

**AUFGABE 1:      Klassifizierungsverfahren:  
ID3 vs. Perceptron**

Betrachten Sie das folgende Klassifizierungsproblem:

Objekt	Attributwerte		Klasse
	X1	X2	
A	2	3	+
B	3	2	-
C	3	3	+
D	4	3	+
E	4	1	-
F	4	2	+
G	1	1	-
H	1	3	-
I	1	2	
J	2	2	
K	2	1	
L	3	1	

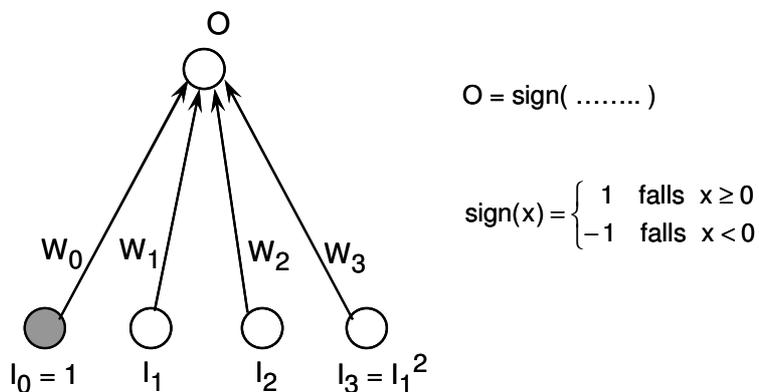
- 1) Bestimmen Sie den ID3-Entscheidungsbaum für die Klassifizierung der Objekte A bis H. (Berechnung der Entropieabnahme für den ersten Entscheidungsschritt!).
- 2) Zeigen Sie (graphisch) dass das Problem linear separabel ist, d.h. auch mit Hilfe eines Perceptrons gelöst werden kann.
- 3) Vergleichen und diskutieren Sie die Klassifizierungen der Objekte I bis L durch ein Perceptron mit denjenigen des ID3-Entscheidungsbaums.

## AUFGABE 2:      Perceptron mit erweitertem Inputraum

Betrachten Sie die folgenden 4 Lernbeispiele ( $D = \text{gewünschter Output}$ ) :

Beispiel	$I_1$	$I_2$	$D$
a	-1	0	+1
b	0	0	-1
c	0	1	-1
d	1	1	+1

- 1) Zeigen Sie, dass dieses nicht linear separable Klassifizierungsproblem durch ein Perceptron mit erweitertem Inputraum gelöst werden kann:



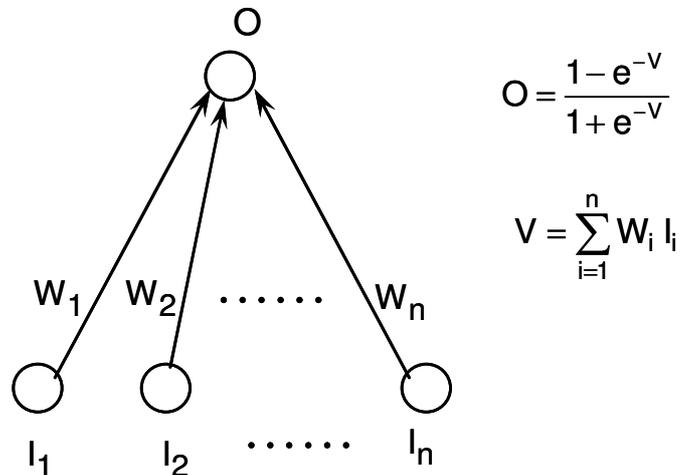
- 2) Wählen Sie einen konkreten Gewichtsvektor ( $W_0, W_1, W_2, W_3$ ), der das Problem löst, und bestimmen Sie im  $(I_1, I_2)$ -Raum die Trennkurven zwischen den Gebieten mit  $O = +1$  bzw.  $O = -1$ .

Stellen Sie diese Trennkurven auch graphisch dar.

Hinweis: Sie können das Problem vereinfachen, indem Sie sich auf Lösungen mit  $W_1 = 0$  beschränken!

### AUFGABE 3:      Gradienten-Lernverfahren

Betrachten Sie ein Perceptron mit sigmoidem Output,



und die Fehlerfunktion

$$F = - (1 + D) \ln(1+O) - (1 - D) \ln(1 - O) ,$$

*(D = gewünschter Output).*

- 1) Bestimmen Sie analytisch die Gewichtsänderungen  $\Delta W_i$ , die sich aus der Minimierung von F mit Hilfe eines Gradientenverfahrens ergeben.

