

## Mathematikaufgabe 86

---

[Home](#) | [Startseite](#) | [Impressum](#) | [Kontakt](#) | [Gästebuch](#)

**Aufgabe:** Bilden Sie vermöge eines dreistufigen neuronalen Netzes mit verdeckter Schicht sämtliche neuronalen Bitmuster, die sich mittels dreier Eingangsneuronen bilden lassen, auf ihre komplementären Bitmuster ab.

**Lösung:** Die  $n_1$  Inputneuronen  $y_i^{(1)}$  der Eingabeschicht (1) mit den Gewichten  $w_{i_2 i_1}^{(1)}$  können übersichtlich in folgender Matrixschreibweise zusammengefaßt werden:

$$\begin{pmatrix} x_1^{(1)} \\ x_2^{(1)} \\ x_3^{(1)} \end{pmatrix} = \begin{pmatrix} w_{11}^{(1)} & w_{21}^{(1)} & w_{31}^{(1)} \\ w_{12}^{(1)} & w_{22}^{(1)} & w_{32}^{(1)} \\ w_{13}^{(1)} & w_{23}^{(1)} & w_{33}^{(1)} \end{pmatrix} \begin{pmatrix} y_1^{(1)} \\ y_2^{(1)} \\ y_3^{(1)} \end{pmatrix}.$$

In Komponentenschreibweise erhalten wir mit der linearen Standard-Propagierungsfunktion  $x_{i_2}^{(1)}$  das folgende lineare Gleichungssystem:

$$x_{i_2}^{(1)} = \sum_{i_1=1}^{n_1} w_{i_2 i_1}^{(1)} y_{i_1}^{(1)}.$$

Mit der Aktivierungsfunktion  $f$  ergeben sich die  $n_2$  verborgenen Neuronen  $y_{i_2}^{(2)}$  der verdeckten Schicht (2) mit den Gewichten  $w_{i_2 i_3}^{(2)}$  zu

$$y_{i_2}^{(2)} = f(x_{i_2}^{(1)}) = f\left(\sum_{i_1=1}^{n_1} w_{i_2 i_1}^{(1)} y_{i_1}^{(1)}\right).$$

Die lineare Standard-Propagierungsfunktion  $x_{i_3}^{(2)}$  kann wieder durch eine orthogonale Matrix<sup>1</sup> mit den Gewichten  $w_{i_2 i_3}^{(2)}$  ausgedrückt werden:

$$\begin{pmatrix} x_1^{(2)} \\ x_2^{(2)} \\ x_3^{(2)} \end{pmatrix} = \begin{pmatrix} w_{11}^{(2)} & w_{21}^{(2)} & w_{31}^{(2)} \\ w_{12}^{(2)} & w_{22}^{(2)} & w_{32}^{(2)} \\ w_{13}^{(2)} & w_{23}^{(2)} & w_{33}^{(2)} \end{pmatrix} \begin{pmatrix} y_1^{(2)} \\ y_2^{(2)} \\ y_3^{(2)} \end{pmatrix},$$

die wir in Komponentenschreibweise wieder wie folgt schreiben können:

$$x_{i_3}^{(2)} = \sum_{i_2=1}^{n_2} w_{i_2 i_3}^{(2)} y_{i_2}^{(2)}.$$

Die Optimierung startet an der Ausgangsebene der  $n_3$  Outputneuronen der Ausgangschicht (3) mit dem Output  $y_{i_3}^{(3)}$  des Ausgangsneurons  $i_3$ :

---

<sup>1</sup> Eine Matrix, deren Inverse gleich ihrer Transponierten ist

$$y_{i_3}^{(3)} = f(x_{i_3}^{(2)}) = f\left(\sum_{i_2=1}^{n_2} w_{i_2 i_3}^{(2)} y_{i_2}^{(2)}\right),$$

mit  $1 \leq i_3 \leq n_3$ . Das Optimierungsproblem kann damit wie folgt beschrieben werden:

$$E = \frac{1}{2} \sum_{i_3=1}^{n_3} (\eta_{i_3} - y_{i_3}^{(3)})^2 = \frac{1}{2} \sum_{i_3=1}^{n_3} (\eta_{i_3} - f(x_{i_3}^{(2)}))^2 \rightarrow \min.$$

