

# Neuronendynamik

Friedrich Bach, Katharina Ritter, Felix Tabbert, Walter  
Tewes, Matthias Walther

WWU Münster

03.08.2012



# Inhalt

Wiederholung

N Neuronen

Synaptische Plastizität

N Neuronen mit Plastizität

# Motivation



## Biologischer Hintergrund

- ▶ Verständnis von kollektivem Verhalten von Neuronen
- ▶ stark vereinfachtes Model für die denritischen Ströme  $\Psi$

## Lighthouse Model

- ▶ Kopplung von vielen ( $N$ ) Neuronen
- ▶ Beobachtung der Wechselwirkungen
- ▶ Strukturbildung beobachten: *bumps*

# Lighthouse Model



- ▶ angeregte Neuronen feuern mit einer der Anregung entsprechenden Frequenz (*pulse train*)
- ▶ Anregung von Neuronen durch Kopplung und externe Anregung
- ▶ mathematisches Model für die eingehenden dendritischen Ströme
  - ▶ Einführung einer Hilfsgröße: Phase  $\Phi$  eines Neurons

# Lighthouse Model – 2 Neuronen

Dynamik im neuronalen Netz lässt sich reduzieren auf:


- ▶ Dendritischer Strom

$$\dot{\Psi}_1(t) = aP_2(t) - \gamma\Psi_1(t)$$

mit  $P(t) = f(\Phi(t)) = \sum_{\nu} \delta(\Phi(t) - 2\pi\nu)\dot{\Phi}(t_{\nu})$

- ▶ Phase


$$\dot{\Phi}_1(t) = \Psi_1(t) + p_{ext,1}(t)$$



# Naka-Rushton-Relation

- ▶ verhindert, dass ein Neuron zu oft feuert
- ▶ Abhängigkeit: Pulse-Rate Neuron  $\leftrightarrow$  Input

$$S(P) = \frac{rP^N}{\Theta^N + P^N}$$



- ▶  $r$ : maximale Kreisfrequenz des Pulse-Trains. Der Puls soll auf ein  $\epsilon$ -tel abgefallen sein, z.B. bei 2 Neuronen:

$$\tau = \frac{\log(\epsilon)}{\gamma}, \quad r = 2\pi\tau$$


- ▶ Für Phase gilt also

$$\dot{\Phi}_m = S(\Psi_m(t) + p_{ext,m}(t))$$

- ▶ Für das Sättigungsregime reicht auch:  $S(P) = rH(P - \theta)$

# Phase locked state

- ▶ gleiche externe Anregung
- ▶ zufällige Anfangsbedingungen
- ▶ Synchronisation
- ▶ analytisch Berechenbar




# N Neuronen

Lighthouse Model:

$$\dot{\Psi}_m(t) = \sum_k a_{mk} P_k(t) - \gamma \Psi_m(t)$$

$$\dot{\Phi}_m(t) = S(\Psi_m(t) + p_{ext,m}(t))$$



$a_{mk}$  statische oder dynamische Kopplungsmatrix

Verschiedene Szenarien:

- lineare Kette und Ausbildung von Strukturen
  - *bumps*: räumlich lokalisierte Struktur, die sich zeitlich durch das Netz bewegt [4]
- lineare Kette mit verschiedenen Kopplungen → 2D Darstellung



# N Neuronen

Lighthouse Model:


$$\dot{\Psi}_m(t) = \sum_k a_{mk} P_k(t) - \gamma \Psi_m(t)$$

$$\dot{\Phi}_m(t) = S(\Psi_m(t) + p_{ext,m}(t))$$

$a_{mk}$  statische oder dynamische Kopplungsmatrix

Verschiedene Szenarien:

- lineare Kette und Ausbildung von Strukturen
  - *bumps*: räumlich lokalisierte Struktur, die sich zeitlich durch das Netz bewegt [4]
- lineare Kette mit verschiedenen Kopplungen → 2D Darstellung




# Synaptische Plastizität

Lernen durch zeitabhängige Kopplungsmatrix  $a_{ij}(t)$


$$\dot{\Psi}_i(t) = \sum_j a_{ij} P_j(t) - \gamma \Psi_i(t)$$

- ▶ Kausales Feuern führt zur Verstärkung der synaptischen Verbindung
- ▶ Akausales Feuern schwächt die synaptische Verbindung



