www.bernstein-network.de

Chefredaktion/ Editor in chief

Claudia Duppé

Redaktion/ Editors

Nikola Schwarzer, Alexandra Stein

Autoren/ Authors

Claudia Duppé (cd), Nikola Schwarzer (njs)
wie angegeben/ as stated below the article

Gestaltung/ Layout

Claudia Duppé

Druck/ Print

Schwarz auf Weiss, Freiburg

Fotohinweise/ Photo credits

Bernstein Network
sonst wie angegeben/ unless otherwise stated

Cover Bild/ Cover image

Grafik modifiziert nach/ modified after G. Johnson/ Pixabay