[ Hinweis:  $\frac{\partial O}{\partial V} = \frac{1}{2}(1 - O^2)$  .]

- 2) Zu Beginn seien alle  $W_i = 0$  (d.h.  $O = 0$  für jeden Input).

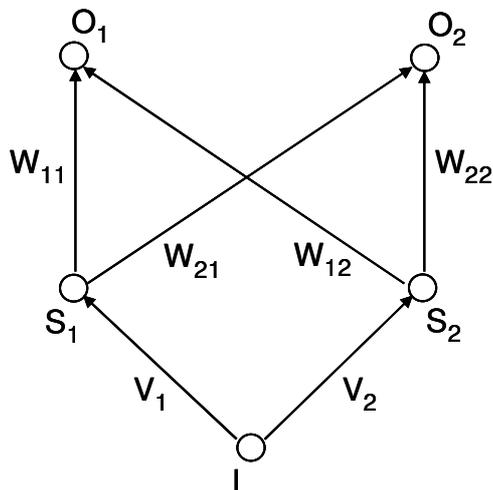
Betrachten Sie nun ein Lernbeispiel mit  $D = 1$ , bei dem alle Inputs  $I_i$  entweder +1 oder -1 sind.

Wie gross ist der Output O für ein solches Lernbeispiel nach einem

Lernschritt mit  $\eta = \frac{2}{n}$  ?

## AUFGABE 4:      Error-Backpropagation

Gegeben sei das folgende Feedforward-Netzwerk,



$$O_1 = f(W_{11} S_1 + W_{12} S_2)$$

$$O_2 = f(W_{21} S_1 + W_{22} S_2)$$

$$S_1 = f(V_1 I)$$

$$S_2 = f(V_2 I)$$

$$f(x) = \frac{1}{1 + e^{-x}}$$

Berechnen Sie die Änderung von  $V_1$  beim Backpropagation-Lernverfahren mit folgender Fehlerfunktion:

$$F = \frac{1}{2}(D_1 - O_1)^2 + \frac{1}{2}(D_2 - O_2)^2.$$

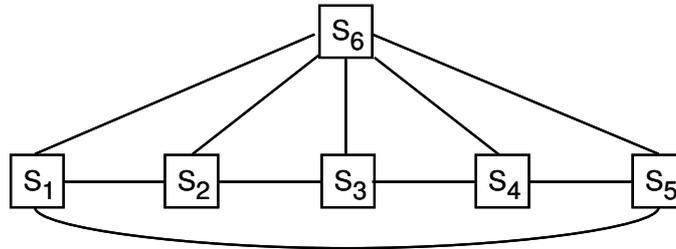
(  $D_1, D_2 =$  gewünschte Outputs)

Stellen Sie  $\Delta V_1$  explizit als Funktion von  $O_1, D_1, O_2, D_2, S_1, I$  und den  $W_{ij}$  dar!

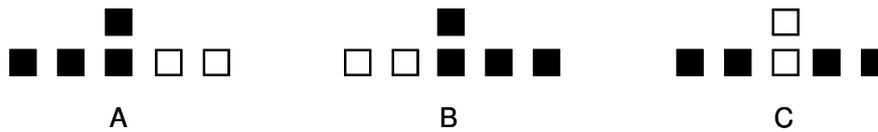
Hinweis:  $\frac{df}{dx} = f(x)[1 - f(x)]$

## AUFGABE 5: Hopfield-Netzwerk

Betrachten Sie das folgende (nicht vollständig verknüpfte) Hopfield-Netzwerk,



und benutzen Sie die Hebb'sche Lernregel, um in diesem Netzwerk die drei Muster A, B und C zu speichern:



( wobei:  $\blacksquare$  :  $S_i = 1$  ,  $\square$  :  $S_i = -1$  )

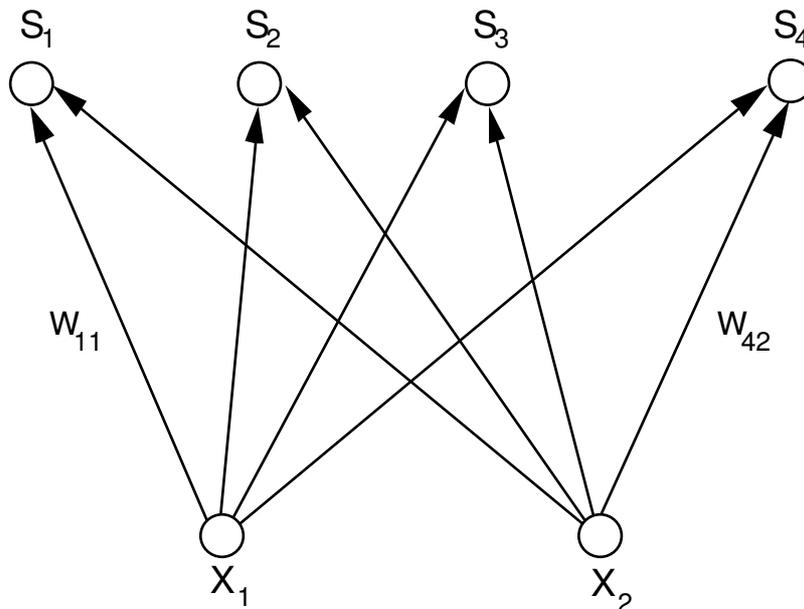
1) Welche Werte ergeben sich für die Gewichte der 10 Verbindungen?

