

B-Spline-Kurve und -Basisfunktionen

Eine **B-Spline-Kurve** der Ordnung k ist ein stückweise aus **B-Splines (Basisfunktion)** zusammengesetztes Polynom vom Grad $(k - 1)$, das an den Segmentübergängen im allgemeinen C^{k-2} stetig differenzierbar ist.

Dabei seien B-Splines Stückweise Polynome, denen die folgenden geordneten Parameterwerte zugrundeliegen:


$$\mathbf{t} = (t_0, t_1, t_2, \dots, t_m, t_{m+1}, \dots, t_{m+k}),$$

wobei

- m : wird von der Anzahl der zu interpolierenden Punkte bestimmt
- k : die festgelegte Ordnung der B-Spline-Kurve


Beispiele von B-Splines

B-Splines der Ordnung 1, 2, 3 und 4:



Innerhalb eines Parameterintervalls gibt es k sich überlappende B-Splines.


Ein Beispiel der kubischen B-Splines



B-Splines der Ordnung $k - 1$


Das rekursive Definitionsverfahren einer B-Spline-Basisfunktion

$N_{i,k}(t)$:




B-Splines der Ordnung k - II


Aktuelle Segmente der B-Spline-Basisfunktionen der Ordnungen 2, 3 und 4 für $t_i \leq t < t_{i+1}$:




Uniforme B-Splines der Ordnung 1 bis 4




$k=1$



$k=2$




$k=3$



$k=4$

Nichtuniforme B-Splines

Ordnung 3:



Eigenschaften der B-Splines

Partition of unity: $\sum_{i=0}^k N_{i,k}(t) = 1.$

Positivity: $N_{i,k}(t) \geq 0.$

Local support: $N_{i,k}(t) = 0$ for $t \notin [t_i, t_{i+k}].$

C^{k-2} continuity: If the knots $\{t_i\}$ are pairwise different from each other, then $N_{i,k}(t) \in C^{k-2}$, i.e.

$N_{i,k}(t)$ is $(k - 2)$ times continuously differentiable.

Gewinnung einer B-Spline-Kurve

Eine B-Spline-Kurve kann dadurch konstruiert werden, daß eine Menge von vorgegebenen Größen mit diesen B-Splines gemischt werden:

$$\mathbf{r}(t) = \sum_{j=0}^m \mathbf{v}_j \cdot N_{j,k}(t)$$

wobei \mathbf{v}_j *Kontrollpunkte* (de *Boor-Punkte*) genannt werden.

Sei ein Parameter t gegeben, ist $\mathbf{r}(t)$ ein Punkt dieser B-Spline-Kurve.

Wenn t von t_{k-1} bis zu t_{m+1} variiert, so stellt $\mathbf{r}(t)$ eine C^{k-2} stetig differenzierbare Kurve dar.

Berechnung von Kontrollpunkten aus Datenpunkten

Die Punkte \mathbf{v}_j sind nur bei $k = 2$ identisch mit den Datenpunkten zur Interpolation, sonst nicht.

Ein Kontrollpunktzug bildet eine konvexe Hülle für die Interpolationskurve.

Zwei Verfahren zur Berechnung von Kontrollpunkten aus Datenpunkten:


1 Durch die Lösung des folgenden Gleichungssystems (**Böhm84**):

$$\mathbf{q}_j(t) = \sum_{j=0}^m \mathbf{v}_j \cdot N_{j,k}(t)$$


wobei \mathbf{q}_j die Datenpunkte für die Interpolation sind, $j = 0, \dots, m$.

2 Durch Lernen basierend auf dem Gradient-Abstieg (**Zhang98**).


Lattice - I



Lattice - II



Tensor-Produkt 2D-NURBS




Problematik in der realen Welt

- **Modellierung:** Lernen aus Beispielen, selbstoptimierende Gestaltung, Vorhersagen, ...
- **Regelung:** Perzeption-Aktion-Zyklus, Zustandsregelung, Identifikation dynamischer Systeme, ...

