


Fuzzy-Regler




Mengenbeziehungen:
 $A = B \Rightarrow \mu_A(x) = \mu_B(x)$
 $A \subseteq B \Rightarrow \mu_A(x) \leq \mu_B(x)$
 $A \cap B \Rightarrow \mu_{A \cap B}(x) = \min(\mu_A(x), \mu_B(x))$
 $A \cup B \Rightarrow \mu_{A \cup B}(x) = \max(\mu_A(x), \mu_B(x))$

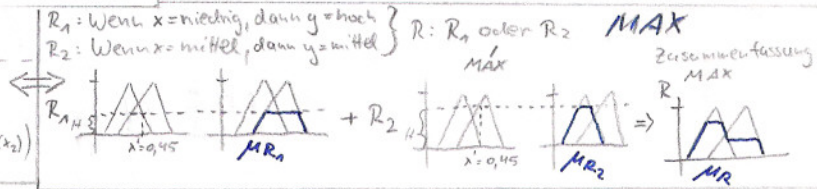
Relationen:
 $A \cdot B \Rightarrow \mu_{A \cdot B}(x) = \mu_A(x) \cdot \mu_B(x)$
 $A \oplus B \Rightarrow \mu_{A \oplus B}(x) = \mu_A(x) \oplus \mu_B(x)$
 $A \setminus B \Rightarrow \mu_{A \setminus B}(x) = \mu_A(x) \cdot (1 - \mu_B(x))$

Fuzzy-Menge
 $\mu_A(x) \in [0, 1]$
 Diskret-Fall: $\mu_A(x) \in \{0, 0.1, 0.2, \dots, 1\}$
 Analytisch: $0.0/0 + 0.1/1 + 0.2/2 + 0.3/3 + 0.4/4 + \dots$
 Kontinuierliche Fall: $\int \mu_A(x) dx$
 Analytisch: $L = y(x) = -\frac{1}{3}x + 6$
 $R = y(x) = \frac{1}{2}x + 6$


Kenngrößen:
 Kardinalzahl = $\text{card}(A) = \sum_{x \in A} \mu_A(x) = 0.2 + 0.3 + 0.4 + \dots = 2.3$
 Höhe = $\text{hgt}(A) = 0.5$ (höchster PK) $\neq 1 \Rightarrow$ nicht normalisiert
 $\Rightarrow \text{card}(A_n) = \frac{\text{card}(A)}{\text{hgt}(A)} = \frac{2.3}{0.5} = 4.6 \leftarrow$ normalisierung
 Träger (Stützmenge) = $\{x \mid \mu_A(x) > 0\} = \{2, 3, 4, 5, 6, 7, 8\}$
 Kern = $\text{core}(A) = \{x \mid \mu_A(x) = 1\} = \{5\}$
 α -Schnitt = $A \geq \alpha \Rightarrow \mu_A(x) \geq \alpha \Rightarrow A^{\alpha} = \{4, 5, 6\}$
 Strenger α -Schnitt = $A > \alpha \Rightarrow \mu_A(x) > \alpha \Rightarrow A^{>\alpha} = \{5\}$



Fuzzy-Inferenz
 R: Wenn x=niedrig, dann y=hoch
 $\mu_R(x, y) = \min(\mu_{\text{niedrig}}(x), \mu_{\text{hoch}}(y))$
 $x = 0.2, \mu_{\text{niedrig}}(0.2) = 0.2$
 $\mu_R(0.2, y) = 0.2$
 R: Wenn x_1 =niedrig und x_2 =mittel, dann y=hoch
 $\mu_R(x_1, x_2, y) = \min(\mu_{\text{niedrig}}(x_1), \mu_{\text{mittel}}(x_2), \mu_{\text{hoch}}(y))$
 $x_1 = 0.2, x_2 = 0.4, \mu_{\text{niedrig}}(0.2) = 0.2, \mu_{\text{mittel}}(0.4) = 0.4$
 $\mu_R(0.2, 0.4, y) = 0.2$



