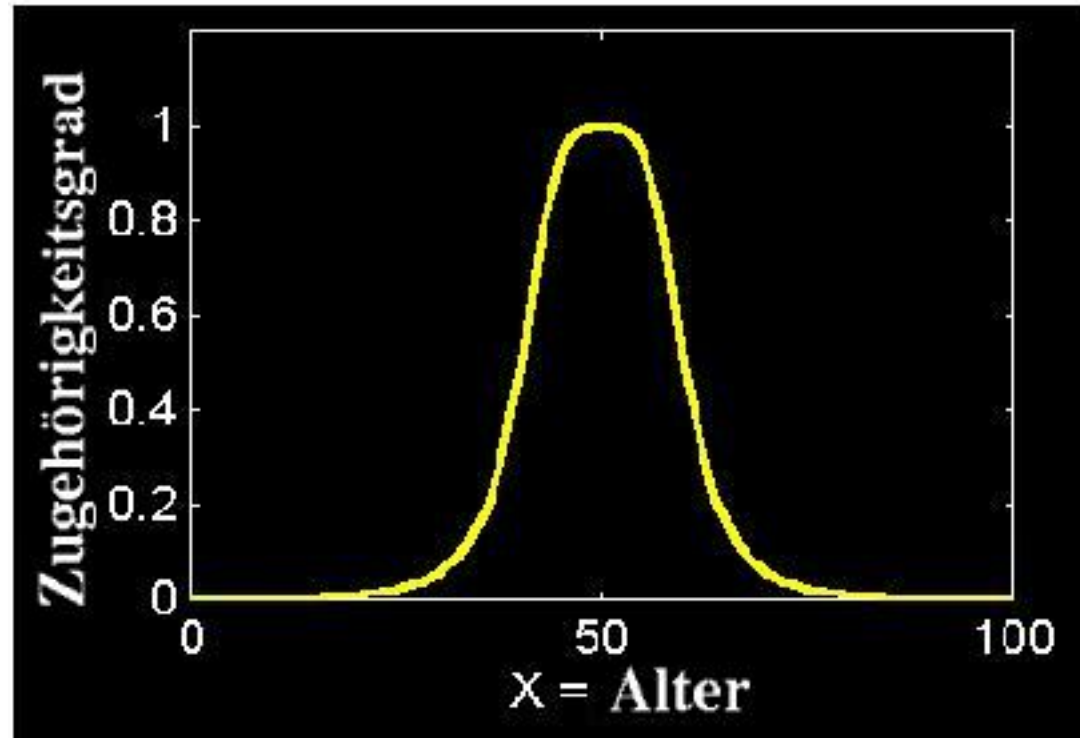










Symbolumwandlung der Kernfunktionen

Positiv definierte, konvexe Kernfunktionen können als Fuzzy-Mengen betrachtet werden. z.B.:

$$\mu_B(x) = \frac{1}{1 + \left(\frac{x-50}{10}\right)^2}$$



ZF-Funktionen



Einführung in die Fuzzy-Mengen

Die Auswertung der Regeln eines Fuzzy-Reglers ist prinzipiell ein Interpolationsprozeß.

- ungenaue natürsprachliche Abstufungen von Begriffen wie “groß, “schön”, “stark” ...
- menschliche Denk- und Verhaltensmodelle mit der einstufigen Logik:

Autofahren: “Wenn-Dann”-Regeln

Autoparken: genau auf den Millimeter?

- Verwendung unscharfer Sprache statt numerischer Beschreibung:

bremse 2.52 m vor der Kurve

→ nur in Maschinesystemen

bremse kurz vor der Kurve

→ in natürlicher Sprache

Fuzzy-Mengen / Fuzzy-Logik als Mechanismus für

- ungenaue natursprachliche Abstufungen von Begriffen wie “groß”, “schön”, “stark” ...

- Verwendung unscharfer Sprache statt numerischer Beschreibung.
- Abstraktion von unnötigen/zu komplexen Details.
- Modellierung menschlicher Denk- und Verhaltensprozesse mit der einstufigen Logik.