Funktionsapproximation als Benchmark zur Wahl eines Modells

Funktionsapproximation - 1D Beispiel

Eine Testfunktion $f(x) = 8\sin(10x^2 + 5x + 1)$ mit $-1 < x < 1$ und die richtig verteilten B-Splines:



Lattice





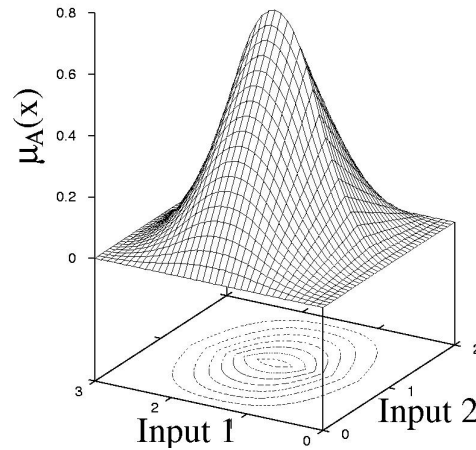
Abbildung 1: The B-spline model – a two-dimensional illustration.

Jedes n -dimensionale Viereck ($n > 1$) wird von dem j^{th} multivariaten B-spline $N_k^j(x)$ bedeckt. $N_k^j(x)$ ist über den Tensorprodukt n univariate B-splines:


$$N_k^j(x) = \prod_{j=1}^n N_{i_j, k_j}^j(x_j) \quad (1)$$



(a) Tensor product of two, order 2 univariate B-splines.



(b) Tensor product of one order 3 and one order 2 univariate B-splines.



(c) Tensor product of two univariate B-splines of order 3.

Abbildung 2: Bivariate B-splines formed by taking the tensor product of two univariate B-splines.

Allgemeine Anforderungen an einen Approximator

- **Universalität**: Approximation von beliebigen Funktionen
- **Generalisierung**: gute Approximation ohne *Overfitting*
- **Adaptivität**: selbsteinstellend anhand von neuen Daten
- **Parallelität**: Rechnen nach biologischen Vorbildern
- **Interpretierbarkeit**: mindestens als “Grey-box” anstatt “Black-box”

Bedeutung der Interpretierbarkeit eines Modells

Richard P. Feynman: “the way we have to describe nature is generally incomprehensible to us” .

Albert Einstein: “it should be possible to explain the laws of physics to a barmaid” .


Wichtige Gründe für symbolische Interpretierbarkeit eines Approximators:

- Linguistische Modellierung bietet ein Mittel zur Fertigungsübertragung von einem Experten auf einen Computer oder Roboter.
- Automatisches Lernen eines transparenten Modells erleichtert die Analyse, Validierung und Überwachung bei der Entwicklung eines Modells bzw. eines Reglers.
- Transparente Modelle besitzen vielfältige Anwendungsmöglichkeiten in *Decision-Support Systems*.

Symbolumwandlung der Kernfunktionen

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

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



B-Spline ANFIS

Bei einem B-Spline ANFIS mit n Eingängen x_1, x_2, \dots, x_n , werden Regeln der folgenden Form benutzt:

$\{ \text{Regel}(i_1, i_2, \dots, i_n): \text{IF } (x_1 \text{ IS } N_{i_1, k_1}^1) \text{ AND } (x_2 \text{ IS } N_{i_2, k_2}^2) \text{ AND } \dots \text{ AND } (x_n \text{ IS } N_{i_n, k_n}^n) \text{ THEN } y \text{ IS } Y_{i_1 i_2 \dots i_n} \},$

wobei

- x_j : Eingangsgröße j ($j = 1, \dots, n$),
- k_j : Ordnung der B-Spline-Basisfunktion für x_j ,