# Mathematische Modellierung der Plastizität


- ▶ Kausales Feuern führt zur Verstärkung der synaptischen Verbindung
- ▶ Akausales Feuern schwächt die synaptische Verbindung



$$\dot{a}_{ij} = \Delta A_j P_i - r a_{ij} B_i P_j \quad (1)$$

$$\dot{A}_j = u_A (1 - A_i) P_j - \frac{A_i}{\tau_A} \quad (2)$$

$$\dot{B}_i = u_B (1 - B_j) P_i - \frac{B_i}{\tau_B} \quad (3) \quad [2]$$



# Bumps

## Parameterwahl

- ▶ lineares Regime der NRR:  $S(X) = X$
- ▶ lineare Kette, mit dem Abstand  $\Delta_{ij} = |i - j|$  abfallende Kopplung  $a_{ij} \propto \beta \exp(-\alpha \Delta_{ij})$
- ▶ keine externe Anregung  $\mathbf{p}_{ext} = \mathbf{0}$ , Anfangswerte  $\Phi(0) \in [0, 2\pi]^N$  und  $\Psi(0) \in [0, 2]^N$  zufällig gewählt

## Numerik

- ▶ stark sensitiv auf Parameter  $a_{ij}$  bzw.  $\alpha, \beta$  und  $\gamma$
- ▶ Selbstorganisation im Bereich kritischer Parameter:  
System stirbt fast ab

# Bumps

## Parameterwahl

- ▶ lineares Regime der NRR:  $S(X) = X$
- ▶ lineare Kette, mit dem Abstand  $\Delta_{ij} = |i - j|$  abfallende Kopplung  $a_{ij} \propto \beta \exp(-\alpha \Delta_{ij})$
- ▶ keine externe Anregung  $\mathbf{p}_{ext} = \mathbf{0}$ , Anfangswerte  $\Phi(0) \in [0, 2\pi]^N$  und  $\Psi(0) \in [0, 2]^N$  zufällig gewählt

## Numerik

- ▶ stark sensitiv auf Parameter  $a_{ij}$  bzw.  $\alpha, \beta$  und  $\gamma$
- ▶ Selbstorganisation im Bereich kritischer Parameter:  
System stirbt fast ab

# Bumps

abschluss\_nn\_bump.mp4

abschluss\_nn\_bump.mp4

## N Neuronen mit Plastizität

- ▶ Strukturbildung in einem komplexen System
- ▶ System beherbergt noch mehr Parameter und reagiert sehr sensitiv auf Änderungen → System schwer verständlich
- ▶ NRR  $S(X) = r \cdot H(X)$ , ansonsten divergiert das System

### Beispiel Bilderkennung

Ziel: Qualitatives Beobachten der Auswirkungen der Plastizität

- ▶ anfänglich Schwache Nächste Nachbar Kopplung
- ▶ externe Anregung lässt Netz die Information lernen und in der dynamischen Kopplungsmatrix speichern
- ▶ externe Anregung wird umgeschaltet
- ▶ max.  $20 \times 20 = 400$  Neuronen in Echtzeit auf Laptop



## N Neuronen mit Plastizität

- ▶ Strukturbildung in einem komplexen System
- ▶ System beherbergt noch mehr Parameter und reagiert sehr sensitiv auf Änderungen → System schwer verständlich
- ▶ NRR  $S(X) = r \cdot H(X)$ , ansonsten divergiert das System

### Beispiel Bilderkennung

Ziel: Qualitatives Beobachten der Auswirkungen der Plastizität

- ▶ anfänglich Schwache Nächste Nachbar Kopplung
- ▶ externe Anregung lässt Netz die Information lernen und in der dynamischen Kopplungsmatrix speichern
- ▶ externe Anregung wird umgeschaltet
- ▶ max.  $20 \times 20 = 400$  Neuronen in Echtzeit auf Laptop

# N Neuronen mit Plastizität

abschluss\_2d\_niko.mp4

abschluss\_2d\_niko.mp4

# Zusammenfassung & Ausblick

## Zusammenfassung

- ▶ das Lighthouse Model wurde untersucht und implementiert
- ▶ Strukturbildung in Form von *bumps* konnte beobachtet werden
- ▶ die Auswirkungen der synaptischen Plastizität („Hebb'sche Lernregeln“) konnte untersucht werden

## Ausblick

- ▶ verfeinerte Parameterwahl, um *bumps* stabil zu bekommen
- ▶ Verständnis der *bumps* → Analytische Beschreibung durch mean field Ansatz
- ▶ Untersuchung der Plastizität und Findung der Parameter

# Quellen



Haken, H.: *Brain dynamics: an introduction to models and simulations*. Springer Verlag, 2008.



Chen, C. and Jasnow, D.: *Phys. Rev. E* **81** 011907 (2010)



[commons.wikimedia.org](https://commons.wikimedia.org)



Chow, C. and Coombes, S.: *Existence and wandering of bumps in a spiking neural network model*, 2006

Vielen Dank für Ihre  
Aufmerksamkeit!