

Selbstorganisierende Merkmalskarten

- **Motivation (Gehirn)**
- **Netzwerk-Architektur**
- **Topographische Merkmalskarten (Früher: „Kohonen-Karten“)**
- **Selbstorganisierende Merkmalskarte (Kohonen-Lernregel)**
- **Anwendungsbeispiele**


Motivation: Topografische Merkmalskarten im Gehirn

Frühe Sehbahn:

- Zellen der primären Sehrinde verarbeiten Input aus lokalem Bereich: „Rezeptives Feld“
- Benachbarte rezeptive Felder erregen benachbarte Kortextbereiche
- Benachbarte Stimuluseigenschaften (Merkmale) erregen benachbarte Kortextbereiche


Also: Struktur interner Repräsentationen:

- Merkmale der Umwelt werden durch den Ort der stärksten Aktivierung in der Großhirnrinde kodiert („Merkmalskarte“).
- Diese Kodierung ist stetig, d.h. benachbarte kortikale Orte kodieren ähnliche Reizmerkmale („Topographisch“).




Beispiel „Retinotopie“:

- Erscheinungsort eines Merkmals wird durch den Ort kortikaler Erregung kodiert



Beispiel „Orientierungspräferenz-Karte“:

- Reizorientierung wird durch den Ort kortikaler Erregung kodiert



Kohonens Idee:

- Benutze topographische Merkmalskarte als Prinzip zur Datenrepräsentation
- Jedes Neuron repräsentiert einen Teil des Datenraums
- Wo viele Daten sind, sind viele Neuronen zuständig => Dichteschätzung
- Gute Datenrepräsentation wird gelernt


Implementierung in einem Neuronalen Netz

- MLP:

- Feed-Forward
- Input-Neuronen verantwortlich für Halbraum
- Verarbeiteter Input wird zu Output transformiert
- Überwachtes Lernverfahren


- Selbstorganisierende Merkmalskarte:

- Rückgekoppelte Verbindungen
- Input-Neuronen verantwortlich für lokalisierten Bereich (wie RBF)
- Verarbeiteter Input wird zu sich selbst in Verbindung gesetzt
- Unüberwachtes Lernverfahren




Kohonen-Netzwerk: Verschaltungsstruktur

1 Rekurrent vernetzte Ausgabeschicht



1 Mexican-Hat-förmige, zeitunabhängige laterale Wechselwirkung



Im Gegensatz zum Hopfieldnetz sind die lateralen Verbindungen $h(\mathbf{r}, \mathbf{r}')$ im Ortsraum festgelegt. Biologisch motiviert: Mexican-Hat-Struktur („Umfeldhemmung“).

Netzwerk-Dynamik:

- 1 Die Inputneuronen initialisieren ein Aktivitätsmuster in der Ausgabeschicht
- 1 Dieses wird durch die rückgekoppelte Netzwerkdynamik verändert, läuft in einen Attraktor
- 1 **Dynamische Gleichung:**
$$\frac{d}{dt} f(\mathbf{r}, t) = -f(\mathbf{r}, t) + g \left(\sum_{l=1}^d w_l(\mathbf{r}) x_l + \int d\mathbf{r}' h(\mathbf{r} - \mathbf{r}') f(\mathbf{r}', t) - \theta \right)$$
- 1 **Analytische Fixpunkt-Lösung schwierig, aber:**

Beobachtung:

- 1 Laterale Wechselwirkungen vom Mexican-Hat-Typ mit genügend starker Inhibition führen immer zur Ausbildung lokalisierter Aktivitäts-“Blobs“
- 1 Denn: Im Laufe der Iterationen inhibiert das anfangs am stärksten aktivierte Neuron seine Nachbarn am stärksten, vermindert damit deren inhibitorische Wirkung, kann so immer stärker aktiv werden, u.s.w...
- 1 Also: Das anfangs am stärksten aktivierte Neuron + Nachbarn gewinnen:
- 1 Winner-take-all Aktivierung

Das Kohonen-Modell: „Self-Organizing Feature-Map“ (SOM)

Architektur einer Selbstorganisierenden Merkmalskarte


- 1 d Eingabeneuronen senden Inputs zu allen Neuronen im zweidimensionalen Gitter der Ausgabeschicht.
- 1 Die Ausgabeneuronen stehen durch eine Nachbarschaftsfunktion miteinander in Beziehung

Merkmalskarte durch „Winner-Take All“

- 1 Das Neuron mit dem stärksten Input sowie seine Nachbarn erhalten den „Zuschlag“, dürfen also den Input repräsentieren

Selbstorganisation:

