

Kognitiver sequentieller Parallelismus: Von kanonischen neuronalen Schaltkreisen und dem Training rekurrenter neuronaler Netze für perzeptuelle Entscheidungsfindungen¹

Tobias Brosch²

Abstract: Die Entwicklung autonomer Fahrzeuge zeigt einmal mehr die Schwierigkeiten der visuellen Informationsverarbeitung. Während es Menschen scheinbar mühelos gelingt den visuellen Informationsstrom auszuwerten, bedarf es bei technischen Anwendungen leistungsstarker/energieintensiver GPUs. Neuromorphe Hardware, welche vom Gehirn inspiriert Millionen von Neuronen simuliert, zeigt hier alternative Ansätze für hochgradig skalierbare und energieeffiziente Lösungen [Me14]. Bestehende Algorithmen aus der Computer Vision lassen sich jedoch nur selten auf solche Hardware portieren [Es13]. Vielmehr bedarf es neuer Algorithmen um die Leistungsfähigkeit neuromorpher Systeme zu nutzen. Hierzu trägt meine Arbeit unmittelbar bei. Durch die Modellierung dynamischer Prozesse mit direktem Bezug zur visuellen Informationsverarbeitung im Gehirn und deren mathematischer Analyse wird die Basis geschaffen, um skalierbare und komplexe Systeme zu modellieren. Die Entwicklung eines ereignisbasierten Algorithmus zur optischen Flusschätzung und eines Lernalgorithmus für simultan rekurrente Netze ermöglicht ein verbessertes Verständnis von neurophysiologischen Untersuchungsdaten aber auch die Entwicklung neuer Anwendungen für extrem parallele (GPUs) und/oder neuromorphe Hardware.

Keywords: Neuromorphic computing, machine learning, neural dynamics, event-based sensing

1 Einleitung

Um die Funktionalität des menschlichen Gehirns besser zu verstehen und die gewonnenen Erkenntnisse in Algorithmen zu überführen, wurden in den vergangenen Jahrzehnten eine Vielzahl von anatomisch-physiologischen Studien durchgeführt. Eine Vielzahl an Belegen deutet darauf hin, dass kortikale Areale in einer reziprok verbundenen Verarbeitungshierarchie angeordnet sind, welche primär von sensorischen Daten angeregt werden (z.B. visuellen Stimuli). Dabei interagieren verschiedene Areale sowohl lateral (intern) als auch mit vorangehenden Arealen [FVE91]. Verschiedene Studien zeigen eine Asymmetrie zwischen diesen vor- und rückwärts gerichteten Verbindungen [Sp02, LSL04]. Während Aktivität primär von vorwärts gerichteten Verbindungen hervorgerufen wird, modulieren rückwärts gerichtete Verbindungen diese Aktivitäten, um sie zu verfeinern und aufgabenrelevante Merkmale hervorzuheben. Weiterhin wurde gezeigt, dass diese Interaktion zu dem *kanonischen* Verarbeitungsmechanismus der so genannten *Normalisierung* führen kann, welche die Aktivität begrenzt und somit das visuelle Perzept stabilisiert [BMC05, CH12, BN12].

¹ Englischer Titel der Dissertation: "Cognitive Sequential Parallelism: From Canonical Neural Circuits to Training Recurrent Neural Networks in Perceptual Decision-Making" [Br15]

² Institut für Neuroinformatik, Ulm University, James-Franck-Ring, 89081 Ulm, Deutschland, tobias.brosch@uni-ulm.de

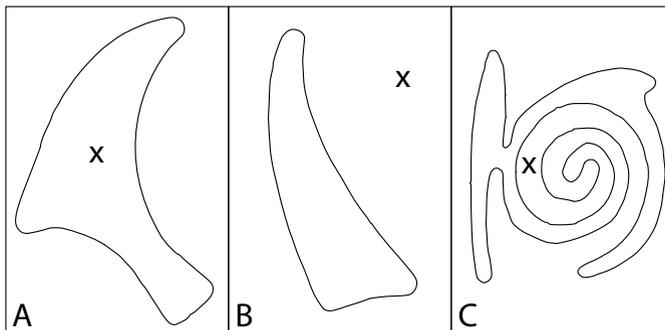


Abb. 1: Während es in den Fällen **A** und **B** fast instantan möglich ist zu bestimmen, ob der markierte Punkt innerhalb oder außerhalb der Kontur liegt (Indiz für parallele Verarbeitung), ist dies im Fall **C** schwieriger. Empirische Untersuchungen zeigen, dass die beobachteten Verarbeitungszeiten konsistent mit einer seriellen Abarbeitung des Stimulus sind [TG80]. Reproduziert aus [U184].