Der Gradient der Fehlerfunktion muß folglich null sein:

$$\nabla E = \left( \frac{\partial E}{\partial w_{11}^{(1)}}, \frac{\partial E}{\partial w_{12}^{(1)}}, \dots, \frac{\partial E}{\partial w_{n_1 n_2}^{(1)}}, \frac{\partial E}{\partial w_{11}^{(2)}}, \frac{\partial E}{\partial w_{12}^{(2)}}, \dots, \frac{\partial E}{\partial w_{n_2 n_3}^{(2)}} \right) = 0.$$

Zur Gewichtsadaption sind die partiellen Ableitungen der Fehlerfunktion

$$\Delta w_{ij}^{(1)} = -\lambda \frac{\partial E}{\partial w_{ij}^{(1)}} \quad \text{und} \quad \Delta w_{ij}^{(2)} = -\lambda \frac{\partial E}{\partial w_{ij}^{(2)}}$$

zu bilden.

Zunächst gilt an der Schnittstelle der Hidden-Output-Schicht für  $w_{i_2 i_3}^{(2)}$  nach der Kettenregel

$$\frac{\partial E}{\partial w_{ij}^{(2)}} = \frac{\partial E}{\partial y_{i_3}^{(3)}} \frac{\partial f(x_{i_3}^{(2)})}{\partial x_{i_3}^{(2)}} \frac{\partial x_{i_3}^{(2)}}{\partial w_{ij}^{(2)}}.$$

Da

$$\frac{\partial w_{i_2 i_3}^{(2)}}{\partial w_{ij}^{(2)}} = \begin{cases} 1 & \text{für } (i, j) = (i_2, i_3), \\ 0 & \text{für } (i, j) \neq (i_2, i_3), \end{cases}$$

ist die Summe

$$\sum_{i_2=1}^{n_2} \sum_{i_3=1}^{n_3} \frac{\partial w_{i_2 i_3}^{(2)}}{\partial w_{ij}^{(2)}} = 1$$

und damit die Summe

$$\sum_{i_2=1}^{n_2} \sum_{i_3=1}^{n_3} \frac{\partial x_{i_3}^{(2)}}{\partial w_{i_2 i_3}^{(2)}} \frac{\partial w_{i_2 i_3}^{(2)}}{\partial w_{ij}^{(2)}} = \frac{\partial x_{i_3}^{(2)}}{\partial w_{ij}^{(2)}}.$$

Folglich ist

$$\frac{\partial E}{\partial w_{ij}^{(2)}} = \sum_{i_3=1}^{n_3} \frac{\partial E}{\partial y_{i_3}^{(3)}} \frac{\partial f(x_{i_3}^{(2)})}{\partial x_{i_3}^{(2)}} \sum_{i_2=1}^{n_2} \frac{\partial x_{i_3}^{(2)}}{\partial w_{i_2 i_3}^{(2)}} \frac{\partial w_{i_2 i_3}^{(2)}}{\partial w_{ij}^{(2)}}.$$

Die Ableitung von  $E$  nach  $y_{i_3}^{(3)}$  liefert

$$\frac{\partial E}{\partial y_{i_3}^{(3)}} = -(\eta_{i_3} - y_{i_3}^{(3)})$$

Für die Sigmoidfunktion

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

ist

$$f'(x) = \frac{1}{(1 + e^{-x})^2} e^{-x} = f(x) \frac{1 + e^{-x} - 1}{1 + e^{-x}} = f(x)(1 - f(x))$$

und damit

$$\frac{\partial y_{i_3}^{(3)}}{\partial x_{i_3}^{(2)}} = \frac{\partial f(x_{i_3}^{(2)})}{\partial x_{i_3}^{(2)}} = f(x_{i_3}^{(2)})(1 - f(x_{i_3}^{(2)})).$$

