

# NuMa 2/1

①

- ▶ **Kondition:** Empfindlichkeit für Störungen des **Problems**
- ▶ **Stabilität:** Empfindlichkeit für Störungen des **Lösungsverfahrens**
- ▶ **Effizienz:** numerischer **Aufwand**, um gewünschte Genauigkeit zu erzielen

## Norm:

- ▶ **Positivität**  $\|v\| \geq 0; \|v\| = 0 \Leftrightarrow v = 0$
- ▶ **Homogenität**  $\|\alpha v\| = |\alpha| \cdot \|v\| \quad \forall \alpha \in \mathbb{R}$
- ▶ **Dreiecksungleichung:**  $\|v+w\| \leq \|v\| + \|w\|$

## Vektornormen

- ▶ **1-Norm:**  $\|x\|_1 = \sum_{i=1}^n |x_i|$
- ▶  **$\infty$ -Norm:**  $\|x\|_\infty = \max_{i=1, \dots, n} |x_i|$
- ▶ **2-Norm:**  $\|x\|_2 = \sqrt{\sum_{i=1}^n x_i^2}$  (Euklidische Norm)

## Matrixnormen

- ▶ **1-Norm:**  $\|A\|_1 = \max_{j=1, \dots, n} \sum_{i=1}^n |a_{ij}|$  (Spalten)
- ▶  **$\infty$ -Norm:**  $\|A\|_\infty = \max_{i=1, \dots, n} \sum_{j=1}^n |a_{ij}|$  (Zeilen)
- ▶ **2-Norm:**  $\|A\|_2 = \sqrt{\lambda_{\max}(A^T \cdot A)}$  (Eigenwerte)

## Taylor-Entwicklung (um $x$ !)

$$f(\tilde{x}) = f(x) + f'(x)(\tilde{x}-x) + \frac{f''(x)}{2}(\tilde{x}-x)^2 + \dots + \frac{f^{(k)}(\xi)}{k!}(\tilde{x}-x)^k$$

$\kappa_2(A) = \frac{\sigma_{\max}}{\sigma_{\min}}$ , mit  $\sigma_i = \sqrt{\lambda_i}$  ?  $\kappa_2(A) = \frac{(\max)}{(\min)}$

Restterm!

# Taylor-Entwicklung für rektwertige Fkts

$$f(\tilde{x}) = f(x) + \sum_{j=1}^n \frac{\partial f(x)}{\partial x_j} (\tilde{x}_j - x_j) + \sum_{i,j=1}^n \frac{1}{2} \frac{\partial^2 f(x)}{\partial x_i \partial x_j} (\tilde{x}_i - x_i) (\tilde{x}_j - x_j) + \mathcal{O}(\|\tilde{x} - x\|_2^3)$$

mit  $\nabla f(x) := \left( \frac{\partial f(x)}{\partial x_1}, \dots, \frac{\partial f(x)}{\partial x_n} \right)^T$   
 $f''(x) := \left( \frac{\partial^2 f(x)}{\partial x_i \partial x_j} \right)_{i,j=1}^n$

$$f(\tilde{x}) = f(x) + (\nabla f(x))^T (\tilde{x} - x) + \frac{1}{2} (\tilde{x} - x)^T f''(x) (\tilde{x} - x) + \mathcal{O}(\|\tilde{x} - x\|_2^3)$$

## relative Kondition:

$$\frac{\delta_y}{\delta_x} = \frac{\text{Ausgabefehler rel.}}{\text{Eingabefehler rel.}}$$

## absolute Kondition

$$\frac{\| \Delta y \|_y}{\| \Delta x \|_x} = \frac{\| \text{Ausgabefehler abs.} \|_y}{\| \text{Eingabefehler abs.} \|_x}$$

Normen im jeweiligen Raum

$f: \mathbb{R} \rightarrow \mathbb{R}$

$$\left| \frac{f(\tilde{x}) - f(x)}{f(x)} \right| \leq \kappa_{\text{rel}}(x) \left| \frac{\tilde{x} - x}{x} \right| \quad \text{mit} \quad \kappa_{\text{rel}}(x) = \left| f'(x) \frac{x}{f(x)} \right|$$

$f: \mathbb{R}^n \rightarrow \mathbb{R}$

$$\frac{|f(\tilde{x}, \tilde{y}) - f(x, y)|}{|f(x, y)|} \leq \kappa_{\text{rel}}(x, y) \cdot \left( \left| \frac{\tilde{x} - x}{x} \right| + \left| \frac{\tilde{y} - y}{y} \right| \right) \quad \text{entsprechend für höhere Dimensionen}$$

$f: \mathbb{R}^n \rightarrow \mathbb{R}^m$

$$\frac{\|f(\tilde{x}) - f(x)\|}{\|f(x)\|} \leq \kappa(A) \frac{\|\tilde{x} - x\|}{\|x\|}$$

mit

$$\kappa(A) = \|A\| \cdot \|A^{-1}\|$$

Multiplication/Division: gut konditioniert,  $\kappa_{\text{rel}} \leq 1$

Addition:  $\left\{ \begin{array}{l} \text{gut konditioniert, wenn gleiches } \forall z \\ \text{sehr schlecht konditioniert, wenn } x_1 \approx -x_2 \end{array} \right.$