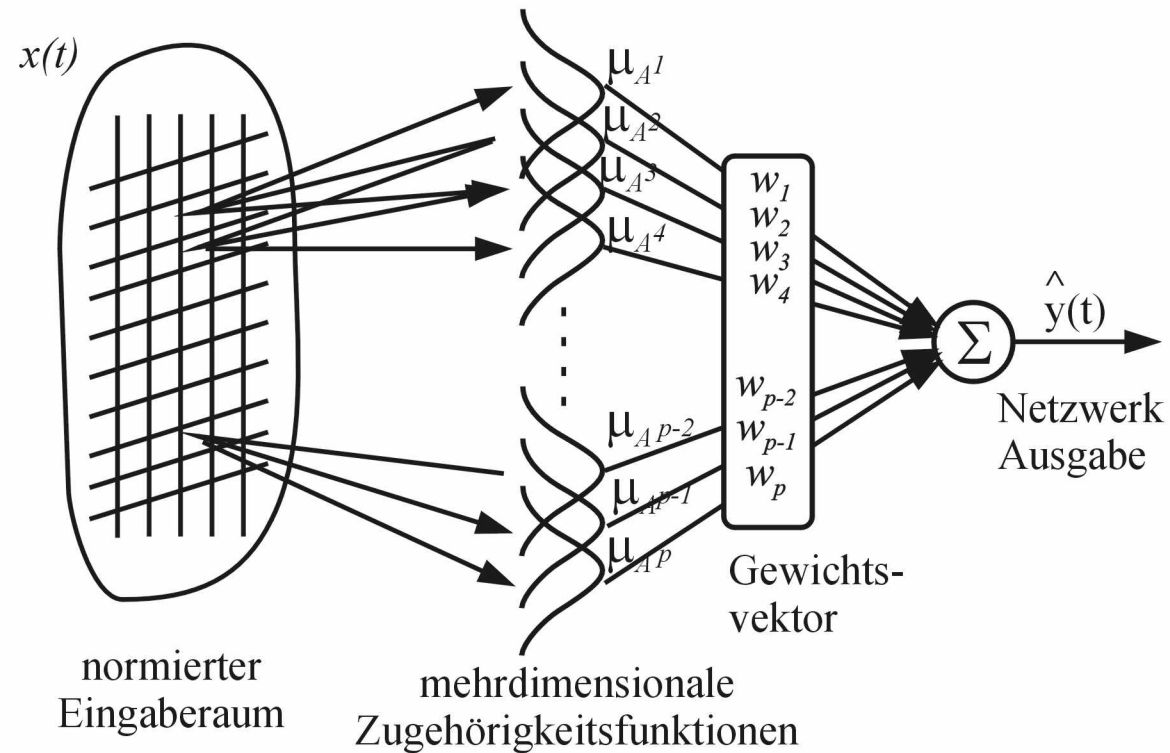
- N_{i_j, k_j}^j : mit dem i -ten linguistischen Term für x_j assoziierte B-Spline-Funktion,
- $i_j = 0, \dots, m_j$, Partitionierung von Eingang j ,
- $Y_{i_1 i_2 \dots i_n}$: Kontrollpunkte der *Regel*(i_1, i_2, \dots, i_n).
- der “AND”-Operator: Produkt

Dann ist der Ausgang y eines MISO Regelungssystems:

$$y = \sum_{i_1=1}^{m_1} \cdots \sum_{i_n=1}^{m_n} (Y_{i_1, \dots, i_n} \prod_{j=1}^n N_{i_j, k_j}^j(x_j))$$