MAX-Prod-Inferenz
 R: Wenn x=niedrig, dann y=hoch
 $\mu_R(x, y) = \min(\mu_{\text{niedrig}}(x), \mu_{\text{hoch}}(y))$
 $x = 0.3, \mu_{\text{niedrig}}(0.3) = 0.3$
 $\mu_R(0.3, y) = 0.3$



Defuzzifizierung Max-Methode
 $V_1 = \text{Mittelwert}$
 $g^* = \frac{y_1 + y_2}{2}$
 V_2 (linke Max) = y_1
 V_3 (rechte Max) = y_2
 neg:

Schwerpunkt-Methode
 Vorteil: Robustheit
 $g^* = \frac{\int y \cdot \mu_R(y) \cdot dy}{\int \mu_R(y) \cdot dy}$

f-Norm (Durchschnitt)
 $t: [0, 1] \times [0, 1] \rightarrow t(x, y) \in [0, 1]$
 1) neutrales Element
 2) Monotonie
 3) Kommutativität
 4) Assoziativität

f-Conorm (Vereinigung)
 $s: [0, 1] \times [0, 1] \rightarrow [0, 1]$

Fuzzy-Ähnlichkeit
 \Rightarrow kann, wenn kern = kern
 Streng-Fuzzy-Ähnlich
 Satz: Zwei Fuzzy-Mengen über dem Träger + Kern übereinstimmen, sind streng fuzzy-ähnlich + umgekehrt
 $M_1 \approx M_2; \mu_1 \approx \mu_2; 1 - \mu_1 \approx 1 - \mu_2$

KNN
 Neuronale Netze... bestehen aus Elementen, die untereinander Daten/Informationen austauschen... sind in der Lage zu lernen und ihre Leistungsfähigkeit zu verbessern

Aktivierungsfunktion
 $f(x) = \begin{cases} -1 & x \leq -1/a \\ x & -1/a < x < 1/a \\ 1 & x \geq 1/a \end{cases}$
 mit $x = g_i$; $-a$ und $a > 0$

Sigmoidfunktion
 $1 + e^{-g \cdot x}$
 Aktivierung im Bereich $[0, 1]$

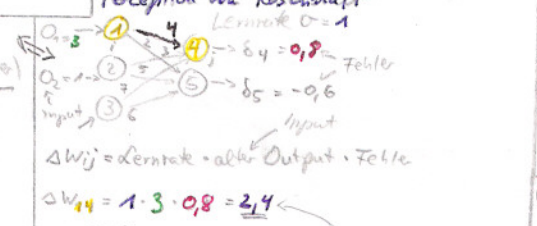
Tangenshyperbolicus-Funktion
 $e^{g \cdot x} - e^{-g \cdot x}$
 Aktivierung im Bereich $[-1, 1]$
 *Aktivierungsstatus!

Perceptrons: XOR-Funktion nicht lösbar \rightarrow Aufbau Perceptrons + dessen (binäre) Neuronen

Inputfunktion
 1) Max ($j=1 \dots n$) $\rightarrow \max(\text{inj} \cdot \text{Wij})$
 2) Min $\rightarrow \min(\text{inj} \cdot \text{Wij})$
 3) Prod $\rightarrow \prod(\text{inj} \cdot \text{Wij})$
 4) Sum $\rightarrow \sum \text{inj} \cdot \text{Wij}$

NN: Inputschicht, innerste Schicht, Outputschicht
 Gewicht bewirkt, dass hohe Input ein kleiner Einfluss
 Outputfunktion: Binär oder keine!
 Netztypen:
 Feedforward \rightarrow Feedforward
 Feedback \rightarrow Feedback
 Entscheidung:
 1) Einzelentscheidung \Rightarrow ja/nein
 2) Alternativenentscheidung \Rightarrow Auswahl aus Menge
 3) Programmentscheidung \Rightarrow Auswahl Menge aus Menge

