



# Computational Neuroscience II

## Übung 03

### Okulare Dominanz

M.Sc. Juliane Höbel-Müller  
Geb. 03, R. 322  
[Juliane.Hoebel@ovgu.de](mailto:Juliane.Hoebel@ovgu.de)

# Inhalt

- Einordnung in die Vorlesung
- Begriff: Synaptische Plastizität
- Hebbsches Lernen
- Regeln zur synaptischen Modifizierung
- Vorstellung des Übungsblattes (Abgabefrist: **7.6.18, 11 Uhr**)

## Einordnung in die Vorlesung

- Synaptische Plastizität und Lernen (Vorlesungsfolie 76 ff.)
- Unüberwachtes Lernen
- Synaptische Plastizität (Form der neuronalen Plastizität)
  - Beschränkung auf die synaptischen Endigungen (Synapsen)
  - Langsame Veränderung der synaptischen Stärke über die Zeit
- Basisphänomen beim Lernen und Gedächtnis
- Grundlage der Forschung: **Hebbsche Regel**

# Hebbsches Lernen I

- Donald Hebb's Vermutung (1949): Wenn der Input eines Neurons A oft dazu beiträgt, dass Neuron B feuert, dann wird die synaptische Stärke von A nach B erhöht.
- Allg.: Änderung **Hebbscher Synapsen** ist proportional zur Korrelation der Aktivitäten der prä- / postsynaptischen Neurone



$$\Delta w \propto A(t)B(t)$$

# Hebbsches Lernen II

- Probleme:
  - Unbegrenztes Wachstum der synaptischen Stärke
  - Sinkende postsynaptische Selektivität
- Möglichkeiten zur Korrektur der Hebbschen Regel:
  - **Synaptische Sättigung**
  - **Synaptischer Wettbewerb**

# Übersicht: Regeln zur synaptischen Modifizierung

- Lineare Feuerratengleichung
- Grundlegende (lineare) Hebb'sche Regel
- Kovarianzregel
- Oja-Regel

# Feuerratengleichung I

$$\tau_r \frac{dv}{dt} = -v + \mathbf{w} \cdot \mathbf{u}$$

- $\tau_r$  := Zeitkonstante zur Kontrolle der Dynamik der Feuerrate
- $v$  := Postsynaptische Aktivität
- $\mathbf{w}$  := Vektor der synaptischen Gewichte präsynaptischer Neurone
- $\mathbf{u}$  := Präsynaptische Aktivität (Mustervektor)

## Feuerratengleichung II

- Synaptische Plastizität **langsamer** als Dynamik des Feuerns
- Annahme für die Dynamik des Feuerns während des Trainings:


$$v = \mathbf{w} \cdot \mathbf{u} = \mathbf{w}^T \mathbf{u} = \mathbf{u}^T \mathbf{w}$$

- Hinweis: Skalarprodukt im  $\mathbb{R}^N$  entspricht Matrizenprodukt



# Feuerratengleichung III

$$v = w \cdot u$$



Beispiel für ein zweilagiges Netz

# Grundlegende Hebbsche Regel I

- Einfachste Plastizitätsregel nach Hebbs Hypothese:

$$\tau_w \frac{d\mathbf{w}}{dt} = \mathbf{v}\mathbf{u}$$

- $\tau_w$  := Zeitkonstante zur Kontrolle der Gewichtsänderung
- Approximation der langsamen Gewichtsänderungen:

$$\tau_w \frac{d\mathbf{w}}{dt} = \langle \mathbf{v}\mathbf{u} \rangle$$

➤  $\langle \mathbf{u} \rangle = \frac{1}{p} \sum_{i=1}^p \mathbf{u}_i$  (Mittelwert eines Ensembles von  $p$  Mustern  $\mathbf{u}$ )

# Grundlegende Hebb'sche Regel II

- Durch Einsetzen der Feuerratengleichung ergibt sich

$w_j$  als multiplikative Faktor betrachtet  
und aus  $\langle \dots \rangle$  gezogen

$$\langle v u_i \rangle = \left\langle \sum_{j=1}^N u_j u_i \right\rangle w_j \quad \text{bzw.} \quad \langle v u \rangle = \underbrace{Q w}$$

$$v = \underbrace{w \cdot u} = \sum_{j=1}^N w_j u_j$$

Matrix-Vektor-Produkt  
Ergebnis: Vektor

## En détail: Input-Korrelationsmatrix

$$\langle v u \rangle = \mathbf{Q} \mathbf{w} = \left\langle \begin{pmatrix} u_{i=1} u_{j=1} & \cdots & u_{i=1} u_{j=N} \\ \vdots & \ddots & \vdots \\ u_{i=N} u_{j=1} & \cdots & u_{i=N} u_{j=N} \end{pmatrix} \right\rangle \begin{pmatrix} w_{j=1} \\ \vdots \\ w_{j=N} \end{pmatrix}$$

$$\langle v u \rangle = \mathbf{Q} \mathbf{w} = \underbrace{\langle \mathbf{u} \mathbf{u}^T \rangle}_{\text{Dyadisches Produkt}} \mathbf{w}$$