Charakteristische Funktion vs. Zugehörigkeitsfunktion

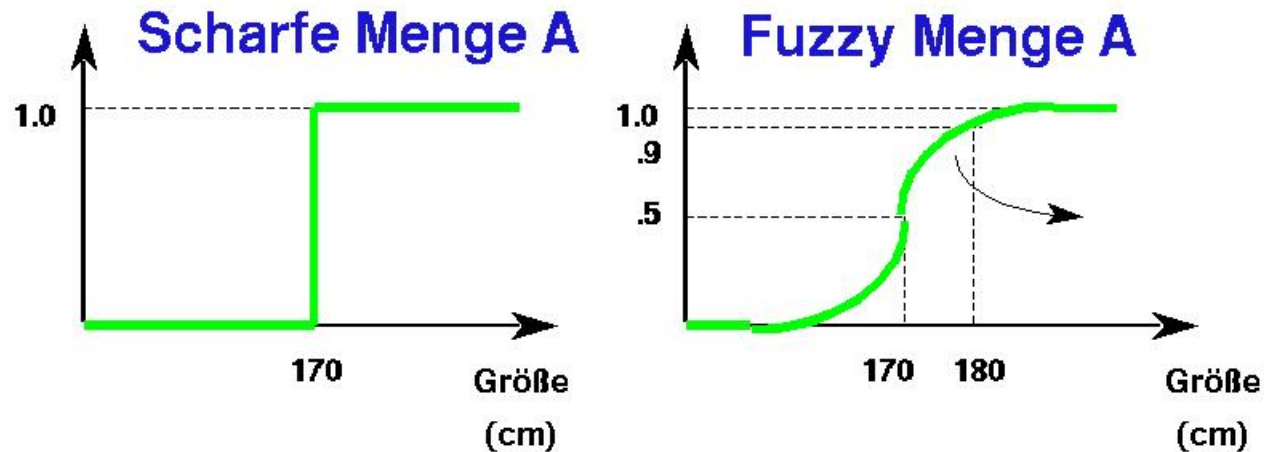
Für **Fuzzy-Mengen** A verwendet man eine verallgemeinerte charakteristische Funktion μ_A , die jedem Element $x \in X$ eine reelle Zahl aus $[0, 1]$ zuordnet — den “Grad”, zu dem das Element x zur beschriebenen unscharfen Menge A gehört:

$$\mu_A : X \rightarrow [0, 1]$$

μ_A wird als Zugehörigkeitsfunktion (ZF) bezeichnet.

$$A = \{(x, \mu_A(x) | x \in X\}$$

Zugehörigkeitsfunktion




Charakteristik der kontinuierlichen ZF:

- Positiv definierte, konvexe Funktionen (einige wichtige Kernfunktionen).
- Subjektive Perzeption
- keine probabilistische Funktionen


ZF-Formulierung - I

Triangulare: $trimf(x; a, b, c) = \max \left(\min \left(\frac{x - a}{b - a}, \frac{c - x}{c - b} \right), 0 \right)$




Trapezoidale:

$$trapmf(x; a, b, c, d) = \max \left(\min \left(\frac{x - a}{b - a}, 1, \frac{d - x}{d - c} \right), 0 \right)$$




ZF-Formulierung - II

Gaussian: $gaussmf(x; c, \sigma) = e^{-\frac{1}{2}\left(\frac{x-c}{\sigma}\right)^2}$



B-Splines: $bsplinemf(x, x_i, x_{i+1}, \dots, x_{i+k})$



Linguistische Variable

Eine numerische Variable nimmt numerische Werte an:

$$\textit{Das_Alter} = 25$$


Eine linguistische Variable nimmt linguistische Werte (Terme) an:

$$\textit{Das_Alter ist jung}$$

Ein linguistischer Wert ist eine Fuzzy-Menge.

Fuzzy-Partition

Fuzzy-Partitionen über die linguistischen Werte “Jung”, “Mittleres Alter” und “Alt”:



Fuzzy-Logik: Ableitungsmechanismen

Eine Fuzzy-Regel wird folgendermaßen formuliert:

“IF A THEN B ”

mit Fuzzy-Mengen A , B über den Universen X , Y .

Einer der wichtigsten Ableitungsmechanismen ist der verallgemeinerte Modus-Ponens (GMP):

Implikation: IF x is A THEN y is B

Prämisse: x is A'

Konklusion: y is B'

Fuzzy-Systeme zur Funktionsapproximation

Grundidee:

- Beschreibung des gewünschten Reglerverhaltens mit Hilfe umgangssprachlicher, qualitativer Regeln.
- Quantifizierung linguistischer Werte durch Fuzzy-Mengen.
- Regel–Auswertung durch Verfahren der Fuzzy-Logik bzw. der Interpolation.

Fuzzy-Regeln:

„**IF** (eine Menge Konditionen werden erfüllt)

THEN

(eine Menge Konsequenzen können bestimmt werden)“

In den Prämissen (Antecedenten) vom IF-Teil:


linguistische Variablen aus der Domäne der
Prozeßzustände;

In den Konklusionen (Konsequenten) vom THEN-Teil:

linguistische Variablen aus der Regelungsdomäne.