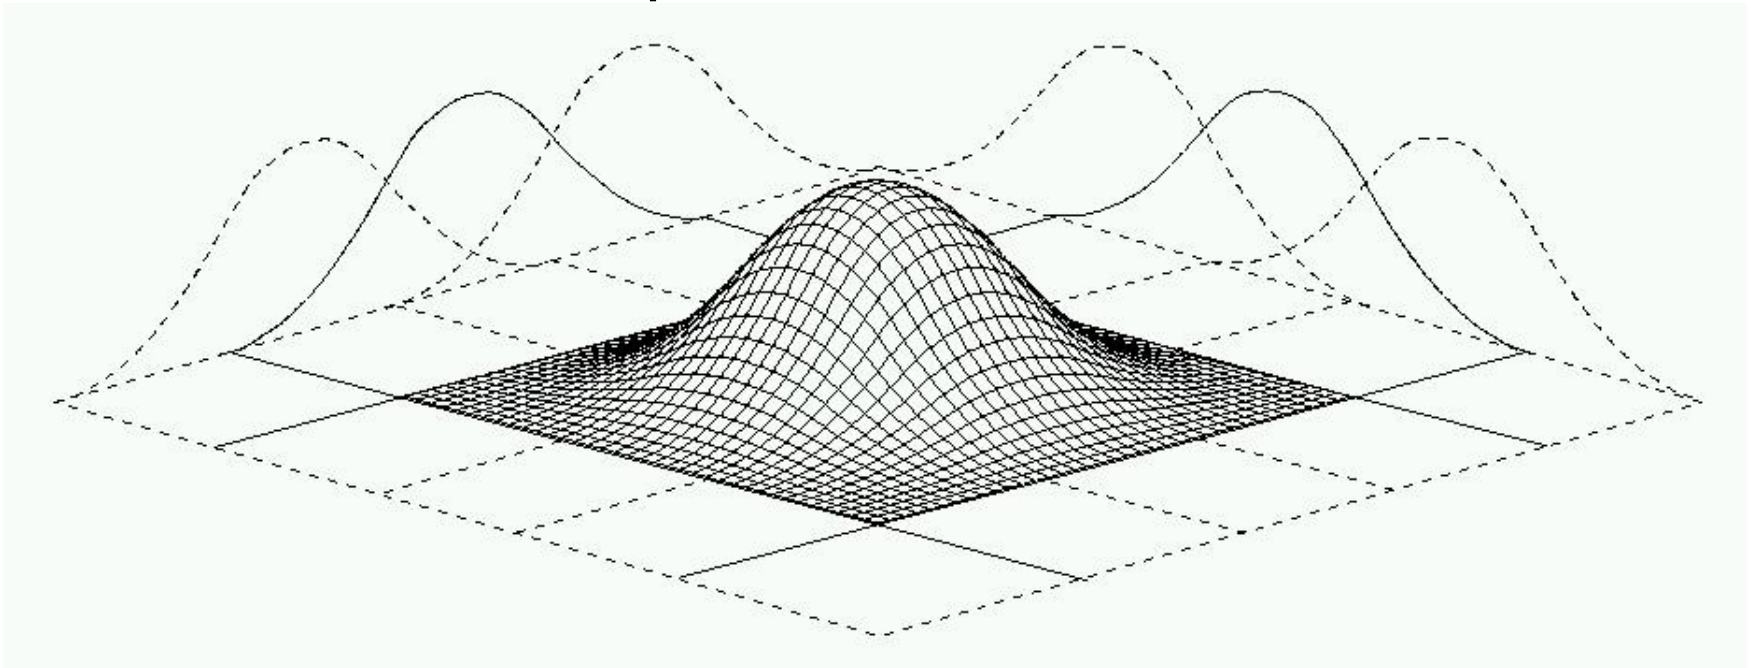
Das ist ein allgemeines B-Spline-Modell, das die Hyperfläche *NUBS* (*nonuniform B-spline*) darstellt.