Entlang der Verarbeitungshierarchie nimmt die Größe der rezeptiven Felder von Zellen sowie die Komplexität der repräsentierten Merkmale zu (von einfachen Kontrasten bis hin zu komplexen Formen und Objekten). Die Einfachheit einer rein vorwärts gerichteten Verarbeitungshierarchie (im Gegensatz zu rekurrenten Interaktionen) führte in den vergangenen Jahren zu einer Vielzahl von sehr erfolgreichen Objekterkennungsnetzen [Sz14]. Nicht alle Aufgaben können jedoch in einer rein vorwärts gerichteten Verarbeitungshierarchie gelöst werden (c.f. Abb. 1), was sich unter anderem in Fehlklassifikationen solcher Netzwerke bei nur kleinen Änderungen der Eingabedaten niederschlägt [Sz13].

Um noch universellere und stabilere Netzwerke zu konzipieren, gilt es also ein besseres Verständnis von vor- und rückwärts gerichteten Verbindungen zu erlangen. Dazu habe ich im Rahmen meiner Arbeit [Br15] dynamische Modelle kortikaler Kolumnen (i.e. lokale Ansammlungen mehrerer stark vernetzter Nervenzellen) mathematisch analysiert. Mithilfe der Ergebnisse wurden anschließend Modelle konzipiert und trainiert, welche eine Vielzahl neurophysiologischer Untersuchungsdaten im Kontext der perzeptuellen Entscheidungsfindung erklären. So tragen die Ergebnisse u.a. zu einem besseren Verständnis von dynamischen Bildverbesserungsmechanismen wie z.B. kontrastabhängigen rezeptiven Feldgrößen, orientierungskontrastabhängigem Antwortverhalten oder kohärenter Signalamplifikation bei. Weiter wurde unter anderem ein neuer Algorithmus zur optischen Flusschätzung auf Basis von event-basierten Sensordaten sowie ein Lernalgorithmus für rekurrente neuronale Netze entwickelt [BSN13, Br15]. Zusammenfassend verbessern die erzielten Ergebnisse das Verständnis über die Funktion der Informationsverarbeitung des Primaten-Gehirns, schaffen aber auch die Grundlage für technische neuronal inspirierte Algorithmen, von denen bereits einige in der Arbeit umgesetzt wurden.

2 Interaktion vor- und rückwärts gerichteter Verarbeitungspfade mit Normalisierung

Zur formalen Beschreibung der Dynamik und der komplexen Interaktion von Neuronen wurden Raten-Code Modelle gewählt, die das mittlere Membranpotential von Neuronengruppen repräsentieren (beschrieben in Abb. 2). Diese stark vernetzte Ansammlung mehrer

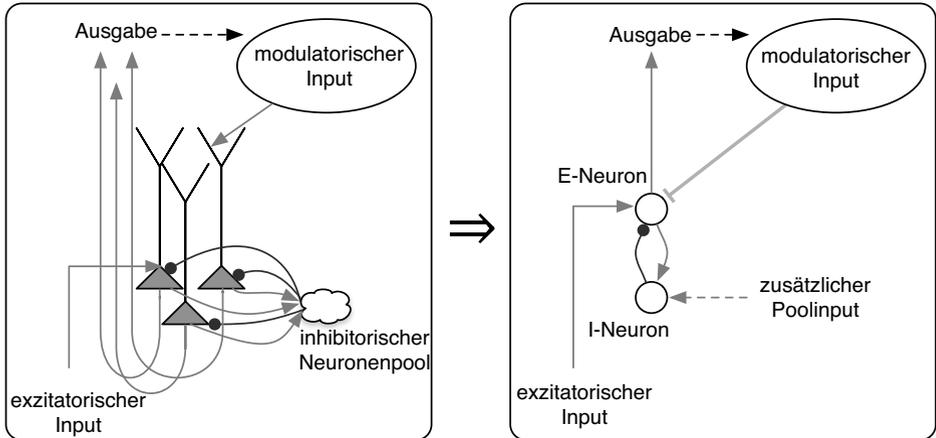


Abb. 2: **Kortikale Kolumnen als E-I-Neuronenpaar.** **Links:** Vereinfachte Abbildung von Zellen einer kortikalen Kolumne. Exzitatorischer Input (Pfeillinienenden) generieren Aktivierungen, die von Interneuronen, welche eine lokale Nachbarschaft hemmen (runde Linienenden), gesammelt werden (Normalisierung). Die Ausgabe wird in höher gelegenen Arealen mit weiteren Informationen fusioniert und koppelt so gewonnene Kontextinformationen an distale Lokationen ein. **Rechts:** Diese Verarbeitungsmechanismen können vereinfacht durch ein exzitatorisch-inhibitorisches (E-I) Neuronenpaar abgebildet werden. Dabei werden Interneurone durch eine inhibitorische Zelle und Pool-Input realisiert. Kontextbezogener Input kann durch modulatorische Interaktion den Einfluss distal koppelnder rückwärtiger Verbindungen abbilden (flache Linienenden). Reproduziert von [Br15].