Wegen

$$x_{i_3}^{(2)} = \sum_{i_2=1}^{n_2} w_{i_2 i_3}^{(2)} y_{i_2}^{(2)} \quad \text{ist} \quad \frac{\partial x_{i_3}^{(2)}}{\partial w_{i_2 i_3}^{(2)}} = y_{i_2}^{(2)}.$$

Setzen wir alle drei Beiträge ein, erhalten wir, da  $\partial w_{i_2 i_3}^{(2)} / \partial w_{ij}^{(2)}$  für  $(i, j) \neq (i_3, i_2)$  verschwindet, den Ausdruck

$$\begin{aligned} \frac{\partial E}{\partial w_{ij}^{(2)}} &= -\sum_{i_3=1}^{n_3} (\eta_{i_3} - f(x_{i_3}^{(2)})) f(x_{i_3}^{(2)})(1 - f(x_{i_3}^{(2)})) \sum_{i_2=1}^{n_2} y_{i_2}^{(2)} \frac{\partial w_{i_3 i_2}^{(2)}}{\partial w_{ij}^{(2)}} \\ &= -(\eta_j - y_j^{(3)}) y_j^{(3)} (1 - y_j^{(3)}) y_i^{(2)}. \end{aligned}$$

Damit lautet die erste Gewichtung

$$\Delta w_{i_2 i_3}^{(2)} = -\lambda \frac{\partial E}{\partial w_{i_2 i_3}^{(2)}} = \lambda (\eta_{i_3} - y_{i_3}^{(3)}) y_{i_3}^{(3)} (1 - y_{i_3}^{(3)}) y_{i_2}^{(2)}.$$

An der Schnittstelle Input-Hidden-Schicht für  $w_{i_1 i_2}^{(1)}$  gilt nach der Kettenregel analog

$$\frac{\partial E}{\partial w_{ij}^{(1)}} = \sum_{i_3=1}^{n_3} \frac{\partial E}{\partial y_{i_3}^{(3)}} \frac{\partial f(x_{i_3}^{(2)})}{\partial x_{i_3}^{(2)}} \sum_{i_2=1}^{n_2} \frac{\partial x_{i_3}^{(2)}}{\partial y_{i_2}^{(2)}} \frac{\partial f(x_{i_2}^{(1)})}{\partial x_{i_2}^{(1)}} \sum_{i_1=1}^{n_1} \frac{\partial x_{i_2}^{(1)}}{\partial w_{i_1 i_2}^{(1)}} \frac{\partial w_{i_1 i_2}^{(1)}}{\partial w_{ij}^{(1)}}.$$

Ebenfalls in Analogie zu oben kommt hinzu

$$\frac{\partial y_{i_2}^{(2)}}{\partial x_{i_2}^{(1)}} = \frac{\partial f(x_{i_2}^{(1)})}{\partial x_{i_2}^{(1)}} = f(x_{i_2}^{(1)}) (1 - f(x_{i_2}^{(1)}))$$

Wegen

$$x_{i_3}^{(2)} = \sum_{i_2=1}^{n_2} w_{i_2 i_3}^{(2)} y_{i_2}^{(2)} \quad \text{ist} \quad \frac{\partial x_{i_3}^{(2)}}{\partial y_{i_2}^{(2)}} = w_{i_2 i_3}^{(2)},$$

und aus

$$x_{i_2}^{(1)} = \sum_{i_1=1}^{n_1} w_{i_1 i_2}^{(1)} y_{i_1}^{(1)} \quad \text{folgt} \quad \frac{\partial x_{i_2}^{(1)}}{\partial w_{i_1 i_2}^{(1)}} = y_{i_1}^{(1)}.$$