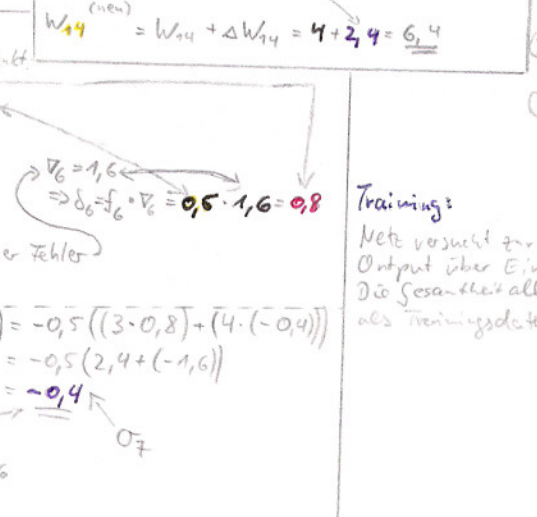
Delta Regel
 $\Delta W_{ij} = \frac{\text{Lernrate} \cdot \text{Output} \cdot \text{Fehler}}{\text{Anzahl Inputs}}$
 $\Delta W_{14} = \frac{1 \cdot 3 \cdot 0.8}{3} = 0.8$
 $W_{14}^{(n)} = 4 + 0.8 = 4.8$



1) Max-Wert aller gewichteten Einzel-inputs wird gewählt
 2) Min-Wert [...] wird gewählt
 3) Summiert alle gewichteten Einzel-inputs
 4) Multipliziert mit [...]

1) Netzoutput - und Solloutput vergleichen \Rightarrow Fehler = Gewichte-Veränderung
 2) Kein exakte Fehlerwert (nahe, weit, sehr nahe)
 3) Menge durch Kriterien aufteilen

Backpropagation-Net-Verfahren
 Wert-Aktivierungsfunktion
 $\delta_6 = 0.8$
 $\delta_7 = -0.4$
 Lernrate $\sigma = 1$
 $\Delta W_{46} = 1 \cdot 2 \cdot 0.8 = 1.6$
 $\delta_6 = f'_6 \cdot (O_6 - O_{6\text{soll}}) \leftarrow$ physischer Fehler
 $\delta_4 = \text{modifizierter Fehler}$
 $\delta_4 = f'_4 \cdot (W_{46} \cdot \delta_6 + W_{47} \cdot \delta_7) = -0.5 \cdot ((3 \cdot 0.8) + (4 \cdot (-0.4))) = -0.5 \cdot (2.4 - 1.6) = -0.4$
 $\Delta W_{24} = 1 \cdot 4 \cdot (-0.4) = -1.6$
 $\hat{=}$ Lernrate \cdot Output \cdot Fehler



Lernformen:
 1) überwachte Lern
 2) bestärkendes
 3) unbeaufsichtigtes

Lernregel:
 neues Gewicht = altes Gewicht + Gewichtsänderung
 $W_{ij}(t+1) = W_{ij}(t) + \Delta W_{ij}(t)$

Hebbische Hypothese:
 Nehme 2 Neuronen zur gleichen Zeit den gleichen Zustand an (aktiv oder inaktiv), dann wird das Gewicht zwischen den Neuronen verstärkt.

Perceptron Regel:
 Für jede Neuron M_i , der Ausgangsbeitrag wird die Solloutputabweichung δ_i berechnet. δ_i wird mit out_j (Output des Vorgängerneurons M_j) und dem Faktor σ (Lernrate) multipliziert.
 $\Delta W_{ij} = \sigma \cdot out_j \cdot (agi - out_i)$
 $\delta_i = (agi - out_i)$

Training:
 Netz versucht zur Inputkombination den richtige Output über Einstellen der Gewichte zu finden.
 Die Gesamtheit aller Versuche bezeichnet man als Trainingsdatensatz.