- 1 Gewichtsvektoren der aktivierten Nachbarn rücken näher zueinander




Def: Merkmalskarte:

- Abbildung, die jedem Vektor des Inputraumes (Musterraum, Merkmalsraum) einen Ort s in einer repräsentierenden Schicht (Karte) zuweist

$$\phi_w : \mathbf{x} \rightarrow \phi_w(\mathbf{x}) = s \mid \|\mathbf{w}(s) - \mathbf{x}\| = \min_r \|\mathbf{w}(\mathbf{r}) - \mathbf{x}\|$$

- Bem: Die Struktur der Karte hängt von den Gewichtsvektoren ab



Berechnung der Gewinner:

- „Merkmal“ = Vektor $\mathbf{x}$ im d -dimensionalen Inputraum
- Gewichtsvektor $\mathbf{w}$ jedes Neurons lebt gleichermaßen im d -dimensionalen Inputraum
- Gewinner-Neuron: Neuron s , dessen normalisierter Gewichtsvektor am nächsten am normalisierten Datenpunkt ist

$$s = \arg \min_r (\|\mathbf{w}(\mathbf{r}) - \mathbf{x}\|)$$

- Das Gewinner-Neuron und seine Nachbarn werden gemäß der Funktion $l(s, \mathbf{r})$ aktiviert: Es entsteht ein lokaler Aktivitäts-Blob um s

- Bsp:
$$l(s, \mathbf{r}) = \exp\left(\frac{-(s - \mathbf{r})^2}{2\sigma^2}\right)$$

Rezeptive Felder und Merkmalskarten :


- **Beobachtung:** Jeder Gewichtsvektor / jedes Neuron ist Gewinner in einem ganzen Abschnitt des Inputraumes: „Rezeptives Feld“

$$RF(s) = \left\{ \mathbf{x} \in V \mid \|\mathbf{w}(s) - \mathbf{x}\| = \min_r (\|\mathbf{w}(r) - \mathbf{x}\|) \right\}$$

- Topographische Merkmalskarte:
Benachbarte rezeptive Felder sollten zu benachbarten Neuronen in der Karte gehören
- **Ziel:** Lernregel, die eigenständig diese topographische Ordnung herstellt:
„Selbstorganisierende Merkmalskarte“

Vorteile:

- Nachbarschaftsbeziehungen im „unübersichtlichen“ Inputraum können direkt in der Ausgabeschicht abgelesen werden
- Auch andere Eigenschaften repräsentierbar; z.B.: Punktdichten => Dichteschätzung




Die Kohonen-Lernregel :

- **Idee:** Für jeden Datenvektor: Nähere die Gewichtsvektoren des Gewinners und seiner Nachbarn in der Karte dem Inputmuster an.
- Dadurch erhalten Nachbarneuronen schließlich benachbarte rezeptive Felder
- Dadurch werden Regionen mit vielen Datenpunkten durch viele Vektoren repräsentiert (Dichteschätzung)


Algorithmus:

- **Geg:** Datensatz auf Länge 1 normierter Datenvektoren $D = (\mathbf{x}^{(1)}, \dots, \mathbf{x}^{(m)}, \dots, \mathbf{x}^{(M)})$
- **Belege Gewichtsvektoren mit Zufallswerten**
- **Präsentiere Datenvektor** $\mathbf{x}^{(m)}$
- **Ermittle den Gewinner** $s^{(m)} = s \mid \|\mathbf{w}(s) - \mathbf{x}^{(m)}\| = \min_{\mathbf{r}} \|\mathbf{w}(\mathbf{r}) - \mathbf{x}^{(m)}\|$
- **Nähere Gewichtsvektoren proportional zur Nachbarschaftsfunktion zueinander an**
 $\mathbf{w}^{\text{neu}}(\mathbf{r}) = \mathbf{w}^{\text{alt}}(\mathbf{r}) + \Delta \mathbf{w}(\mathbf{r})$ mit $\Delta \mathbf{w}(\mathbf{r}) = \eta l(s, \mathbf{r})(\mathbf{x}^{(m)} - \mathbf{w}(\mathbf{r}))$
- **Normiere Gewichtsvektoren auf Länge 1, präsentiere nächsten Datenpunkt**

Effekt der Lernregel:



Vor dem Training



Nach dem Training


Bemerkungen:

- 1 Üblicherweise werden die Breite σ der Nachbarschaftsfunktion und die Lernschrittweite η im Lauf der Zeit verringert: $\sigma \leftarrow \sigma(t)$, $\eta \leftarrow \eta(t)$.
- 1 Konvergenzbeweise gegen einen statistisch beschreibbaren Gleichgewichtszustand existieren für:
$$\eta(t) = \eta t^{-\alpha}, 0 < \alpha \leq 1 \quad \lim_{t \rightarrow \infty} \sigma(t) = 0$$