Setzen wir alle Größen ein, erhalten wir

$$\frac{\partial E}{\partial w_{ij}^{(1)}} = - \sum_{i_3=1}^{n_3} (\eta_{i_3} - y_{i_3}^{(3)}) f(x_{i_3}^{(2)}) (1 - f(x_{i_3}^{(2)})) \sum_{i_2=1}^{n_2} w_{i_2 i_3}^{(2)} f(x_{i_2}^{(1)}) (1 - f(x_{i_2}^{(1)})) \sum_{i_1=1}^{n_1} y_{i_1}^{(1)} \frac{\partial w_{i_1 i_2}^{(1)}}{\partial w_{ij}^{(1)}}.$$

Mit

$$\frac{\partial w_{i_1 i_2}^{(2)}}{\partial w_{ij}^{(2)}} = \begin{cases} 1 & \text{für } (i, j) = (i_1, i_2), \\ 0 & \text{für } (i, j) \neq (i_1, i_2) \end{cases}$$

folgt weiter

$$\frac{\partial E}{\partial w_{ij}^{(1)}} = - \sum_{i_3=1}^{n_3} (\eta_{i_3} - y_{i_3}^{(3)}) y_{i_3}^{(3)} (1 - y_{i_3}^{(3)}) w_{j i_3}^{(2)} y_j^{(1)} (1 - y_j^{(1)}) y_i^{(1)}.$$

Mit der Wahl  $i = i_1$  und  $j = i_2$  ist

$$\frac{\partial E}{\partial w_{i_1 i_2}^{(1)}} = - \sum_{i_3=1}^{n_3} (\eta_{i_3} - y_{i_3}^{(3)}) y_{i_3}^{(3)} (1 - y_{i_3}^{(3)}) w_{i_2 i_3}^{(2)} y_{i_2}^{(2)} (1 - y_{i_2}^{(2)}) y_{i_1}^{(1)}.$$

Damit erhalten wir die zweite Gewichtung zu

$$\Delta w_{i_1 i_2}^{(1)} = -\lambda \frac{\partial E}{\partial w_{i_1 i_2}^{(1)}} = \lambda \sum_{i_3=1}^{n_3} (\eta_{i_3} - y_{i_3}^{(3)}) y_{i_3}^{(3)} (1 - y_{i_3}^{(3)}) w_{i_2 i_3}^{(2)} y_{i_2}^{(2)} (1 - y_{i_2}^{(2)}) y_{i_1}^{(1)}.$$

Für die schrittweise Gewichtsadaptation mit zufällig vorinitialisierten Verbindungsgewichten  $w_{i_2 i_3}^{(2)}(0)$  und  $w_{i_1 i_2}^{(1)}(0)$  ergibt sich insgesamt

$$\Delta w_{i_2 i_3}^{(2)}(0) = -\lambda \left. \frac{\partial E}{\partial w_{i_2 i_3}^{(2)}} \right|_{w_{i_2 i_3}^{(2)} = w_{i_2 i_3}^{(2)}(0)} = \lambda (\eta_{i_3} - y_{i_3}^{(3)}(0)) y_{i_3}^{(3)}(0) (1 - y_{i_3}^{(3)}(0)) y_{i_2}^{(2)}$$

und

$$\begin{aligned} \Delta w_{i_1 i_2}^{(1)}(0) &= -\lambda \frac{\partial E}{\partial w_{i_1 i_2}^{(1)}} \Big|_{w_{i_1 i_2}^{(1)} = w_{i_1 i_2}^{(1)}(0)} \\ &= \lambda \sum_{i_3=1}^{n_3} (\eta_{i_3} - y_{i_3}^{(3)}(0)) y_{i_3}^{(3)}(0) (1 - y_{i_3}^{(3)}(0)) w_{i_2 i_3}^{(2)}(0) y_{i_2}^{(2)}(0) (1 - y_{i_2}^{(2)}(0)) y_{i_1}^{(1)}. \end{aligned}$$

