


## Wiederholung

## a) Bestapproximation in PNR

$$\|u - f\| \leq \|v - f\|, u \in U \subset V, \forall v \in U$$

$$\Leftrightarrow (u - f, v) = 0$$

$$\Leftrightarrow u - f \perp U$$



$u := Pf$ ,  $u$  ist die Orthogonalprojektion von  $f$  auf  $U$

Berechnung über Basisdarstellung  $U = \text{span}\{\varphi_1, \dots, \varphi_n\}$

$$\langle u, v \rangle = \langle f, v \rangle \quad \forall v \in U$$

$$\Leftrightarrow Au = b \quad \text{mit} \quad u = \sum_{i=1}^n u_i \varphi_i, \quad A_{ij} = (\varphi_j, \varphi_i)$$

$$b_i = (f, \varphi_i)$$

## b) Approximation stetiger Funktionen

$$V = C([a, b]), \quad U = \mathcal{P}_n$$

$$\|p - f\| \leq \|q - f\| \quad \forall q \in \mathcal{P}_n$$

$$\left. \begin{array}{l} f(x) = x^{n+1} \\ a = -1, b = 1 \\ \|\cdot\| = \|\cdot\|_{\infty} \end{array} \right\} p^* = x^{n+1} - \frac{1}{2^n} T_{n+1}$$

$$\bullet \quad a = 0, b = 1, \|\cdot\| = \|\cdot\|_2$$

Basisdarstellung von  $U$  - Monome  $\varphi_i(x) = x^i$   
 $\Rightarrow A$  ist Hilbertmatrix

- Legendre-Polynome (OGB)  
 ungeeignet für komplexe Geometrien ( $d \geq 2$ )


## 2.14 Lineare finite Elemente

$$\text{Gitter } a = x_0 < x_1 < \dots < x_n = b$$

$$S_n = \left\{ \varphi \in C([x_0, x_n]) : \varphi|_{[x_i, x_{i+1}]} \text{ linear } \forall i = 0, \dots, n-1 \right\}$$

Basis von  $S_n$ : Knotenbasis  $\varphi_i(x_k) = \delta_{ik} = \begin{cases} 1, & i = k \\ 0, & \text{sonst} \end{cases}$   
 bestimmt  $\varphi_i$  eindeutig

$$\Rightarrow \varphi_i(x) = \begin{cases} 1 + \frac{1}{h_i}(x-x_i) & , x \in [x_{i-1}, x_i], i=1, \dots, n \\ 1 - \frac{1}{h_{i+1}}(x-x_i) & , x \in [x_i, x_{i+1}], i=0, \dots, n-1 \\ 0 & , \text{sonst} \end{cases}$$



$$\text{mit } h_i = x_i - x_{i-1}$$

$$\|\cdot\| = \|\cdot\|_2 = \int_a^b u(x)v(x)dx$$

Eigenschaften:

$$- u \in S_n : u(x) = \sum_{i=0}^n u_i \varphi_i(x) \quad , u_i = u(x_i)$$

$$- \text{lokaler Träger} \Rightarrow (\varphi_i, \varphi_j) = 0 \quad \forall |i-j| \geq 2$$

$$\Rightarrow (\varphi_i, \varphi_j) \neq 0 \quad \text{nur für } |i-j| \leq 1$$

$\Rightarrow$  Gramsche Matrix  $M$  ist tridiagonal

$$M \underline{u} = \underline{b}$$

$$M = \begin{pmatrix} 2 & \lambda_0 & 0 & & \\ \mu_1 & 2 & \lambda_1 & & \\ & \mu_2 & 2 & \lambda_2 & \\ & & \mu_n & 2 & \\ 0 & & & \mu_n & 2 \end{pmatrix} \quad \mu_i = \frac{h_i}{h_i + h_{i+1}} \quad \lambda_i = \frac{h_{i+1}}{h_i + h_{i+1}}$$

$$M_{ij} = (\varphi_i, \varphi_j) \cdot \frac{6}{h_i + h_{i+1}} \quad , \quad b_i = (f, \varphi_i) \cdot \frac{6}{h_i + h_{i+1}}$$

$\uparrow$   
Zeilenskalierung für  
bessere Darstellbarkeit

$$\text{Satz: } \kappa_\infty(M) = \|M\|_\infty \cdot \|M^{-1}\|_\infty \leq 3$$

$$\text{Beweis: } |\mu_i| + |\lambda_i| = \mu_i + \lambda_i = 1 \quad \forall i$$

$$\|M\|_\infty = \max_{i=0, \dots, n} \sum_{j=0}^n |m_{ij}| = \max_i (2 + \mu_i + \lambda_i) = 3$$

$M^{-1}$  ist unbekannt, daher wähle  $z \in \mathbb{R}^{n+1}$  beliebig, aber fest

$$(Mz)_i = \mu_i \cdot z_{i-1} + 2z_i + \lambda_i z_{i+1} \quad (\text{mit } \mu_0 = 0, \lambda_n = 0)$$

$$\Rightarrow 2|z_i| \leq \max_{j=0, \dots, n} |(Mz)_j| + \underbrace{(\mu_i + \lambda_i)}_{=1} \cdot \max_{j=0, \dots, n} |z_j| \quad \forall i$$

$$\Leftrightarrow |z_i| \leq \frac{1}{2} \|Mz\|_\infty + \frac{1}{2} \|z\|_\infty \quad \forall i$$

$$\Rightarrow \|z\|_\infty \leq \frac{1}{2} \|Mz\|_\infty + \frac{1}{2} \|z\|_\infty \Rightarrow \|z\|_\infty \leq \|Mz\|_\infty$$

$$y = M \cdot z$$

$$\Rightarrow \|M^{-1}y\|_{\infty} \leq \|y\|_{\infty}$$

$$\Rightarrow \|M^{-1}\|_{\infty} = \max_{\substack{y \in \mathbb{R}^{n+1} \\ y \neq 0}} \frac{\|M^{-1}y\|_{\infty}}{\|y\|_{\infty}} \leq 1$$

D.h. das lin. Gleichungssystem ist gut konditioniert (unabhängig von  $n$ !).