Anwendungsbeispiele

Dichteschätzung:

- Schätzen einer Wahrscheinlichkeitsdichte, die den Daten zugrunde liegt
- Die Merkmalskarte wird mit Vektoren trainiert, die aus der zu schätzenden pdf als Stichproben gezogen wurden
- Häufig auftretende Merkmale werden von der SOM durch mehr Neuronen repräsentiert
- Beispiel: Merkmalskarte mit 15x15 Neuronen



Spezialfall Vektorquantisierung:

(Verfahren zur Datenkompression)

- 1 Folge von Datenvektoren $\mathbf{x}(t)$, $t = 1, \dots$, sollen durch eine feste Anzahl von Referenzvektoren $\mathbf{w}_s$ approximiert werden
 - 1 Kompression: Speicherung des Index $s(\mathbf{x})$ mit minimalem $\|\mathbf{w}_{s(\mathbf{x})} - \mathbf{x}\|$ für jedes $\mathbf{x}(t)$
 - 1 Restauration: $\mathbf{x}(t) := \mathbf{w}_{s(\mathbf{x}(t))}$, $t = 1, \dots$ (Es gibt einen Restaurationsfehler!)
- 1 Ziel: Finde optimale Verteilung der Referenzvektoren mit min. Restaurationsfehler


1 **Kostenfunktion**
$$E = \int P(\mathbf{x}) \|\mathbf{w}_{s(\mathbf{x})} - \mathbf{x}\|^2 d\mathbf{x} \equiv \min$$

1 **Gradientenabstieg**
$$\mathbf{w}_s(t+1) = \mathbf{w}_s(t) - \frac{\eta}{2} \frac{\partial E}{\partial \mathbf{w}_s} = \mathbf{w}_s(t) + \eta \int (\mathbf{x} - \mathbf{w}_s(t)) P(\mathbf{x}) d\mathbf{x}$$

 $RF(s)$

1 **Empirische Lernregel**
$$\mathbf{w}_{s(\mathbf{x})}(t+1) = \mathbf{w}_{s(\mathbf{x})}(t) + \eta (\mathbf{x} - \mathbf{w}_{s(\mathbf{x})})$$

1 **Bsp:**




Clustering und Visualisierung:

- 1 **Problem: Hochdimensionaler Datenraum**
- 1 **Aufgabe: Finde Korrelationen in den Daten**
- 1 **Lösung mit dem Kohonenalgorithmus: Merkmale, die im Inputraum nahe beieinanderliegen, werden auf benachbarte Gebiete der SOM abgebildet**

	klein	mittel	groß	2 Beine	4 Beine	Haare	Hufe	Mähne	Federn	jagt	rennt	fliegt	schwimmt
Taube	1	0	0	1	0	0	0	0	1	0	0	1	0
Henne	1	0	0	1	0	0	0	0	1	0	0	0	0
Ente	1	0	0	1	0	0	0	0	1	0	0	0	1
Gans	1	0	0	1	0	0	0	0	1	0	0	1	1
Eule	1	0	0	1	0	0	0	0	1	1	0	1	0
Falke	1	0	0	1	0	0	0	0	1	1	0	1	0
Adler	0	1	0	1	0	0	0	0	1	1	0	1	0
Fuchs	0	1	0	0	1	1	0	0	0	1	0	0	0
Hund	0	1	0	0	1	1	0	0	0	0	1	0	0
Wolf	0	1	0	0	1	1	0	1	0	1	1	0	0
Katze	1	0	1	0	1	1	0	0	0	1	0	0	0
Tiger	0	0	1	0	1	1	0	0	0	1	1	0	0
Löwe	0	0	1	0	1	1	0	1	0	1	1	0	0
Pferd	0	0	1	0	1	1	1	1	0	0	1	0	0
Zebra	0	0	1	0	1	1	1	1	0	0	1	0	0
Kuh	0	0	1	0	1	1	1	0	0	0	0	0	0

- 1 Die Merkmale werden ihrer Ähnlichkeit entsprechend auf der SOM angeordnet
- Topologieerhaltende Abbildung des hochdimensionalen Inputraumes auf die zweidimensionale Kartenfläche



Spezialfall: Dimensionsreduktion

- 1 **Geg:** Signale mit vielen Freiheitsgraden (hohe Dimensionalität).
- 1 **Ges:** Bestmögliche Repräsentation in einer niedrigdimensionalen Neuronenstruktur (typisch: 1 bis 2-dimensional).