Adaptive Netzwerke


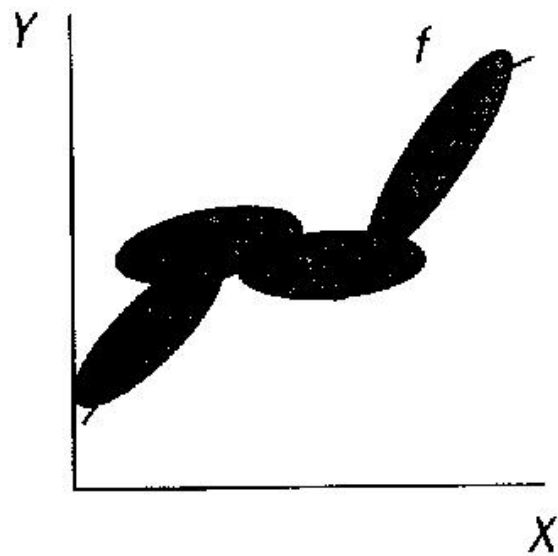


Architektur:

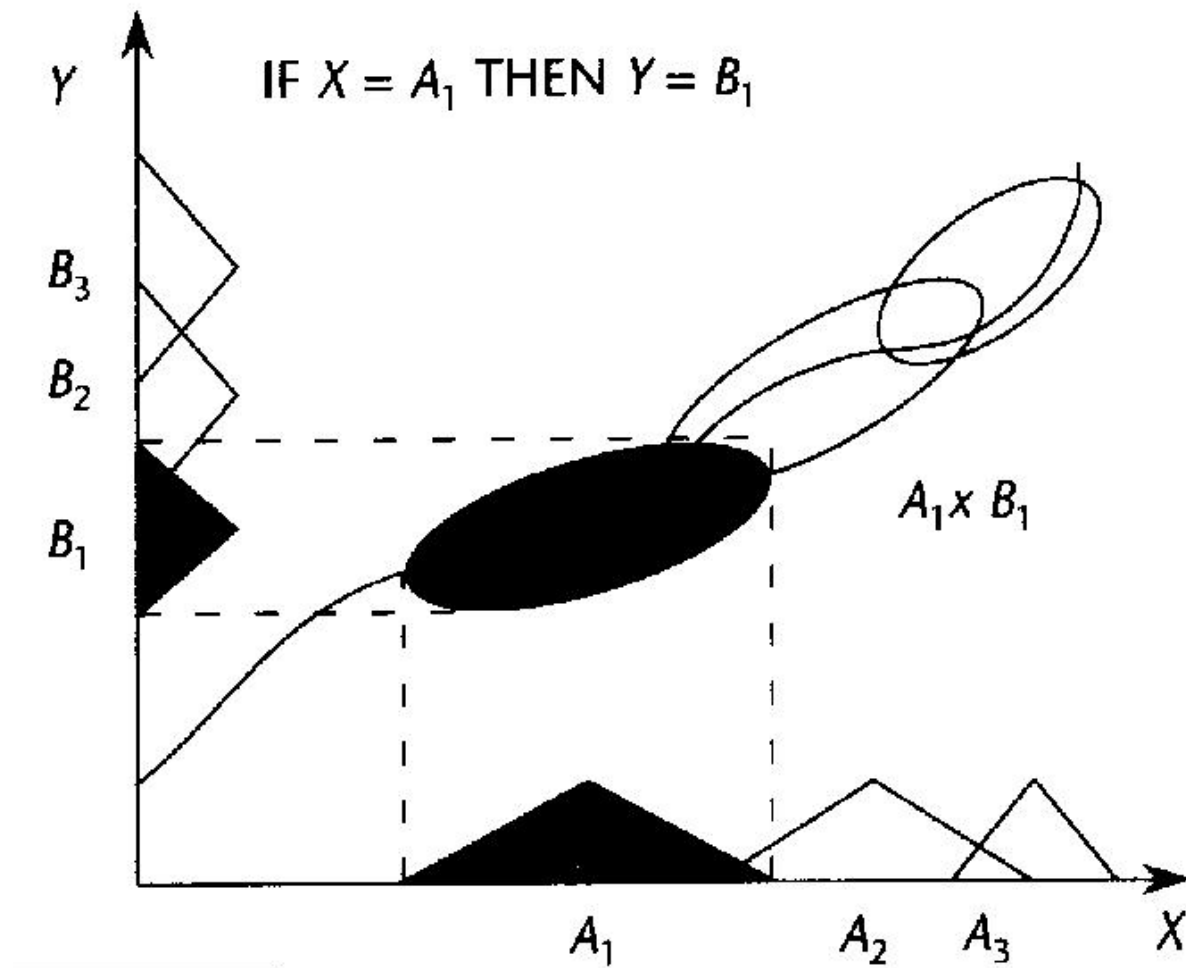
Feedforward Netzwerke mit verschiedenen Knoten-Funktionen

Rule Extraction

Die Fuzzy-Patches (Kosko):



Ein Fuzzy-Regel-Patch:



Additive Systeme


Ein additiver Fuzzy-Controller addiert die “THEN”-Teile der gefeuerten Regeln.