Dyadisches Produkt

- $\mathbf{Q} = \langle \mathbf{u} \mathbf{u}^T \rangle$  beschreibt Korrelationen zw. den Komponenten von  $\mathbf{u}$

➤ Definition von  $\mathbf{Q}$  als Input-Korrelationsmatrix

Mittelwertbildung über alle  $p$  Muster

$$Q_{ij} = \langle \mathbf{u} \mathbf{u}^T \rangle_{ij} = \langle u_i u_j \rangle = \overbrace{\frac{1}{p} \sum_{k=1}^p u_i^k u_j^k}$$

# Kovarianzregel I

- Realität: Stärke der Synapsen kann nicht nur zu-, sondern auch abnehmen
- Option: Subtraktion eines präsynaptischen Schwellenwerts zur Bestimmung des Niveaus von  $u$

$$\tau_w \frac{dw}{dt} = v(u - \theta_u)$$

- Hier:  $\theta_u = \langle u \rangle$  (Vgl. Dayan & Abbott)

## Kovarianzregel II

- Einsetzen der Feuerratengleichung:  $v = \mathbf{w} \cdot \mathbf{u}$
- Anwendung des Mittelwerts auf  $v(\mathbf{u} - \boldsymbol{\theta}_u)$ , wobei  $\boldsymbol{\theta}_u = \langle \mathbf{u} \rangle$

$$\tau_w \frac{d\mathbf{w}}{dt} = \mathbf{C} \mathbf{w}$$

- $\mathbf{C} :=$  Input-Kovarianzmatrix
- Induzierung eines synaptischen Wettbewerbs
- Aber: Wachstum von  $\mathbf{w}$  wie bei linearer Hebb-Regel unbeschränkt

## Hinweise zur Input-Kovarianzmatrix

- Korrelationsmatrix  $\mathbf{Q}$  ist gleich der Kovarianzmatrix  $\mathbf{C}$ , wenn der Mittelwert verschwindet

$$\mathbf{C} = \langle (\mathbf{u} - \langle \mathbf{u} \rangle)(\mathbf{u} - \langle \mathbf{u} \rangle)^T \rangle$$

- Die Kovarianz 2er Zufallsvariablen  $X$  und  $Y$  kann man mit dem Verschiebungssatz (Satz von Steiner) angeben:

$$\text{Cov}(X, Y) = E(XY) - E(X)E(Y)$$

$$\mathbf{C} = \langle \mathbf{u}\mathbf{u}^T \rangle - \langle \mathbf{u} \rangle \langle \mathbf{u}^T \rangle$$

Wdhlg.: Annäherung des Mittelwerts an den Erwartungswert für unendlich viele  $\mathbf{u}$ .

# Oja-Regel I

- Balancieren des Wachstums der synaptischen Stärke

➤ Nutzung eines „Vergessensterms“

- „Vergessensterm“ ist proportional zu  $\mathbf{w}$  und  $v^2$

$$\tau_w \frac{d\mathbf{w}}{dt} = v \mathbf{u} - \alpha v^2 \mathbf{w}$$

$$\tau_w \frac{d\mathbf{w}}{dt} = \mathbf{C} \mathbf{w} - \alpha (\mathbf{w}^T \mathbf{C} \mathbf{w}) \mathbf{w}$$

- $\alpha := \text{Lernrate}$



## Oja-Regel II

- Ergebnis des Trainings eines Netzes mit Oja-Regel:
  - 1)  $\mathbf{w} \sim \mathbf{e}^j$ , wobei  $\mathbf{e}^j$  ein Eigenvektor von  $\mathbf{C}$  mit Eigenwert  $\lambda^j$  ist
  - 2)  $\lambda^j = \lambda^{\max}$  ist der größte Eigenwert von  $\mathbf{C}$
  - 3)  $|\mathbf{w}|^2 = \frac{1}{\alpha}$
  - 4)  $\langle v^2 \rangle$  ist maximal
- Fazit: Mit der Oja-Regel findet man die **Richtung der größten Varianz** der Musterverteilung.