$\kappa_{\text{rel}} \gg 1$ , wenn  $|x \pm y| \ll \max\{|x|, |y|\}$

# Numa 2/R

Floats:

$$x = \pm 0, d_1 d_2 \dots d_m \cdot b^e$$

$$x = \pm \left( \sum_{j=1}^m b^j \cdot d_j \right) \cdot b^e$$

Exponent  $e \in [\underline{e}, \overline{e}]$

M-Länge    Mantisse +    Basis

→ Maschinenzahlen  $M(b, m, r, R)$

•  $e$  beschränkt    Bildbereich

•  $f$  beschränkt    Genauigkeit

Maschinengenauigkeit  $\epsilon_{ps} := \frac{b^{1-m}}{2}$

Rundungsfehler  $\epsilon: |\epsilon| \leq \epsilon_{ps}, \quad fl(x) = x(1 + \epsilon)$

Pseudorithmetik

→ Reihenfolge wichtig!

$$x \odot y = fl(x \cdot y) = (x \cdot y)(1 + \epsilon)$$

$$\odot \in \{+, -, \cdot, : \}$$

$$x, y \in M$$

+ -  
Auslöschung

Stabilität:

Algorithmus stabil/gutartig, wenn „dessen Fehler in Größenordnung des Fehlers durch Kondition“

rückwärts stabil: exakte Lsg eines nahezu richtigen Problems

$$\frac{\| \tilde{f}(x) - f(x) \|}{\| f(x) \|} = \mathcal{O}(\kappa(x) \epsilon_{ps})$$

$$\kappa_{rel} = \max \left\{ \left| \frac{\partial f(x,y)}{\partial x} \cdot \frac{x}{f(x,y)} \right|, \left| \frac{\partial f(x,y)}{\partial y} \cdot \frac{y}{f(x,y)} \right| \right\}$$

$$\|Ay\| \leq \kappa_A \|ay\|$$

$$\|f\|_1 = \int_a^b |f(x)| dx$$

Störungsnetz (in  $\infty$  Norm)

$$\|f\|_2 = \sqrt{\int_a^b |f(x)|^2}$$

$$\delta_x \leq \frac{\kappa(A)}{1 - \kappa(A) \cdot \delta_A} (\delta_B + \delta_A) \quad \text{für } \kappa(A) \cdot \delta_A < 1$$

$$\|f\|_{\infty} = \sup_{x \in [a,b]} |f(x)|$$

$$\delta_A = \frac{\|AA\|}{\|A\|}$$

A regulär / nichtsingulär  $\Leftrightarrow \det A \neq 0$

$\Rightarrow A(x + \Delta x) = b + \Delta b$

$\Rightarrow \frac{\| \Delta x \|}{\| x \|} \leq \kappa(A) \frac{\| \Delta b \|}{\| b \|}$

$\Rightarrow (A + \Delta A)(x + \Delta x) = b + \Delta b$

u.  $\kappa(A) \frac{\| \Delta A \|}{\| A \|} < 1$

$\Rightarrow \frac{\| \Delta x \|}{\| x \|} \leq \frac{\kappa(A)}{1 - \kappa(A) \frac{\| \Delta A \|}{\| A \|}} \left( \frac{\| \Delta A \|}{\| A \|} + \frac{\| \Delta b \|}{\| b \|} \right)$

Residuum  $\tilde{r} := b - A\tilde{x}$  wo  $\tilde{x}$  Näherungslösung

$\kappa(A)$  groß  $\rightarrow$  Residuum schlechtes Maß für Fehler

Zeilenstufenform  $\rightarrow$  minimales  $\kappa_{\infty}(D_2 A)$   $\| D_2 A \|_{\infty} = 1$

$Ax = b \Rightarrow \underbrace{D_2 A} x = \underbrace{D_2 b}$   
 $A_{neu} x = b_{neu}$

Wähle Diagonalmatrix  $D_2$  so, dass  $\kappa(A_{neu})$  gut

$d_i = \left( \sum_{j=1}^n |a_{ij}| \right)^{-1}$

$D_2 A$  zeilenweise äquilibriert  $\rightarrow$  Alle Betragssummen gleich 1

Berechnung

- ▷ Skalarprodukt  $x^T y$
- ▷ Cholesky-Zerlegung
- ▷ Dyadisches Produkt  $x y^T$
- ▷ M-V-Produkt  $Ax$
- ▷ Householder-Trafo
- ▷ M-M-Produkt  $AB$
- ▷ Gauß mit Pivotisierung
- ▷ Rückwärtssetzen

Aufwand

- $2n$
- $\frac{1}{3}n^3$
- $n^2$
- $2n^2$
- $\frac{4}{3}n^3$  /  $2nn^2$
- $2n^3$
- $\frac{2}{3}n^3$
- $n^2$