2) Gegen welches Muster konvergiert das Anfangsmuster  $\square \blacksquare \blacksquare \square \blacksquare$  wenn Sie die  $S_i$  der Reihe nach ( $S_1, S_2, \dots$ ) aufdatieren?

3) Vergleichen Sie die Energie des Anfangsmusters mit derjenigen des stabilen Endmusters.

## AUFGABE 6: Winner-Take-All Netzwerk, Kompetitives Lernen

Betrachten Sie ein Netzwerk mit 2 Inputs und 4 Winner-Take-All Output-Neuronen:



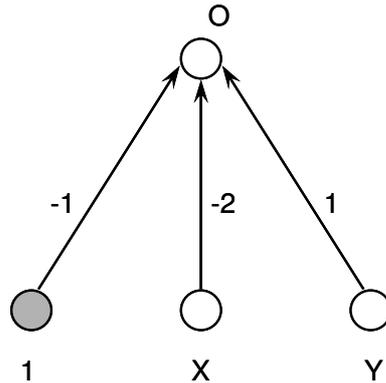
$$\begin{array}{cccc} W_{11} = 0.2 & W_{21} = 0.8 & W_{31} = 0.6 & W_{41} = 0.4 \\ W_{12} = 0.2 & W_{22} = 0.2 & W_{32} = 0.8 & W_{42} = 0.8 \end{array}$$

- 1) Bestimmen Sie die Winner-Gebiete der 4 Outputneuronen im Inputraum ( $0 < X_1, X_2 < 1$ ).
- 2) Präsentieren Sie dann die beiden Lernbeispiele ( $X_1 = 0.4, X_2 = 0.5$ ) und ( $X_1 = 0.9, X_2 = 0.8$ ) je einmal, und ändern Sie die Gewichte gemäss dem einfachen kompetitiven Lernverfahren [d.h. nur die Gewichte des Winner-Neurons werden geändert] mit  $\eta = 2/3$ .
- 3) Bestimmen Sie die neuen Winner-Gebiete im Inputraum.

Hinweis: Alle Aufgaben lassen sich rein graphisch lösen!

## AUFGABE 7:      **Stochastische Neuronen, Reinforcement Learning**

- 1) Für welche Werte von X und Y ist beim folgenden stochastischen Neuron (Standard-Definition) die Wahrscheinlichkeit, dass O den Wert +1 annimmt, grösser als 0.5 ?



- 2) Wie werden in einem stochastischen Feedforward-Netzwerk die Gewichtsänderungen  $\Delta W_{ij}$  berechnet ( $A_{R-P}$  – Lernverfahren ohne Bestrafung)?
- 3) Welche Vorteile hat Reinforcement Learning (z.B. das  $A_{R-P}$  – Lernverfahren) im Vergleich mit Gradienten-Lernverfahren (z.B. Error-Backpropagation)?

## **AUFGABE 8:      Lernverfahren und Lernverhalten**

- 1) Warum und wie kann man Hopfield-Netzwerke (bzw. Hopfield-Tank-Netzwerke) auch dazu benutzen, gewisse Typen von Optimierungsproblemen zu lösen?
  
- 2) Welche Probleme können beim Error-Backpropagation-Lernverfahren auftreten?  
Was sind die Ursachen für diese Probleme?  
Beschreiben Sie mögliche Massnahmen gegen diese Probleme.
  
- 3) Beschreiben Sie die wichtigsten Schritte eines einfachen stochastischen Lernverfahrens (z.B. "Iterative Improvement").
  
- 4) Zur Lösung eines Problems mit 10 Inputs und einem Output möchten Sie ein Multilayer-Perceptron verwenden, das 2 Schichten mit je 4 Hidden Units enthält (aufeinander folgende Schichten sind vollständig verknüpft!).  
Wie viele Lernbeispiele sollten mindestens zur Verfügung stehen, damit das Sinn macht?