rer geschichteter Neurone führt zu einem Gesamtverhalten, welches zur Erklärung vieler Untersuchungsdaten bereits ausreicht, ohne jedoch die Komplexität von z.B. spikenden multi-Kompartiment-Modellen mit sich zu bringen [LSL04, BN14b]. Um die Asymmetrie zwischen vorwärts- und rückwärtsgerichteten Verbindungen abzubilden, wirken in dem untersuchten Modell rückwärtige Signale (Feedback) modulatorisch, d.h. derartige Signale können bestehende (z.B. durch exzitatorische Verbindungen ausgelöste) Aktivitäten verstärken, aber nicht alleinig ohne gleichzeitige Signaleingabe hervorrufen. Hierdurch können selektiv aufgabenrelevante Aktivierungen verstärkt werden, welche durch lokale Interaktion simultan zu einer Abschwächung der Repräsentierungen von Distraktoren führen. Die Interaktion ist in Abb. 3 skizziert und kann vereinfacht wie folgt formuliert werden:

$$\dot{r} = -\alpha \cdot r + (\beta - r) \cdot (I + \gamma_{SE} \cdot g_r(r)) \cdot (1 + \lambda \cdot net^{FB}) - \gamma \cdot r g_p(p), \quad (1)$$

$$\dot{p} = -p + \beta_p \cdot g_r(r) + I_c, \quad (2)$$

wobei r und p das Membranpotential eines exzitatorischen (E) bzw. inhibitorischen (I) Neurons, I der exzitatorische Input des E-Neurons, I_c der exzitatorische Input des I-Neurons

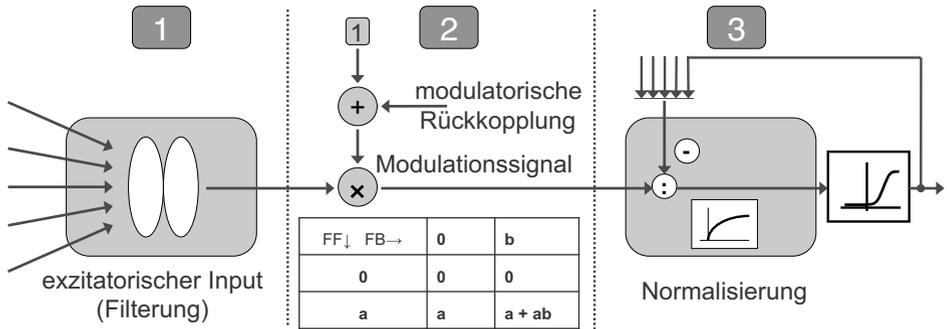


Abb. 3: **Dreistufige Hierarchie des Modells einer kanonischen Kolumne.** (1) Der Input wird durch Filterantworten der ersten Stufe generiert. (2) Die Kombination aus modulatorischer Rückkopplung b (feedback; FB) und exzitatorischem FF Input a erhöht die Aktivierung um die Korrelation $a \cdot b$. Ohne exzitatorischen Input (feedforward (FF); obere Tabellenreihe) wird keine Aktivierung generiert. (3) Die Ausgabestufe realisiert eine Normalisierung der Energie durch die Interaktion mit einem lokalen Pool von Neuronen.

From Tobias Brosch and Heiko Neumann, "Computing with a Canonical Neural Circuits Model with Pool Normalization and Modulating Feedback", *Neural Computation*, 26:12 (December, 2014), pp. 2735-2789. © 2014 by the Massachusetts Institute of Technology.

und net^{FB} der modulatorische Input des E-Neurons sind. Der Parameter β ist die obere Aktivitätsschranke des E-Neuron und $\alpha, \gamma_E, \lambda, \gamma, \beta_p$ sind Verstärkungsfaktoren der verschiedenen Interaktionskomponenten (siehe [BN14a] für weitere Details).

Durch die mathematische Analyse des Phasenraums und der Equilibria konnten verschiedene Parameterbereiche identifiziert werden, in welchen das System stabil ist, oszilliert oder instabile Interaktionen zeigt. Hierdurch trugen die Ergebnisse in weiteren Untersuchungen zur Entwicklung von Modellen bei, welche eine Vielzahl von elektrophysiologischen Untersuchungsdaten erklären und technische Modelle für neuronale dynamische Signalverbesserung beschreiben. Darunter sind die Verstärkung schwacher und Hemmung starker Signale, kontrastabhängige rezeptive Feldgrößen, verschiedene Arten der Aufmerksamkeitsmodulation, kohärente Signalamplifikation, sowie orientierungskontrastabhängiges Antwortverhalten mit nur geringen Parameteränderungen [BN14a]. Darüber hinaus wurde in einem separaten Beitrag gezeigt, dass das untersuchte Modell auf der verwendeten Modellierungsebene kohärent mit Untersuchungsdaten zur Elektrophysiologie von Einzelzellen im visuellen Kortex sowie detaillierten Modellen hierzu ist, jedoch einen geringeren Rechenaufwand benötigt [BN14b]. Die Vielzahl der erklärten Untersuchungsergebnisse bestätigt somit die bereits zuvor postulierte kanonische Eigenschaft der Normalisierung, die durch den E-I-Schaltkreis realisiert wird [CH12]. Zusätzlich schafft die mathematische Analyse und das dadurch vertiefte Verständnis die Grundlage zur Realisierung komplexer neuronaler/technischer Systeme, in denen eine Vielzahl von Neuronen miteinander interagiert ohne instabil zu werden.