Fuzzy-Approximations-Satz:


Ein additiver Fuzzy-Controller kann eine beliebige stetige Funktion $f : X \rightarrow Y$ approximieren wenn X kompakt ist.

Optimale Fuzzy-Regel-Patches


Optimale Fuzzy-Regel-Patches decken die Extrema einer Funktion:




Projektion der Ellipsoide auf die Ein- und Ausgangsachse:




Die Größe eines Ellipsoids hängt von den Trainingsdaten ab.




(a)



(b)




(c)




(d)


Visualisierung des Eingangs-Ausgangs-Raumes:




Ein Beispiel der Interpolation:




Datencluster entlang der Funktion:







Approximation mit Fuzzy Mengen an den Projektionen der Extremapunkte:



Approximation einer zweidimensionalen Funktion

$$z = f(x, y)$$

$$= 3(1-x)^2 e^{-x^2-(y+1)^2} - 10\left(\frac{x}{5} - x^3 - y^5\right) e^{-x^2-y^2} - \frac{1}{3} e^{-(x+1)^2-y^2}$$



Ableitungen der Funktion:

$$\begin{aligned}\frac{dz}{dx} = & -6(1-x)e^{-x^2-(y+1)^2} - 6(1-x)^2xe^{-x^2-(y+1)^2} \\ & - 10\left(\frac{1}{5} - 3x^2\right) * e^{-x^2-y^2} + 20\left(\frac{1}{5}x - x^3 - y^5\right)xe^{-x^2-y^2} \\ & - \frac{1}{3}(-2x-2)e^{-(x+1)^2-y^2}\end{aligned}$$

$$\begin{aligned}\frac{dz}{dy} = & 3(1-x)^2(-2y-2)e^{-x^2-(y+1)^2} \\ & + 50y^4e^{-x^2-y^2} + 20\left(\frac{1}{5}x - x^3 - y^5\right)ye^{-x^2-y^2} \\ & + \frac{2}{3}ye^{-(x+1)^2-y^2}\end{aligned}$$

$$\begin{aligned}
\frac{d}{dx} \frac{dz}{dx} = & 36xe^{-x^2-(y+1)^2} - 18x^2e^{-x^2-(y+1)^2} - 24x^3e^{-x^2-(y+1)^2} + 12x^4e^{-x^2-(y+1)^2} \\
& + 72xe^{-x^2-y^2} - 148x^3e^{-x^2-y^2} - 20y^5e^{-x^2-y^2} + 40x^5e^{-x^2-y^2} + 40x^4ye^{-x^2-y^2} \\
& - \frac{2}{3}e^{-(x+1)^2-y^2} - \frac{4}{3}e^{-(x+1)^2-y^2}x^2 - \frac{8}{3}e^{-(x+1)^2-y^2}x
\end{aligned}$$

$$\begin{aligned}
\frac{d\left(\frac{dz}{dy}\right)}{dy} &= -6(1-x)^2 e^{-x^2-y(+1)^2} + 3(1-x)^2(-2y-2)^2 e^{-x^2-(y+1)^2} + 2 \\
&\quad - 200y^5 e^{-x^2-y^2} + 20\left(\frac{1}{5}x - x^3 - y^5\right) e^{-x^2-y^2} \\
&\quad - 40\left(\frac{1}{5}x - x^3 - y^5\right) y^2 e^{-x^2-y^2} + \frac{2}{3} e^{-(x+1)^2-y^2} \\
&\quad - \frac{4}{3} y^2 e^{-(x+1)^2-y^2}
\end{aligned}$$

Vereinte Betrachtung aus der statistischen Lerntheorie - I

$\{(\mathbf{x}_i, y_i)\}_{i=1}^l$ seien die Daten oder Beispiele. Gesucht wird eine Funktion f , die die folgende Darstellung minimiert:

$$H[f] = \frac{1}{l} \sum_{i=1}^l V(y_i, f(\mathbf{x}_i)) + \lambda \|f\|_K^2$$

wobei $V(\cdot, \cdot)$ eine *Verlustfunktion* und $\|f\|_K^2$ eine Norm im Hilbert-Raum \mathcal{H} ist, welche von einer positiv definierten Kernfunktion K bestimmt wird, und λ der Regularisierungsparameter ist.