Mit den Abkürzungen  $\delta$  für die Fehler können wir die Ausdrücke noch einmal vereinfachen:

$$\begin{aligned} \delta_{i_3}^{(3)}(0) &= (\eta_{i_3} - y_{i_3}^{(3)}(0)) y_{i_3}^{(3)}(0) (1 - y_{i_3}^{(3)}(0)), \\ \delta_{i_2}^{(2)}(0) &= \sum_{i_3=1}^{n_3} \delta_{i_3}^{(3)}(0) w_{i_2 i_3}^{(2)}(0) y_{i_2}^{(2)}(0) (1 - y_{i_2}^{(2)}(0)), \end{aligned}$$

so daß

$$\Delta w_{i_2 i_3}^{(2)}(0) = \lambda \delta_{i_3}^{(3)}(0) y_{i_2}^{(2)} \quad \text{und} \quad \Delta w_{i_1 i_2}^{(1)}(0) = \lambda \delta_{i_2}^{(2)}(0) y_{i_1}^{(1)}.$$

Nach Adaption der Gewichte im ersten Schritt können die im nächsten berechnet werden:

$$w_{i_2 i_3}^{(2)}(1) = w_{i_2 i_3}^{(2)}(0) + \Delta w_{i_2 i_3}^{(2)}(0) \quad \text{bzw.} \quad w_{i_1 i_2}^{(1)}(1) = w_{i_1 i_2}^{(1)}(0) + \Delta w_{i_1 i_2}^{(1)}(0).$$

Rekursiv gilt

$$w_{i_2 i_3}^{(2)}(k+1) = w_{i_2 i_3}^{(2)}(k) + \Delta w_{i_2 i_3}^{(2)}(k) \quad \text{bzw.} \quad w_{i_1 i_2}^{(1)}(k+1) = w_{i_1 i_2}^{(1)}(k) + \Delta w_{i_1 i_2}^{(1)}(k),$$

mit

$$\Delta w_{i_2 i_3}^{(2)}(k) = \lambda \delta_{i_3}^{(3)}(k) y_{i_2}^{(2)} \quad \text{bzw.} \quad \Delta w_{i_1 i_2}^{(1)}(k) = \lambda \delta_{i_2}^{(2)}(k) y_{i_1}^{(1)}.$$

Dieses rückwärtsgewandte Durchreichen der Soll-Ist-Abweichung zwischen Zielwert und Netzoutput zurück zur Inputschicht beschreibt das, was man gemeinhin unter einem Backpropagation-Algorithmus versteht.

$y_1^{(1)}$	$y_2^{(1)}$	$y_3^{(1)}$	$y_1^{(3)}$	$y_2^{(3)}$	$y_3^{(3)}$	$\eta_1$	$\eta_2$	$\eta_3$
1	1	1	0,0290	0,0290	0,0290	0	0	0
1	1	0	0,0315	0,0315	0,9722	0	0	1
1	0	1	0,0315	0,9722	0,0315	0	1	0
0	1	1	0,9722	0,0315	0,0315	1	0	0
1	0	0	0,0386	0,9651	0,9651	0	1	1
0	1	0	0,9651	0,0386	0,9651	1	0	1
0	0	1	0,9651	0,9651	0,0386	1	1	0
0	0	0	0,9462	0,9462	0,9462	1	1	1

Tabelle 1. Werte der Eingangs- und Ausgangsneuronen sowie die Soll-Ausgangswerte

## Mathematikaufgabe 86

---

In Tabelle 1 wurden als Soll-Ausgangswerte die Komplemente der Inputwerte der Eingabeschicht gewählt. Die Fehler zwischen Soll- und Ist-Ausgangswerten liegen im Bereich von 3-5 Prozent, werden aber je nach Lage der Schwelle ohnehin entweder auf- oder abgerundet. Der Anhang enthält ein MATLAB-Programm, das den Backpropagation-Algorithmus mit Angabe des Fehlers ausführt. Die Fehler liegen in unserem Fall in der Größenordnung von  $10^{-4}$ .