3 Ereignisbasierte Verarbeitungsalgorithmen

In weiteren Untersuchungen wurde gezeigt, dass der kanonische Mechanismus der Normalisierung ebenfalls zur Verbesserung optischer Flusssschätzung dienen kann. Im Kontext energieeffizienter neuromorpher Hardware wurde hierzu ein neuartiger Algorithmus zur optischen Flusssschätzung entwickelt, welcher ereignisbasierte Daten eines neuromorphen asynchronen Bildsensors verarbeitet (beschrieben in Abb. 4). Dazu wurden Untersuchungs-

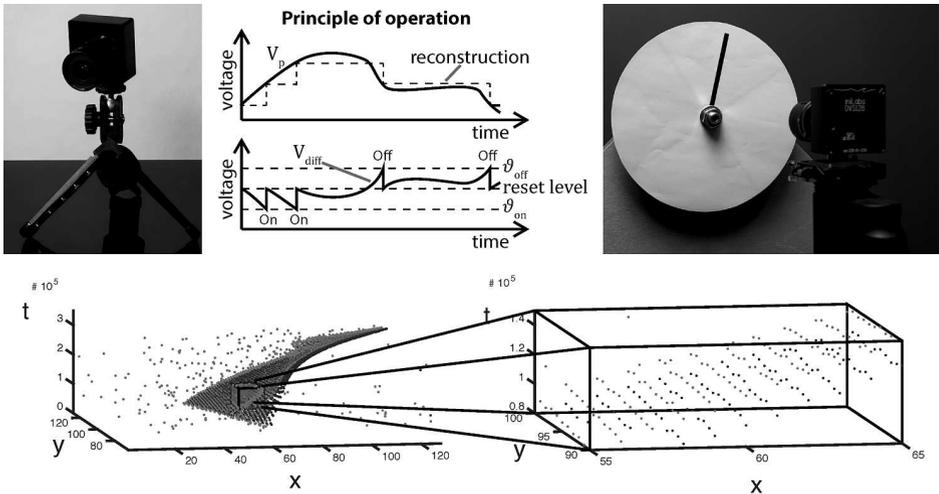


Abb. 4: **Asynchroner Bildsensor.** Oben (von links nach rechts): Bild, Verarbeitungsprinzip und Stimulusgenerierung eines asynchronen Bildsensors. Helligkeitsänderungen, welche eine gegebene Schwelle überschreiten, führen zu ON bzw. OFF Ereignissen. Die sehr geringe Latenz des dynamischen Bildsensors ($15\mu.s$) benötigt eine analoge Stimulusgenerierung (rechts). Nach [LPD08]. Unten: Visualisierung der Raum-zeitlichen Ereigniswolke, welche von einem rotierenden Balken als Eingabe (oben rechts) generiert wird.

Reproduziert von [BTN15] published under the terms of the Creative Commons Attribution License (CC BY) <http://creativecommons.org/licenses/by/4.0/>.

ergebnisse von [De00] verwendet um einen Filter zu generieren, welcher auf raum-zeitliche Änderung reagiert. Der neuartige Filter wird durch Invertierung der Singularwertzerlegung des rezeptiven Felds von bewegungssensitiven Zellen von [De00] generiert (c.f. [DOF95], dortige Abb. 3). Jeder der beiden Filter setzt sich separabel aus einem bi-phasischen temporalen und einem geraden räumlichen Filter oder einem mono-phasischen temporalen und einem ungeraden räumlichen Filter zusammen.

Weiter wurde gezeigt, dass Normalisierung hilft ein typisches Problem der optischen Flusssschätzung zu reduzieren. Dieses ist das so genannte Aperturproblem. So ist bei 1D Strukturen, wie z.B. einer geraden Kontrastkante, nicht klar, wie stark sich die Kante parallel zu der Kante bewegt, sondern lediglich wie stark die Bewegung orthogonal dazu ist. 2D Strukturen wie z.B. Eckpunkte hingegen erlauben eine eindeutige Bestimmung der Bewegungsrichtung und Geschwindigkeit. In Experimenten konnte gezeigt werden, dass der kanonische Mechanismus der Normalisierung (c.f. Abschnitt 2) dieses Problem lösen kann, indem Aktivierungen entlang der Kante reduziert und Aktivierungen an Ecken hervorgehoben werden. Dadurch bekommt die Schätzung durch Neurone an den Ecken