- 1 **Der Kohonenalgorithmus führt zu einer optimalen Abdeckung des höherdimensionalen Raumes gemäß der Wahrscheinlichkeitsverteilung der präsentierten Inputmuster**

- 1 **Beispiel: Eindimensionale Neuronenkette wird mit zweidimensionalen Vektoren aus dem Einheitsquadrat trainiert**

- 1 **Zeitabhängige Breite der Nachbarschaftsfunktion:** $\sigma(t) = 100(0.01)^{10^{-5}t}$

- 1 **bewirkt sukzessive Ausbildung immer feinerer Strukturen**

Dimensionsreduktion: Lernverlauf



Zuordnung: zu Beginn, nach 200, nach 50000, nach 100000 Schritten

Beispiel Sensorik: Positionskodierung einer Schallquelle

Ausgangspunkt:


- 1 Schallsignale einheitlicher Lautstärke ertönen in beliebigen Positionen innerhalb eines krummlinig begrenzten Gebietes
- 1 Die Signale werden von zwei Mikrofonen aufgenommen, deren Ausgangsintensität den Abstand der Schallquelle kodiert
- 1 Mit der nichtlinearen Verstärkerkennlinie $f(x)$ werden die Signale zu:

$$v_1 = f\left(\left[(x-a)^2 + y^2\right]^{-1}\right)$$


$$v_2 = f\left(\left[(x+a)^2 + y^2\right]^{-1}\right)$$

Ziel:


- 1 Lerne Merkmalskarte zur Rekonstruktion des Ortes aus dem gemessenen Schallsignal



Positionskodierung einer Schallquelle: Lernverlauf



Karte nach 100 Lernschritten




Karte nach 40000 Lernschritten

- 1 Es sind die Gewichtsvektoren und damit die Positionen höchster Sensitivität für ein Gitter von 40x40 Neuronen dargestellt. Nach dem Training kodiert jedes Neuron einen Teil-bereich des betrachteten Gebietes. Das Netzwerk hat die der Positionskodierung innewohnende nichtlineare Transformation invertiert.

Positionskodierung einer Schallquelle: Dichteschätzung des sensorischen Inputs

- 1 Die Repräsentation passt sich der Wahrscheinlichkeitsverteilung der Inputsignale an, d.h. häufig präsentierte Muster werden durch mehr Kohonen-Neuronen kodiert



Im zentralen Kreis wurde die Signalhäufigkeit gegenüber außen um einen Faktor 3 erhöht.

Jedes Muster hat eine „anziehende“ Wirkung auf die im Inputraum benachbarten Gewichtsvektoren: Kumulation bei Peaks der Wahrscheinlichkeitsverteilung.

(s. a. Vektorquantisierung).

Denselben Effekt kann man durch lokale Erhöhung der Netzwerkelastizität (Verbreiterung von l) erreichen

Optimierungsprobleme:


- ┆ Lösungsaufwand für ein System mit L Komponenten steigt wie $\exp(L)$ bzw. $L!$


- ┆ **Beispiel: Handlungsreisenden-Problem:**

- ┆ Finde die kürzeste Route, die L gegebene Städte berührt.

- ┆ **Ansatz:** Wähle eindimensionalen Neuronenring mit $N \geq L$ Neuronen ($N > L$ empfohlen) und zweidimensionalen Gewichtsvektoren.

Die Inputsignale kodieren x - und y -Positionen der Städte.





Netzwerkarchitektur für das Handlungsreisenden-Problem. Die Inputs kodieren die xy-Position, die Ausgabeneuronen implementieren eine Ringnachbarschaft.

- 1 **Präsentiere die Städtepositionen als Inputmuster und trainiere mit**

$$\Delta \mathbf{w}(r, t) = \eta(t) l(s(\mathbf{x}), r, t) (\mathbf{x} - \mathbf{w}(r, t))$$
- 1 **Die Nachbarschaftsfunktion $l(r, r')$ versucht, die Repräsentation des Rings im Ortsraum möglichst kurz zu halten („kurzer Weg“-Forderung)**
- 1 **Unter dieser Bedingung werden die Städtepositionen sukzessive approximiert**

Simulationsablauf (nach Durbin und Willshaw 1987):

$L = 30$

$N = 800$

$h = 0.8$

$s(t) = 50 \cdot 0.02^{(t/t_{\max})}$

$t_{\max} = 10000$

**Verlauf einer Simulation mit 30
Städten es werden die
Gewichtsvektoren im
zweidimensionalen Inputraum
gezeigt nach 0, 5000, 7000 und
10000 Lernschritten**

