


IV. KOMPETITIVES LERNEN

IV.1 "Winner-Take-All" Netzwerke



Output: S_i , $i=1, \dots, M$

Gewichte: W_{ij}

Input: X_j , $j=1, \dots, N$

- Die Inputs X_j können diskret oder kontinuierlich sein.
- Die Output-Neuronen sind sogenannte "Winner-Take-All" Neuronen ("Grandmother Cells"), d.h. dass immer nur eines der S_i den Wert 1 hat und alle übrigen den Wert 0.
- Realisierungsmöglichkeiten:

A) Berechne $d_i = \|\underline{X} - \underline{W}_i\| = \sum_j (X_j - W_{ij})^2$ $i=1, \dots, M$

Bestimme $i^* = \arg\min_i d_i$

[d.h. $d_{i^*} = \min_i d_i$]

$\rightarrow S_{i^*} = 1$, alle übrigen $S_i = 0$

B) Analog zu A), aber $d_i = \|\underline{x} - \underline{w}_i\|$ durch $\underline{x} \cdot \underline{w}_i = \sum_j x_j w_{ij}$ ersetzt.

→ B) ist äquivalent zu A), wenn die Gewichtsvektoren $\underline{w}_i$ normiert sind:

$$\|\underline{w}_i\| = \sum_j w_{ij}^2 = 1$$

C) Durch inhibitorische symmetrische Verbindungen $w_{ii'} = w_{i'i} < 0$ zwischen den Outputneuronen (und exzitatorischen Selbstverbindungen $w_{ii} > 0$).

→ Outputschiicht wie ein Hopfield-Netzwerk relaxieren lassen (gegen Grenzzustand mit nur einem $S_i = 1$).

• Anwendungen:

- Diskretisierung eines kontinuierlichen Inputraums
- Clustering, Kategorisierung, Data Compression

[→ Vorverarbeitung von Inputdaten!]

- Vorteile:
 - Vereinfachung eines nachfolgenden Lernprozesses.
 - Erhaltung von Nachbarschaftsrelationen (siehe "Feature Maps").

- Nachteile:
 - Für jede Kategorie wird ein separates Outputneuron benötigt.
 - Nicht robust gegenüber Degradation oder Ausfall von Komponenten.

IV.2 Einfaches kompetitives Lernen

→ LERNALGORITHMUS (UNSUPERVISED):

① Zufällige Startgewichte $W_{ij}(0)$ $i = 1, \dots, M$
 $j = 1, \dots, N$

② Wahl eines Inputbeispiels: $X_j(t)$, $j = 1, \dots, N$

③ Berechne $d_i = \sum_{j=1}^N [X_j(t) - W_{ij}(t)]^2$, $i = 1, \dots, M$

④ Bestimme $i^* = \operatorname{argmin}_i d_i$: $d_{i^*} = \min_i d_i$

⑤ Ändere Gewichte:

$$W_{i^*j}(t+1) = W_{i^*j}(t) + \eta(t) [X_j(t) - W_{i^*j}(t)]$$


$$W_{ij}(t+1) = W_{ij}(t), \quad i \neq i^* \quad j = 1, \dots, N$$

⑥ $t \leftarrow t+1$, GOTO ②

Die Lernrate $\eta(t)$, $0 \leq \eta(t) < 1$, nimmt während des Lernprozesses ab:

$$\text{z.B. } \eta(t) = \eta_0 e^{-\alpha t} \text{ oder } \eta(t) = \eta_0 (1 - \alpha t)$$

Graphisch:



IV.3 "Learning Vector Quantization" (LVQ)


LVQ für Datenkompression ist wahrscheinlich die wichtigste Anwendung von kompetitiven Lernalgorithmen.

Idee: Kategorisierung eines vorgegebenen Satzes von Inputvektoren $\underline{X}^n$ in M Klassen, wobei diese durch Prototypvektoren $\underline{W}_i$ dargestellt werden:

Inputraum:

• : Inputvektoren $\underline{X}^n$

o : Prototypvektoren $\underline{W}_i$



→ Realisierung der $\underline{W}_i = (W_{i1}, W_{i2}, \dots, W_{iN})$ durch die Gewichtsvektoren von kompetitiven Neuronen (ev. mehrere Neuronen pro Klasse!):

A) Benutze einfachen Lernalgorithmus von IV.2
[+ nachträgliche Bestimmung der Klassen $C(i)$]

B) SUPERVISED LVQ :

[T. Kohonen, "Selforganization and Associative Memory", 3rd Edition, Springer 1989]


- Klasse $C(\underline{X})$ der Inputbeispiele bekannt
- $C(i)$ = Klasse des kompetitiven Neurons i

$$\textcircled{5} \quad W_{i^*j}(t+1) = W_{i^*j}(t) + \eta(t) [X_j(t) - W_{i^*j}(t)] \quad \text{if } C(i^*) = C(\underline{X}(t))$$

$$W_{i^*j}(t+1) = W_{i^*j}(t) - \eta(t) [X_j(t) - W_{i^*j}(t)] \quad \text{if } C(i^*) \neq C(\underline{X}(t))$$

$$W_{ij}(t+1) = W_{ij}(t) \quad , \quad i \neq i^*$$

Beispiel: [M. de Bollivier et al, IJCNN 1990]



- 3 Klassen: A) Superpositionen von h_1 und h_2
 B) " " " h_1 " h_3
 C) " " " h_2 " h_3