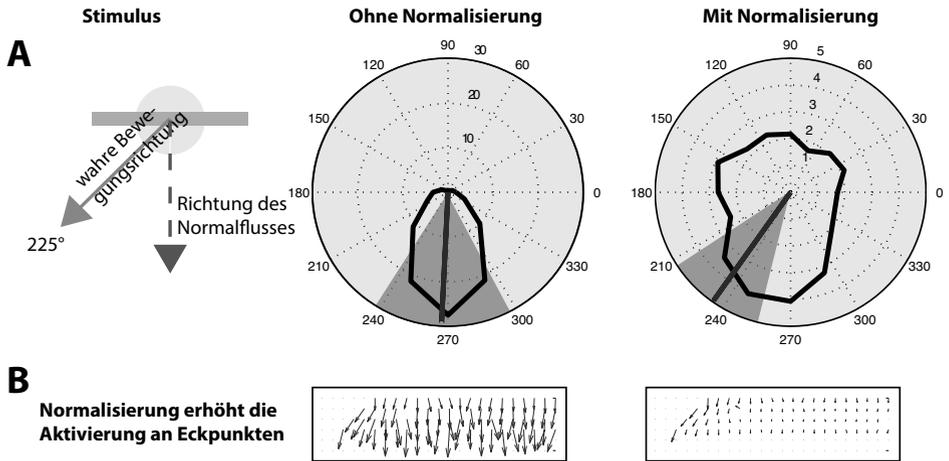


Abb. 5: **Normalisierung verbessert signifikant die initiale Bewegungsschätzung** einer geraden Kante, welche sich mit 45° Winkeldifferenz zu ihrer Orientierung bewegt. **A, linkes Histogramm:** Initial dominiert die Aktivierung der Zellen in Richtung des Normalflusses (blaue Linie; blaue Fläche gibt Standardabweichung an). **A, rechtes Histogramm:** Normalisierung durch die lokale Nachbarschaft erhöht die Aktivierung an den Ecken und hemmt die Aktivierung entlang der Kante (**B**), sodass die Schätzung stärker in Richtung der wahren Bewegungsrichtung zeigt und somit das Aperturproblem minimiert (**A, rechts**) (c.f. [Gu06, Ts10]).

Nach [BTN15] published under the terms of the Creative Commons Attribution License (CC BY) <http://creativecommons.org/licenses/by/4.0/>.

eine stärkere Gewichtung als Neurone entlang von Kanten, was durch Feedback-Interaktion weiter verbessert werden kann (Abb. 5; [Ts14, BTN15]).

Zusammenfassend zeigen die Untersuchungsergebnisse, dass die kanonische Operation der Normalisierung auch zur Signalverbesserung von optischen Flussignalen basierend auf event-basierten Daten eines neuromorphen Sensors eingesetzt werden kann. Weiterführend konnte gezeigt werden, dass der neu entwickelte Filter aufgrund seiner Separierbarkeit nicht nur auf konventioneller, sondern auch auf neuromorpher Hardware effizient implementiert werden kann. Dazu wurde im Rahmen der Arbeit gezeigt, wie sich die analysierten neuronalen Mechanismen auf einem konkreten spikenden neuromorphen Chip (IBM; TrueNorth-Chip) realisieren lassen ([Br15], Appendix A). Noch spezifischer wurde in anschließenden Arbeiten skizziert, wie eine konkrete Implementierung den event-basierten Eingabestrom in Echtzeit mit nur geringem Energieaufwand (ca. 72mW) analysieren kann [BN15].

4 Verarbeitung und Lernen in rekurrenten neuronalen Netzen

Wie bereits in der Einleitung diskutiert, führt die Konstruktion immer größerer neuronaler Algorithmen/Netze zu Problemen in der Parameterwahl, sodass Lernalgorithmen eine immer größere Bedeutung zukommt. Weiter wurde dargelegt, dass rein vorwärts gerichtete (feedforward) Netze in ihrem Funktionsumfang limitiert sind (c.f. Abb. 1). Daher wurde im Rahmen meiner Arbeit ein Lernalgorithmus für rekurrente neuronale Netze entwickelt (REinforcement LEARNING in Recurrent Neural Networks; RELEARNN), welcher durch

laterale Interaktionen und rückwärts gerichtete Verbindungen (Feedback) zu einer Stabilisierung der internen Repräsentationen, aber auch zur Etablierung neuer, in feedforward Netzen nicht möglichen, funktionalen Strukturen beitragen kann. So können beispielsweise Aufgaben, wie das mentale Verfolgen statischer beliebig geformter Linien um z.B. deren Anfang und Ende zu finden (c.f. Abb. 1C) nur mit kombinatorischer Komplexität in reinen feedforward Netzen gelöst werden [MP87], wohingegen in meiner Arbeit eine derartige Aufgabe in einem trainierten rekurrenten Netz gelöst wurde. Die Interaktion zwischen Neuronen ist dabei wie folgt gegeben (E-I-Paare wie in Gl. (1) können hier durch Lernen etabliert werden; $I^{ex,inh,mod}$ beschreiben die Summe aller eingehenden Aktivierungen für jede Unit):