## En détail: Beweis von 1)

- Annahme: Konvergenz des Trainings

➤ Keine Änderung von  $\mathbf{w}$  über alle Muster des Trainingsdatensatzes:

$$\left\langle \frac{d\mathbf{w}}{dt} \right\rangle = 0$$

- Bei Konvergenz gilt:

$$\langle v\mathbf{u} - v^2\mathbf{w} \rangle = C\mathbf{w} - (\mathbf{w}^T C \mathbf{w})\mathbf{w} = C\mathbf{w} - \lambda\mathbf{w}$$

- Dabei wird verwendet:

$$\langle v^2 \rangle = \langle (\mathbf{w}^T \mathbf{u})^2 \rangle = \langle \mathbf{w}^T \mathbf{u} \mathbf{u}^T \mathbf{w} \rangle = \mathbf{w}^T C \mathbf{w}$$

- Aus der vorletzten Gleichung folgt, dass  $\mathbf{w}$  Eigenvektor von  $C$  ist:

$$C\mathbf{w} = \lambda\mathbf{w}$$

Eigenwertproblem

## En détail: Beweis von 2)

- $w$  kann in  $C$ -Eigenvektorkoordinaten geschrieben werden:
- Für jede Komponente  $k$  von  $w$  gilt

$$\tau_w \frac{dw_k}{dt} = (\lambda_k - \alpha \sum_j \lambda_j w_j^2) w_k$$

- Summenterm ist gleich für alle  $k$
- $(..)$  ist maximal für größten Eigenwert  $\lambda$
- Mit der Oja-Regel findet man die Richtung der größten Varianz der Musterverteilung.

# Zusammenfassung

- Allgemeines zum Hebbischen Lernen
- Lineare Feuerratengleichung
- Grundlegende (lineare) Hebbische Regel
- Kovarianzregel
  - Synaptischer Wettbewerb
  - Unbegrenztes synaptisches Wachstum
- Oja-Regel
  - Synaptische Sättigung
  - Synaptischer Wettbewerb

## Fragen

- [Einfache Hebb–Regel] Mit welchem Problem ist die grundlegende Hebb–Regel und die Kovarianzregel verknüpft?
- [Kovarianz–Regel] Annahme: Der initiale Gewichtsvektor ( $t=0$ ) beinhalte Komponenten in alle Eigenvektor–Richtungen. Charakterisieren Sie die Langzeitentwicklung des Gewichtsvektors.
- [Kovarianz–Regel] Zeigen Sie, dass die synaptischen Gewichte über die Zeit unbegrenzt wachsen.
- [Oja–Regel] Zeigen Sie, dass die Oja–Regel konvergiert.
- [Oja–Regel] Geben Sie den Lernalgorithmus (Oja–Regel) in Pseudocode an.

## Übung 3: Okulare Dominanz im Hebbischen Modell

- **Okulare Dominanz:** Bevorzugung *eines* Auges durch Input-Neurone im primären visuellen Kortex

- Zwei Neurone  $u_L$  und  $u_R \rightarrow$  Projektion in primären vis. Kortex
- $u_L$  (bzw.  $u_R$ ) erhält Input vom linken (bzw. rechten) Auge
- Beobachtung: Zielneuronen im prim. vis. Kortex mit häufigen Input vom selben Auge ( $\rightarrow$  ok. Dom.)
- Ziel: Nachvollziehen des Phänomens mithilfe der Kovarianz- und Oja-Regel

➤ Analyse der Entwicklung der Gewichtsvektoren über die Zeit

## Übung 3: Überblick

- 1: Hintergrundinformation
- 2: Statistische Beschreibung des Inputs des linken/rechten Auges
- Beschreibung verschiedener Arten der Ausbildung synaptischer Gewichte:
- Aufgabe 3: **Kovarianzmatrix** (analytisch vs. numerisch)
- Aufgabe 4: **Kovarianzregel** (Synaptische Sättigung mithilfe eines einfachen Schwellenwertbereichs)
- Aufgabe 5: Dynamische Normierung mithilfe der **Oja-Regel**
- Frage nach der Ausbildung monokularer Neurone

# Voraussetzung für Bearbeitung der Übung


- Verständnis der Vorlesungsfolien
- Bsp. „Ocular dominance (2)“ / „Ocular dominance with saturation (3)“

## Ocular dominance (2)

- ◆ If correlation between eyes is positive,  $q_D > 0$ . Then the principal eigenvector is  $e^1 = (1,1)$ ;  $\lambda_1 = q_S + q_D$ , representing the combined weight vector  $w_R + w_L$ .
- ◆ After some Hebbian Learning time, the weights will be proportional to  $w_R + w_L$ , whereas the other eigenvector is suppressed, i.e.  $w_R - w_L \rightarrow 0$ .
- ◆ This means that both eyes contribute equal innervation, so no ocular dominance occurs.
- ◆ Hebb has failed ?????