Problem 1: $x(t) = \alpha h_n(t) + (1-\alpha) h_m(t) + \varepsilon(t)$ $0 \leq t \leq 20$

α zufällig in $[0, 1]$, $\varepsilon(t) \sim N(0, 1)$

Problem 2:
$$x(t) = \begin{cases} \frac{1}{5} [\alpha h_n(t) + (1-\alpha) h_m(t)] + \varepsilon(t) & 0 \leq t \leq 20 \\ \varepsilon(t) & 21 \leq t \leq 40 \end{cases}$$

Trainingsset: 300 Beispiele

Testset: 5000 Beispiele


Resultate:

Methode	LVQ	Multilayer Perceptron
Test Set (Problem 1)	84.6 % korrekt	81.6 % korrekt
Test Set (Problem 2)	77.0 % korrekt	80.5 % korrekt

IV.4 Topologieerhaltende Abbildungen

(KOHONEN FEATURE MAPS)

→ Benachbarte Inputvektoren werden auch durch benachbarte Outputneuronen dargestellt
[ERHALTUNG VON NACHBARSCHAFTSRELATIONEN !]





→ LERNALGORITHMUS FÜR DIE W_{ij} :

- ① $W_{ij}(0) = 0.5 + \epsilon \cdot \text{RND} \quad \begin{matrix} i=1, \dots, M \\ j=1, \dots, N \end{matrix} \quad [\text{RND zufällig} \in (-1, +1)]$
- ② $X_j = X_j(t), \quad j=1, \dots, N$
- ③ $d_i = \sum_{j=1}^N [X_j(t) - W_{ij}(t)]^2, \quad i=1, \dots, M$
- ④ $i^* = \arg \min_i d_i : d_{i*} = \min_i d_i$
- ⑤ $W_{ij}(t+1) = W_{ij}(t) + \eta(t) \cdot \Lambda_{ii*}(t) [X_j(t) - W_{ij}(t)]$
 $j=1, \dots, N$
- ⑥ $t \leftarrow t+1, \text{ GO TO } ②$

• Nachbarschaftsfunktion $\Lambda_{ii*} = \begin{cases} 1 & \text{für } i=i^* \\ \text{abnehmend mit } |i - i^*| \end{cases}$


- Beispiele für Nachbarschaftsfunktionen:



- Lernrate $\eta(t)$, $0 \leq \eta(t) < 1$, und Reichweite von $\Lambda_{ii^*}(t)$ sind abnehmende Funktionen von t .

BEISPIEL 1:


- 2-dim Inputraum: $X_1(t), X_2(t)$ zufällig in $(0,1)$
- 1-dim Ring mit 16 kompetitiven Neuronen, $i = 1, \dots, 16$




$$t_{\max} = 16'000$$

BEISPIEL 2: [Kohonen 1984]

- 2-dim Inputraum: $X_1(t)$, $X_2(t)$ zufällig in $(0,1)$
 - 2-dim Gitter mit 100 kompetitiven Neuronen
- Zeitliche Entwicklung der Gewichte W_{i1} , W_{i2} :

BEISPIEL 3: [Ritter et al, 1989]

- 2-dim Inputraum: $X_1(t)$, $X_2(t)$ zufällig, aber mit grösserer Wahrsch.keit in der Mitte des rechteckigen Gebietes
- 2-dim Gitter mit 15×24 kompetitiven Neuronen



→ Grössere Konzentration in der Mitte
(→ feinere Auflösung!)

ANWENDUNGEN VON KOHONEN FEATURE MAPS

- SPRACHERKENNUNG:

→ T. Kohonen:

"THE NEURAL PHONETIC TYPEWRITER",
IEEE Computer 21, 11 (March 1988)

- KLASSIFIZIERUNG VON ZUSTÄNDEN EINES ELEKTRISCHEN VERTEILNETZES:

→ D. Niebur and A.J. Germond:

"UNSUPERVISED NEURAL NET CLASSIFICATION OF
POWER SYSTEM STATIC SECURITY STATES",
Journal of Electrical Power and Energy Systems,
Vol. 14, No. 2/3, pp. 233-242 (1992).

- LASTVORHERSAGE IN ELEKTRISCHEN VERTEILNETZEN:


→ A.J. Germond, T. Macabrey, and T. Traumann:

"APPLICATION OF ARTIFICIAL NEURAL NETWORKS
TO LOAD FORECASTING",

Proceedings Summer Workshop on Neural Network
Computing for the Electric Power Industry,
Stanford, pp. 24-35 (1992).

IV.5 Hybride Systeme

Beispiel:



→ Feature Map (Vorverarbeitung) mit anschließendem Feedforward-Netzwerk!

→ Lernverfahren:

$$W_{ij}(t+1) = W_{ij}(t) + \eta(t) \wedge_{ii^*}(t) [X_j(t) - W_{ij}(t)]$$

$$V_i(t+1) = V_i(t) + \eta'(t) \wedge'_{ii^*}(t) [Y^D - V_i(t)]$$

↑
(Y^D = gewünschter Output)

ANWENDUNGEN:

- ROBOTIK, REGELUNG

→ H.J. Ritter, T.M. Martinetz, and K.J. Schulten:

"Topology-Conserving Maps for Learning Visuo-Motor-Coordination", Neural Networks 2, 159 (1989).

- VORHERSAGE

→ T.M. Martinetz et al.:

"Neural Gas Network for Time-Series Prediction"
IEEE Trans. on Neural Networks, Vol. 4, No. 4, 558-569 (1993).