$$\frac{d}{dt}p = -\alpha p + (\beta - p) \cdot I^{ex} \cdot (1 + \gamma I^{mod}) - (\zeta + p) \cdot I^{inh}, \quad (3)$$

wobei β und δ die obere bzw. untere Schranke sind und α, γ die Abklingrate und den Einfluss von modulatorischem Feedback beschreiben. Dabei wurde mathematisch eine Beziehung zu früheren Arbeiten rekurrenter Rückpropagation von Almeida und Pineda im speziellen Fall des Reinforcement Lernens hergeleitet [Al87, Pi87], welches eine Übertragung von Eigenschaften wie z.B. Stabilitätsbeweisen zulässt. Zusätzlich wurde eine dreistufige Beschreibung mit lokalen Interaktionen entwickelt, welche nun eine testbare Hypothese für künftige Untersuchungen darstellt (c.f. Abb. 6): In einer *ersten Phase* wird

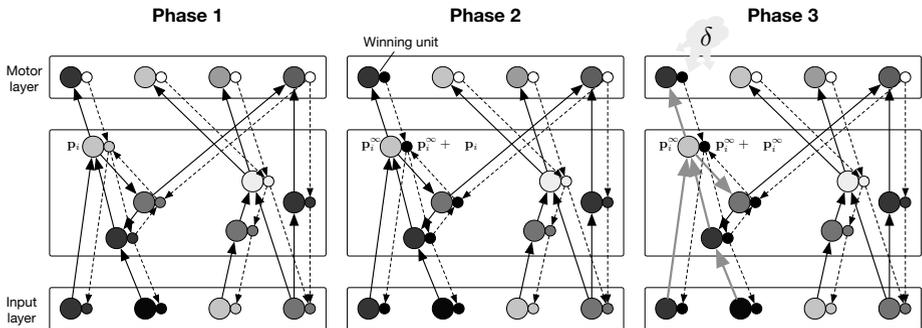


Abb. 6: **Illustration der Lernphasen.** Für die Propagation des Lernsignals gibt es zu jeder regulären Unit (große Kreise) eine *accessory* Unit (kleine Kreise). **1)** Sensorischer Input führt zu einem stabilen Zustand p^∞ der regulären Units. Dabei repräsentieren Units in der Ausgabeschicht durch ihre Aktivierung die erwartete Belohnung für den Fall, in welchem die mit den Ausgabeunits assoziierte Aktion ausgeführt wird. **2)** Die gewinnende Ausgabeunit injiziert zusätzliche Aktivität in das *accessory* Netzwerk, welches reziproke Verbindungsgewichte wie das reguläre Netzwerk hat. Dabei haben *accessory* Units, deren assoziierte reguläre Unit einen starken Einfluss auf die Aktivierung der gewinnenden Unit hat, eine starke Aktivitätserhöhung Δp in dieser Phase. **3)** Synaptische Änderungen hängen von Δp und einem globalen Belohnungsvorhersagefehler δ ab. Reproduziert von [BNR15]. Siehe [BNR15] für weitere Details.

das reguläre rekurrente Netzwerk aktiviert. Units in der Ausgabeschicht werden darauf trainiert, die erwartete Belohnung der mit ihnen assoziierten Aktion zu kodieren und stehen in einer Konkurrenz um die auszuführende Aktion. Um das Lernsignal zu bestimmen, wird in der *zweiten Phase* ein zum regulären Netzwerk reziprokes *accessory* Netzwerk durch die

gewinnende Unit aktiviert. Die Aktivierungen im regulären r_k^∞ als auch im *accessory* Netzwerk $r_k^\infty + \Delta p_l^\infty$ werden dann in der *dritten Phase* (initiiert durch ein globales Lernsignal) zur Gewichtsadaptation ΔW_{kl} verwendet. Die Veränderung der Verbindungsstärke ΔW_{kl} von Unit k zu Unit l ist dabei wie folgt gegeben:

$$\Delta W_{kl} = \eta \cdot \delta \cdot \Delta p_l^\infty \cdot f_l(p_l^\infty) \cdot r_k^\infty, \quad (4)$$

wobei η die Lernrate ist, δ das globale Lernsignal, Δp_l^∞ die Änderung im *accessory* Netzwerk in Phase (2) beschreibt (c.f. Abb. 6), $f_l(p_l^\infty)$ eine interaktionsabhängige Funktion im Membranpotential des Zielneurons l und r_k^∞ die Feuerrate des Ausgangsneurons ist. So konnten in Simulationen durch das Training von rekurrenten Verbindungen mit RELEARNN erstmals Verhaltens- aber auch elektrophysiologische-Untersuchungsdaten in zwei herausfordernden Aufgaben innerhalb einer Lernarchitektur erklärt werden (siehe [BNR15] für mehr Details). Zusätzlich konnte gezeigt werden, dass sowohl die Interaktionen im regulären als auch dem *accessory* Netzwerk auf neuromorpher Hardware realisierbar sind [Br15], App. A. Somit können mit RELEARNN trainierte Netzwerke sowohl auf klassischer als auch auf neuromorpher Hardware trainiert und ausgeführt werden, um bestehende Ansätze und Netzwerke robuster und funktional reicher zu machen.