## Ocular dominance with saturation (3)

- ◆ With the (biologically plausible) saturation of weights  $0 < w < w_{\max}$ , the outcome of Hebbian learning depends on the initial overlaps  $e \cdot w$  and the products  $\bullet t$ :
- ◆ If „few“ time has elapsed and saturation is already reached, the outcome is rather determined by the initial overlaps than by the largest eigenvalue [here  $= (1,-1)$ ]:





## Aufgabe 3: Input-Kovarianz

- Berechnung der Kovarianzmatrix  $\mathcal{C}$ 
  - a) Anhand *statistischer* Ensembles von  $(u_L, u_R)$  (analytisch)
  - b) Anhand eines zufällig generierten Ensembles  $\{(u_L, u_R)\}$  (numerisch)
  - c) Berechnung der Eigenvektoren und -werte von  $\mathcal{C}$

	$u_R = 1$	$u_R = 0$	
$u_L = 1$	$\gamma/4$	$1/2 - \gamma/4$	$P(u_L = 1) = 1/2$
$u_L = 0$	$1/2 - \gamma/4$	$\gamma/4$	$P(u_L = 0) = 1/2$
	$P(u_R = 1) = 1/2$	$P(u_R = 0) = 1/2$	1

Tabelle 1: Die durch  $\gamma$  parametrisierten Wahrscheinlichkeiten für die Paare  $(u_L, u_R)$ .

- Gleiche Auftretenswahrscheinlichkeit:  $\langle u_L \rangle = \langle u_R \rangle = \frac{1}{2}$

## Aufgabe 3: Input-Kovarianz II

- Analytisch zu berechnende Kovarianzmatrix
- Berücksichtigung der Wahrscheinlichkeitstabelle (Tab. 1)

$$C_{1,2,3} = \begin{pmatrix} c_S & c_D \\ c_D & c_S \end{pmatrix},$$

$$c_S = \langle u_L u_L \rangle - \langle u_L \rangle^2 = \langle u_R u_R \rangle - \langle u_R \rangle^2$$

$$c_D = \langle u_L u_R \rangle - \langle u_L \rangle \langle u_R \rangle = \langle u_R u_L \rangle - \langle u_R \rangle \langle u_L \rangle$$

- Erklärung:  $\langle u_L u_L \rangle :=$  Erwartungswert für Input nur vom linken Auge

## Aufgabe 4: Ausbildung von Gewichten mit Sättigung

- Modellierung synaptischer Modifizierung als **diskreten** Prozess anstelle eines kontinuierlichen Prozesses


➤ Diskrete Regel zur Aktualisierung von  $w$ :

$$w_{i+1} = w_i + \epsilon C w_i$$


- $\epsilon$  := Parameter analog zur Lernrate
- In eurem Matlab-Skript:  $\epsilon = \frac{dt}{\tau_w}$

# Aufgabe 4: Ausbildung von Gewichten mit Sättigung

- Anwendung der Kovarianzregel



Eigenvektoren von  $C_{\gamma=0.5}$



Entwicklung synaptischer Gewichte

## Aufgabe 4: Ausbildung von Gewichten mit Sättigung

- Anfangsbedingungen := rote Kreise
- Endwerte (Sättigung) := blaue Kreise
- Hebbsches Lernen abhängig von initialen Überlappungen der Zustandsverbindungen mit den Eigenvektoren
- Wie entwickeln sich die Kurven hinsichtlich  $\gamma$  und der Beziehung zw.  $w_L$  und  $w_R$ ?
- Welche  $(w_L, w_R)$  entwickeln sich *nicht* entlang des Haupteigenvektors? Warum?


## Aufgabe 5: Ausbildung von Gewichten mit dynamischer Normierung

➤ Diskrete Regel zur Aktualisierung von  $w$ :

$$w_{i+1} = w_i + \epsilon (C w_i - \alpha (C w_i) w_i)$$

$$\epsilon = \frac{dt}{\tau_w}$$

$$\alpha = \frac{1}{2}$$



Entwicklung synaptischer Gewichte  
bei Anwendung der Oja-Regel

# Hinweis zum Erstellen der Plots

- Anwendung der Matlab-Funktion *scatter*

➤ Doku: <https://www.mathworks.com/help/matlab/ref/scatter.html>

```
% Visualisierung der zeitlichen Entwicklung der Verbindungszustände
figure(2);
hold on;
% P Kurven
for l=1:P
    % Zeichne P Kurven
    plot(_____, _____);
    % Zeichne die Anfangsbedingungen (rote Kreise)
    scatter(_____, _____, 'r');
    % Zeichne die Endwert (blaube Kreise)
    scatter(_____, _____, 'b');
end
xlabel('w_L');
ylabel('w_R');
s=strcat('Kovarianzregel; gamma = ', num2str(gamma));
title(s);
```

Auszug: Matlab-Code zur Zeichnung des Prozesses der synaptischen Modifizierung

**Vielen Dank für Eure Aufmerksamkeit!**

**Referenzen:**

**→ Vorlesung CNS II**

**→ Buch Theoretical Neuroscience (Dayan & Abbott)**