Die Probleme in der Modellierung, Datenregression und Musterklassifikation beruhen jeweils auf einer Art von $V(\cdot, \cdot)$.

Vereinte Betrachtung aus der statistischen Lerntheorie - II

1. $V(y_i, f(\mathbf{x}_i)) = (y_i - f(\mathbf{x}_i))^2$

($y_i \in \mathbb{R}^1$, V : Quadratische Fehlerfunktion)

\Rightarrow *Regularization Networks, RN*

2. $V(y_i, f(\mathbf{x}_i)) = |y_i - f(\mathbf{x}_i)|_\epsilon$

($y_i \in \mathbb{R}^1$, $|\cdot|_\epsilon$: eine ϵ -unempfindliche Norm)

\Rightarrow *Support Vector Machines Regression, SVMR*

3. $V(y_i, f(\mathbf{x}_i)) = |1 - y_i f(\mathbf{x}_i)|_+$

($y_i \in \{-1, 1\}$, $|x|_+ = x$ für $x \geq 0$, sonst $|x|_+ = 0$)

\Rightarrow *Support Vector Machines Classification, SVMC*

Vereinigte Betrachtung aus der statistischen Lerntheorie - II

1. $V(y_i, f(\mathbf{x}_i)) = (y_i - f(\mathbf{x}_i))^2$

(y_i : eine reelle Zahl, V : Quadratische Fehlerfunktion)

\Rightarrow *Regularization Networks, RN*

2. $V(y_i, f(\mathbf{x}_i)) = |y_i - f(\mathbf{x}_i)|_\epsilon$

(y_i : eine reelle Zahl, $|\cdot|_\epsilon$: eine ϵ -unempfindliche Norm)

\Rightarrow *Support Vector Machines Regression, SVMR*

3. $V(y_i, f(\mathbf{x}_i)) = |1 - y_i f(\mathbf{x}_i)|_+$

(y_i : -1 oder 1, $|x|_+ = x$ für $x \geq 0$, sonst $|x|_+ = 0$)

\Rightarrow *Support Vector Machines Classification, SVMC*

Für Modellierungs- und Regelungsaufgaben ist die 1. Definition am wichtigsten.

Universelle Funktionsapproximierung - I

Ein Regularisierungsnetzwerk kann alle glatten Funktionen beliebig gut approximieren.

Die allgemeine Lösung dieses Problems ist:

$$f(x) = \sum_{i=1}^l c_i K(x; x_i)$$

wobei c_i die Koeffizienten sind.

Universelle Funktionsapproximierung - II

Proposition der Approximation:

Für irgendeine kontinuierliche Funktion Y , die auf einer kompakten Untermenge R^n definiert wird und K eine der Kernfunktionen ist, gibt es eine Funktion $y^*(x) = \sum_{i=1}^l c_i K(x; x_i)$, so dass für alle x und irgendein ϵ gilt:

$$|Y(x) - y^*(x)| < \epsilon$$

Universelle Funktionsapproximatoren

Verwendung verschiedener Kernfunktionen führt zu unterschiedlichen Modellen:

$K(\mathbf{x} - \mathbf{x}_i) = \exp(-\ \mathbf{x} - \mathbf{x}_i\ ^2)$	Gaussian RBF
$K(\mathbf{x} - \mathbf{x}_i) = (\ \mathbf{x} - \mathbf{x}_i\ ^2 + c^2)^{-\frac{1}{2}}$	Inverse Multiquadratische Funktion
$K(\mathbf{x} - \mathbf{x}_i) = \tanh(\mathbf{x} \cdot \mathbf{x}_i - \theta)$	Multilagen Perzeptron
$K(\mathbf{x} - \mathbf{x}_i) = (1 + \mathbf{x} \cdot \mathbf{x}_i)^d$	Polynom vom Grad d
$K(x - x_i) = B_{2n+1}(x - x_i)$	B-Splines
$K(x - x_i) = \frac{\sin(d + \frac{1}{2})(x - x_i)}{\sin \frac{(x-x_i)}{2}}$	Trigonometrisches Polynom
...	...

Probleme

1. “Fluch der Dimensionalität” durch exponentielle Abhängigkeit des Speicherbedarfs von der Dimension des Eingaberaumes.
2. *Aliasing* bei der Merkmals-Extrahierung.
3. Nicht vorhandene Soll-Daten (y).
4. Nicht vorhandene Eingangsfaktoren.