5 Zusammenfassung

Im Rahmen meiner Doktorarbeit [Br15] konnte ich durch die mathematische Analyse dynamischer Systeme, die Entwicklung neuronaler Modelle, ereignisbasierter optischer Flusschätzung und einem Lernalgorithmus für rekurrente neuronale Netze die notwendigen Grundlagen für neuromorphe Algorithmen erweitern. Ein Beitrag, welcher gerade im Hinblick auf das sich abzeichnende Ende von schneller getakteten Prozessoren und Moore's Law immer wichtiger erscheint [Me14]. Gleichzeitig sind die erarbeiteten Ergebnisse auch von Relevanz für ein verbessertes Verständnis unseres eigenen Gehirns. Insbesondere die gute Übereinstimmung der Simulationsergebnisse des neuen Lernalgorithmus RELEARNN mit verhaltensbezogenen- und elektrophysiologischen-Untersuchungsdaten stellt testbare Prädiktionen für makroskopische lernbezogene Signale auf, welche in künftigen Experimenten untersucht werden können.

Literaturverzeichnis

- [A187] Almeida, L. B.: A learning Rule for Asynchronous Perceptrons with Feedback in a Combinatorial Environment. In: First Annual International Conference on Neural Networks. IEEE, 1987.
- [BMC05] Bonin, V.; Mante, V.; Carandini, M.: The Suppressive Field of Neurons in Lateral Geniculate Nucleus. *Journal of Neuroscience*, 25(47):10844–56, 2005.
- [BN12] Brosch, T.; Neumann, H.: The Brain's Sequential Parallelism: Perceptual Decision-Making and Early Sensory Responses. In: ICONIP (Part II). Vol. 7664 in LNCS, S. 41–50, 2012.
- [BN14a] Brosch, T.; Neumann, H.: Computing with a Canonical Neural Circuits Model with Pool Normalization and Modulating Feedback. *Neural Computation*, 26(12):2735–89, 2014.

- [BN14b] Brosch, T.; Neumann, H.: Interaction of Feedforward and Feedback Streams in Visual Cortex in a Firing–Rate Model of Columnar Computations. *Neural Networks*, 54:11–6, 2014.
- [BN15] Brosch, T.; Neumann, H.: Event–Based Optical Flow on Neuromorphic Hardware. In: *BICT*. 2015.
- [BNR15] Brosch, T.; Neumann, H.; Roelfsema, P. R.: Reinforcement Learning of Linking and Tracing Contours in Recurrent Neural Networks. *PLoS Computational Biology*, 11(10):e1004489, 2015.
- [Br15] Brosch, T.: Cognitive Sequential Parallelism: From Canonical Neural Circuits to Training Recurrent Neural Networks in Perceptual Decision–Making. Dissertation, Ulm University, 2015.
- [BSN13] Brosch, T.; Schwenker, F.; Neumann, H.: Attention–Gated Reinforcement Learning in Neural Networks–A Unified View. In: *ICANN*. Vol. 8131 in LNCS. Springer, S. 272–9, 2013.
- [BTN15] Brosch, T.; Tschechne, S.; Neumann, H.: On Event–Based Optical Flow Detection. *Frontiers in Neuroscience*, 9(137):1–15, 2015.
- [CH12] Carandini, M.; Heeger, D. J.: Normalization as a Canonical Neural Computation. *Nature Reviews Neuroscience*, 13:51–62, 2012.
- [De00] De Valois, R. L.; Cottaris, N. P.; Mahon, L. E.; Elfar, S. D.; Wilson, J. A.: Spatial and Temporal Receptive Fields of Geniculate and Cortical Cells and Directional Selectivity. *Vision Research*, 40(27):3685–702, 2000.
- [DOF95] DeAngelis, G. C.; Ohzawa, I.; Freeman, R. D.: Receptive–Field Dynamics in the Central Visual Pathways. *TINS*, 18(10):451–8, 1995.
- [Es13] Esser, S. K.; Andreopoulos, A.; Appuswamy, R.; Datta, P.; Barch, D.; Amir, A.; Arthur, J.; Cassidy, A.; Flickner, M.; Merolla, P.; Chandra, S.; Basilico, N.; Carpin, S.; Zimmerman, T.; Zee, F.; Alvarez-Icaza, R.; Kusnitz, J. A.; Wong, T. M.; Risk, W. P.; McQuinn, E.; Nayak, T. K.; Raghavendra Singh, R.; Modha, D. S.: Cognitive Computing Systems: Algorithms and Applications for Networks of Neurosynaptic Cores. In: *IJCNN*. IEEE, S. 1–10, 2013.
- [FVE91] Felleman, D. J.; Van Essen, D. C.: Distributed Hierarchical Processing in the Primate Cerebral Cortex. *Cerebral Cortex*, 1(1):1–47, 1991.
- [Gu06] Guo, K.; Robertson, R.; Nevado, A.; Pulgarin, M.; Mahmoodi, S.; Young, M. P.: Primary Visual Cortex Neurons that Contribute to Resolve the Aperture Problem. *Neuroscience*, 138(4):1397–1406, 2006.
- [LPD08] Lichtsteiner, P.; Posch, C.; Delbruck, T.: A 128 × 128 120 dB 15 μ s Latency Asynchronous Temporal Contrast Vision Sensor. *Solid–State Circuits, IEEE Journal of*, 43(2):566–76, 2008.
- [LSL04] Larkum, M. E.; Senn, W.; Lüscher, H.-R.: Top–Down Dendritic Input Increases the Gain of Layer 5 Pyramidal Neurons. *Cerebral Cortex*, 14(10):1059–70, 2004.
- [Me14] Merolla, P. A.; Arthur, J. V.; Alvarez-Icaza, R.; Cassidy, A. S.; Sawada, J.; Akopyan, F.; Jackson, B. L.; Imam, N.; Guo, C.; Nakamura, Y.; Brezzo, B.; Vo, I.; Esser, S. K.; Appuswamy, R.; Taba, B.; Amir, A.; Flickner, M. D.; Risk, W. P.; Manohar, R.; Modha, D. S.: A Million Spiking–Neuron Integrated Circuit with a Scalable Communication Network and Interface. *Science*, 345(6197):668–73, 2014.