### Anhang

```
% Programm Hidden Layer

% Fehlerberechnung für ein dreistufiges neuronales Netz mit verdeckter
% Schicht mit beliebig vielen Ein- und Ausgabeneuronen und einer Sigmoidkurve
% als Aktivierungsfunktion
clear all

% Der Lernparameter sei lambda
lambda = 5;

kmax = 50;

n1 = 3;
n2 = 3;
n3 = 3;

for i1=1:n1
    for i2=1:n2
        w1(i1,i2,1) = 1;
    end
end

for i2=1:n2
    for i3=1:n3
        w2(i2,i3,1) = 1;
    end
end

% Input des Neurons i1 in Schicht 1, wobei 1 <= i1 <= n1
y1(1,1) = 0;
y1(2,1) = 0;
y1(3,1) = 0;

% eta(i3) Soll-Output des Neurons i3 in Schicht 3, wobei 1 <= i3 <= n3
eta(1) = 1;
eta(2) = 1;
eta(3) = 1;

% x1(i2,1)
x1(1,1) = w1(1,1,1)*y1(1,1) + w1(2,1,1)*y1(2,1) + w1(3,1,1)*y1(3,1);
x1(2,1) = w1(1,2,1)*y1(1,1) + w1(2,2,1)*y1(2,1) + w1(3,2,1)*y1(3,1);
x1(3,1) = w1(1,3,1)*y1(1,1) + w1(2,3,1)*y1(2,1) + w1(3,3,1)*y1(3,1);
% y2(i2,1)
y2(1,1) = 1/(1+exp(-x1(1,1)));
y2(2,1) = 1/(1+exp(-x1(2,1)));
y2(3,1) = 1/(1+exp(-x1(2,1)));
% x2(i3,1)
```

## Mathematikaufgabe 86

---

```
x2(1,1) = w2(1,1,1)*y2(1,1) + w2(2,1,1)*y2(2,1) + w2(3,1,1)*y2(3,1);
x2(2,1) = w2(1,2,1)*y2(1,1) + w2(2,2,1)*y2(2,1) + w2(3,2,1)*y2(3,1);
x2(3,1) = w2(1,3,1)*y2(1,1) + w2(2,3,1)*y2(2,1) + w2(3,3,1)*y2(3,1);
% y3(i3,1)
y3(1,1) = 1/(1+exp(-x2(1,1)));
y3(2,1) = 1/(1+exp(-x2(2,1)));
y3(3,1) = 1/(1+exp(-x2(3,1)));

summeE = 0;
for k=1:kmax
    summe3 = 0;
    for i3=1:n3
        for i2=1:n2
            x2(i3,k) = w2(1,i3,k)*y2(1,1) + w2(2,i3,k)*y2(2,1) +
w2(3,i3,k)*y2(3,1);
            y3(i3,k) = 1/(1+exp(-x2(i3,k)));
            delta3(i3,k) = (eta(i3) - y3(i3,k))*y3(i3,k)*(1-y3(i3,k));
            x1(i2,k) = w1(1,i2,k)*y1(1,1) + w1(2,i2,k)*y1(2,1) +
w1(3,i2,k)*y1(3,1);
            y2(i2,k) = 1/(1+exp(-x1(i2,k)));
            Deltaw2(i2,i3,k) = lambda*delta3(i3,k)*y2(i2,1);
            summe3 = summe3 + delta3(i3,k)*w2(i2,i3,k)*y2(i2,k)*(1-
y2(i2,k));
            delta2(i2,k) = summe3;
            w2(i2,i3,k+1) = w2(i2,i3,k) + Deltaw2(i2,i3,k);
            for i1=1:n1
                Deltaw1(i1,i2,k) = lambda*delta2(i2,k)*y1(i1,1);
                w1(i1,i2,k+1) = w1(i1,i2,k) + Deltaw1(i1,i2,k);
            end
        end
        E(k) = summeE + 1/2*(eta(i3) - y3(i3,k))^2;
    end
end

Error = E(kmax)
Input1 = y1(1,1)
Input2 = y1(2,1)
Input3 = y1(3,1)
Output1 = y3(1,kmax)
Output2 = y3(2,kmax)
Output3 = y3(3,kmax)
Solloutput1 = eta(1)
Solloutput2 = eta(2)
Solloutput3 = eta(3)
```