### III. 3 Methode der kleinsten Quadrate (Ausgleichsprobleme)

#### 2.15 Parameteridentifikation

- $m$  Messpunkte  $(t_i, b_i)$ ,  $i=1, \dots, m$

- Modell  $b(t) = \varphi(t, x_1, \dots, x_n)$

- Messfehler  $b_i = \varphi(t_i, x_1, \dots, x_n) + r_i$

↑  
unbekannt & zufällig

- unabhängig

- identisch verteilt & normalverteilt

$\Rightarrow$  Maximum-Likelihood-Schätzung:

Bestimme  $x_1, \dots, x_n$  so, dass  $\sum_{i=1}^m r_i^2 = \min!$

#### 2.16 Lineare Modelle

$$\varphi(t, x_1, \dots, x_n) = a_1(t)x_1 + a_2(t)x_2 + \dots + a_n(t)x_n$$

$$\sum_{i=1}^m r_i^2 = \min! \Leftrightarrow \sum_{i=1}^m [b_i - \varphi(t_i, x_1, \dots, x_n)]^2 = \min!$$

$$\Leftrightarrow \|b - Ax\|_2^2 = \min! \Leftrightarrow Ax \approx b \text{ mit } A = \begin{pmatrix} a_1(t_1) & \dots & a_n(t_1) \\ \vdots & & \vdots \\ a_1(t_m) & \dots & a_n(t_m) \end{pmatrix}$$

In der Praxis ist häufig  $m \gg n$ .

Modellmatrix

Definition: Lineares Ausgleichsproblem

Gegeben  $b \in \mathbb{R}^m$ ,  $A \in \mathbb{R}^{m \times n}$ ,  $m \geq n$ .

Gesucht  $x \in \mathbb{R}^n$ , sodass  $\|Ax - b\|_2^2 = \min!$

$$\text{bzw. } \|Ax - b\|_2 \leq \|Av - b\|_2 \quad \forall v \in \mathbb{R}^n$$

## Bemerkungen:

a) andere Normen:  $l_1$ -Ausgleich  $\|Ax-b\|_1 = \min$  } nicht  
 $l_\infty$ -Ausgleich  $\|Ax-b\|_\infty = \min$  } differenzierbar!

b) Bestapproximation:

$U = \mathcal{R}(A)$ , gesucht  $u \in U$ , sodass  $\|u-b\|_2 \leq \|v-b\|_2 \quad \forall v \in U$

c) Hat  $A$  vollen Spaltenrang, dann existiert ein eindeutiges  $x$  mit  
 $Ax = u$ .

2.17 Regressionsgerade (siehe Skript)

2.18 Normalengleichung "revisited"

Satz: Sei  $m \geq n$ . Dann ist  $x \in \mathbb{R}^n$  genau dann Lösung des  
Ausgleichsproblems, wenn  $x$  der Normalengleichung  
 $A^T A x = A^T b$  genügt.

Ist  $A$  injektiv (voller Spaltenrang), so ist  $x$  eindeutig  
bestimmt.

Beweis:  $x$  löst das Ausgleichsproblem.

Normalengleichung 2.8  
mit  $u := Ax$   
 $\tilde{b} := b$

$$\Leftrightarrow (Ax - b, v) = 0 \quad \forall v \in \mathcal{R}(A)$$

$$\Leftrightarrow (Ax, v) = (b, v) \quad \forall v \in \mathcal{R}(A)$$

$$\Leftrightarrow (Ax, Ay) = (b, Ay) \quad \forall y \in \mathbb{R}^n$$

$$\Leftrightarrow (A^T A x, y) = (A^T b, y) \quad \forall y \in \mathbb{R}^n$$

$$\Leftrightarrow A^T A x = A^T b$$

Falls  $A$  injektiv ist, dann ist  $A^T A$  regulär und

$x = (A^T A)^{-1} A^T b$  ist eindeutig.  $\square$

2.19 Konditionsanalyse

Möglicher Algorithmus:  $(b, A) \xrightarrow{\text{invert}} (A^T A, A^T b) \xrightarrow{\text{(*) Löse}} A^T A x = A^T b$   
 $\uparrow$   
LR-Zerlegung  
oder Cholesky

Kondition von (\*) (für festes  $b$ ):

$$K_2(A^T A) = \|A^T A\|_2 \| (A^T A)^{-1} \|_2 = \underset{\substack{\uparrow \\ \text{falls } n=m}}{[K_2(A)]^2}$$

Beispiel:

$$A = \begin{pmatrix} 1 & 1 \\ \varepsilon & 0 \\ 0 & \varepsilon \end{pmatrix} \Rightarrow A^T A = \begin{pmatrix} 1+\varepsilon^2 & 1 \\ 1 & 1+\varepsilon^2 \end{pmatrix}$$

für  $\varepsilon < \sqrt{\varepsilon_{\text{machine}}}$  ist  $A^T A$  singular  
(Normalgleichung nicht mehr lösbar)