Architektur des B-Spline ANFIS

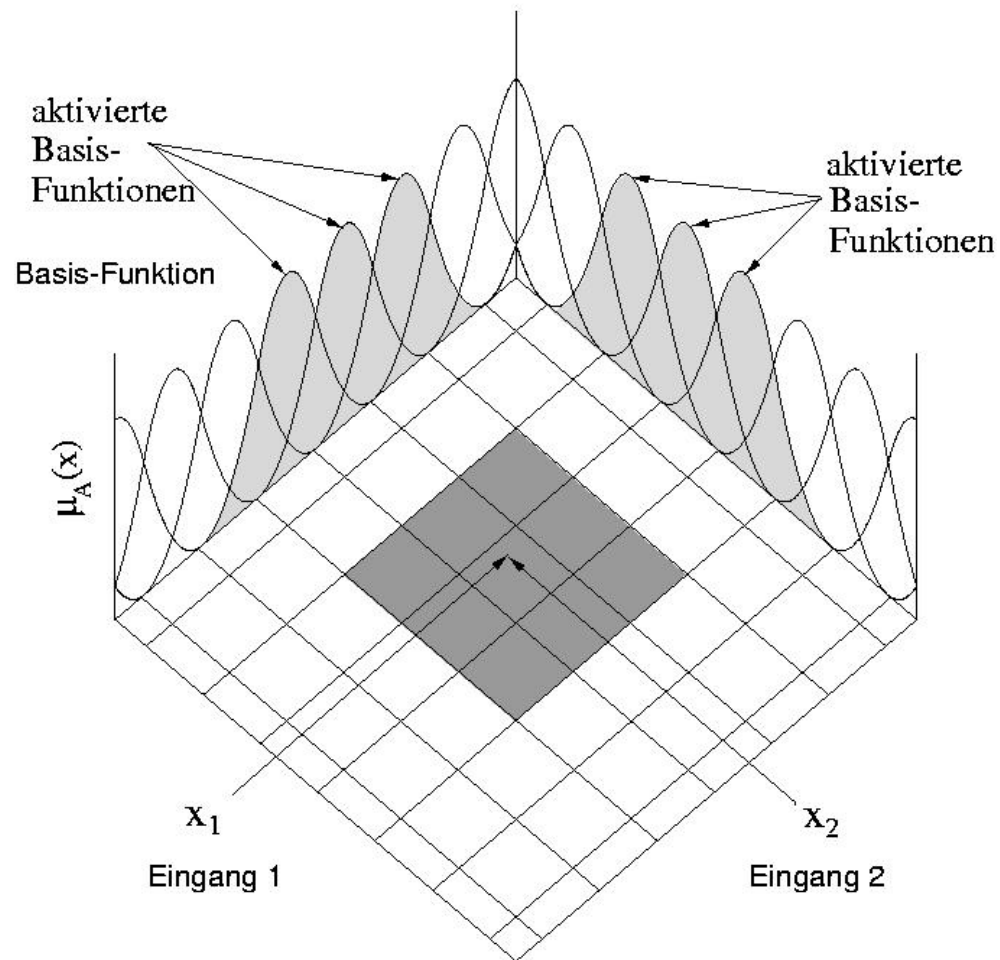


ZF-Formulierung - Tensorprodukt

Tensor-Produkt 2D-Splines:




Die Aktivierung der ZF über den Eingang




B-Spline ANFIS: ein Beispiel

Ein Beispiel mit zwei Eingangsvariablen (x und y) und einem Ausgang z . Die Parameter der DANN-Teile sind Z_1, Z_2, Z_3, Z_4 .

Die linguistischen Terme der Eingänge (WENN-Teile):



Die Parameter der DANN-Teile:




Ein Beispiel-Regelbasis

Die Beispiel-Regelbasis besteht aus vier Regeln:

Regel


- 1) IF x is X_1 and y is Y_1 THEN z is Z_1
- 2) IF x is X_1 and y is Y_2 THEN z is Z_2
- 3) IF x is X_2 and y is Y_1 THEN z is Z_3
- 4) IF x is X_2 and y is Y_2 THEN z is Z_4

Illustrierung der Fuzzy-Inferenz




IF (x is X_1) and (y is Y_1)

THEN z is Z_1




IF (x is X_1) and (y is Y_2)

THEN z is Z_2








IF (x is X_2) and (y is Y_1)

THEN z is Z_3



IF (x is X_2) and (y is Y_2)

THEN z is Z_4



Algorithm zum überwachten Lernen - I

Angenommen sei $\{(\mathbf{X}, y_d)\}$ eine Menge von Trainingsdaten, wobei

- $\mathbf{X} = (x_1, x_2, \dots, x_n)$: der Vektor der Eingangsdaten,
- y_d : der gewünschte Ausgang für \mathbf{X} .

Der LSE ist:

$$E = \frac{1}{2}(y_r - y_d)^2, \quad (2)$$

wobei y_r der aktuelle reale Ausgangswert während des Trainings ist.

Die zu findenden Parameter sind Y_{i_1, i_2, \dots, i_n} , die den Fehler in (2) minimiert, d.h.

$$E = \frac{1}{2}(y_r - y_d)^2 \equiv \text{MIN.} \quad (3)$$

Algorithm zum überwachten Lernen - II

Jeder Controlpunkt Y_{i_1, \dots, i_n} kann über das folgende Gradientenabstiegsverfahren verbessert werden:

$$\Delta Y_{i_1, \dots, i_n} = -\epsilon \frac{\partial E}{\partial Y_{i_1, \dots, i_n}} \quad (4)$$

$$= \epsilon (y_r - y_d) \prod_{j=1}^n N_{i_j, k_j}^j(x_j) \quad (5)$$

wobei $0 < \epsilon \leq 1$.

Das Gradientenabstiegsverfahren gewährleistet, dass der Lernalgorithmus zum globalen Minimum der LSE-Funktion konvergiert, weil die 2. partielle Ableitung bezüglich zu Y_{i_1, i_2, \dots, i_n} konstant ist:

$$\frac{\partial^2 E}{\partial^2 Y_{i_1, \dots, i_n}} = \left(\prod_{j=1}^n N_{i_j, k_j}^j(x_j) \right)^2 \geq 0. \quad (6)$$

Dies bedeutet dass die LSE-Funktion (2) konvex im Raum Y_{i_1, i_2, \dots, i_n} ist und deshalb nur einen (globalen) Minimum besitzt.

Funktionsapproximation - Demonstrationen

$\sin(x^2)$ Stop 1d-demo

$\sin(x^2y)$ Stop 2d-demo