- [MP87] Minsky, M.; Papert, S. A.: *Perceptrons: An Introduction to Computational Geometry*. MIT Press, Cambridge, MA, 1987.
- [Pi87] Pineda, F. J.: Generalization of Back-Propagation to Recurrent Neural Networks. *Physical Review Letters*, 59(19):2229–32, 1987.
- [Sp02] Spratling, M. W.: Cortical Region Interactions and the Functional Role of Apical Dendrites. *Behavioral and Cognitive Neuroscience Reviews*, 1(3):219–28, 2002.
- [Sz13] Szegedy, C.; Zaremba, W.; Sutskever, I.; Bruna, J.; Erhan, D.; Goodfellow, I.; Fergus, R.: , Intriguing Properties of Neural Networks , 2013. <http://arxiv.org/abs/1312.6199>, Jan. 2016 (Zugegriffen: Jan. 2016).
- [Sz14] Szegedy, C.; Liu, W.; Jia, Y.; Sermanet, P.; Reed, S.; Anguelov, D.; Erhan, D.; Vanhoucke, V.; Rabinovich, A.: , Going Deeper with Convolutions, 2014. <http://arxiv.org/abs/1409.4842>, Feb. 2015 (Zugegriffen: Feb. 2015).
- [TG80] Treisman, A. M.; Gelade, G.: A Feature-Integration Theory of Attention. *Cognitive Psychology*, 12:97–136, 1980.
- [Ts10] Tsui, J. M. G.; Hunter, J. N.; Born, R. T.; Pack, C. C.: The Role of V1 Surround Suppression in MT Motion Integration. *Journal of Neurophysiology*, 103:3123–38, 2010.
- [Ts14] Tschechne, S.; Brosch, T.; Sailer, R.; von Eglhoffstein, N.; Abdul-Kreem, L. I.; Neumann, H.: On Event-Based Motion Detection and Integration. In: 8th International ACM Conf. on Bio-inspired Information and Communications Technologies. S. 298–305, 2014.
- [Ul84] Ullman, S.: Visual Routines. *Cognition*, 18(1–3):97–159, 1984.



Dr. Tobias Brosch wurde am 11. Oktober 1985 in Ulm geboren. Sein Mathematik Studium mit Nebenfach Informatik an der Universität Ulm schloss er 2010 nach 8 Semestern mit seiner Diplomarbeit über adaptive Merkmalsfusion am Institut für Neuroinformatik ab. Der Erhalt eines Stipendiums des „Promotionskollegs Mathematical Analysis of Evolution, Information and Complexity“ ermöglichte ihm den direkten Einstieg in die Promotion am Institut für Neuroinformatik der Universität Ulm bei Prof. Dr. Heiko Neumann. Während seiner Promotion erstellte er zahlreiche Beiträge für internationale Journals/Tagungen und kollaborierte in Forschungsaufenthalten u.a. mit Prof. Dr. Pieter Roelfsema vom Netherlands Institute for Neuroscience (2013). Seine Beiträge reichen dabei von der mathematischen Analyse dynamischer Systeme über optische Flusssschätzung ereignisbasierter Sensordaten bis hin zu neuen Algorithmen für simultan rekurrente neuronale Netze. Nach Abschluss seiner Promotion (2015) arbeitete er am IBM Almaden Research Laboratory, vertiefte dabei seine Kenntnisse in *deep neural networks* und neuromorphen Algorithmen und initiierte ein Field Test Agreement mit der Universität Ulm zur Nutzung des neurosynaptischen IBM-Chips „TrueNorth“.