$\nabla \cdot \nabla = \nabla$   
 $(\nabla)^{-1} = \nabla$

$\det(\nabla) = \prod a_{ii}$   
 $\lambda(\nabla) = a_{ii}$

# Matrix-Zerlegungen

► LR:

$$A = RL$$

$$A = \begin{pmatrix} * & * \\ * & * \end{pmatrix} \cdot \begin{pmatrix} * & * \\ * & * \end{pmatrix}$$

► Cholesky:

$$A = LDL^T$$

$$D = \begin{pmatrix} * & & \\ & * & \\ & & * \end{pmatrix}$$

► QR:

$$A = QR$$

$Q$  orthogonal

Gauss ohne Pivotisierung  $(A|b) \rightarrow (R|c) \rightarrow$  nicht stabil

$\rightarrow$  LR-Zerlegung als Nebenprodukt

! wenn Pivotelemente ungleich Null

Gauss mit Pivotisierung

$\Rightarrow$  stabil

$\rightarrow$  Zeilen vertauschen (Multiplikation mit  $P$ ),

damit das betragsmäßig größte Element

Pivot ist  $\rightarrow LR = PDA$  (vorher skalieren)

$$LR = PA$$

Zeilen skalierung / -äquilibrierung  $\rightarrow$  Kondition  $\uparrow$

Pivotisierung  $\rightarrow$  Stabilität  $\uparrow$

$$Ax = b \Leftrightarrow PAx = Pb \Leftrightarrow LRx = Pb$$

$$\Rightarrow PA = LR$$

$$Ly^k = Pb^k$$

$$Rx^k = y^k$$

1. LGS

2. viele LGS ( $y^k, b^k$ )

$$\Rightarrow LRx^i = Pe^i$$

$i$ te Spalte  $\sim$  Einheitsvektor  
von  $A^{-1}$

3. Inverse

$$\Rightarrow \det A = (-1)^{\# \text{Zeilenwaps}} \prod_{j=1}^n r_{jj}$$

4. Determinante

# Numa 3/2

symmetrisch positiv definite (s.p.d.) Matrix:

$$A^T = A$$

1.

$$x^T A x > 0$$

A s.p.d.

$\Rightarrow$  A invertierbar,  $A^{-1}$  s.p.d.

$$\Rightarrow \lambda_i(A) \in \mathbb{R}^+$$

$\Rightarrow A_{ii} \in \mathbb{R}^+$ , größter Eintrag <sup>liegt</sup> auf Diagonale

$\Rightarrow$  Gauß ohne Pivot: alle Pivot  $\in \mathbb{R}^+$

Cholesky-Zerlegung

A s.p.d.

$\Rightarrow$  stabil

$$A = LDL^T$$

$$A = \begin{pmatrix} \blacktriangle \\ \vdots \\ \blacktriangledown \end{pmatrix} \cdot \begin{pmatrix} \cdot & & \\ & \cdot & \\ & & \cdot \end{pmatrix} \cdot \begin{pmatrix} \blacktriangle \\ \vdots \\ \blacktriangledown \end{pmatrix}$$

$$d_{ii} > 0$$

$$L = \begin{pmatrix} 1 & 0 & 0 \\ l_{21} & 1 & 0 \\ l_{31} & l_{32} & 1 \end{pmatrix}$$

$$D = \begin{pmatrix} d_{11} & 0 & 0 \\ 0 & d_{22} & 0 \\ 0 & 0 & d_{33} \end{pmatrix}$$

$$\Rightarrow \begin{cases} d_{kk} = a_{kk} - \sum_{j=1}^{k-1} l_{kj}^2 \cdot d_{jj} \\ l_{ik} = \left( a_{ik} - \sum_{j=1}^{k-1} l_{ij} d_{jj} \cdot l_{kj} \right) \cdot \frac{1}{d_{kk}} \end{cases}$$

$$\triangleright LDL^T = LR$$

$$\triangleright Ax = b \Rightarrow \underbrace{LDL^T}_y x = b$$

$$Ly = b, L^T x = D^{-1} y$$

orthogonale Matrix:

$\Rightarrow$  Spalten sind Orthonormalbasis

$$Q^T \cdot Q = \mathbb{1}$$

$$\Rightarrow Q^{-1} = Q^T$$

$\Rightarrow Q^T$  orthogonal

$$\Rightarrow \|Q \cdot x\|_2 = \|x\|_2 \quad \forall x \in \mathbb{R}^n$$

$$\Rightarrow \mathcal{L}_2(Q) = 1$$

QR-Zerlegung

$$A = QR$$

$$A = (\text{orth}) \cdot \begin{pmatrix} \blacktriangledown \\ \vdots \\ \blacktriangledown \end{pmatrix}$$

$$\Rightarrow \|A\|_2 = \|QR\|_2 = \|A\|_2 \quad \forall A$$

$\Rightarrow Q \cdot \tilde{Q}$  orthogonal für  $\tilde{Q}$  orthog.

bzw.  $\tilde{Q}A = \tilde{R}$

Householder-Transformation  $\Rightarrow$  sehr stabil

$$A = QR = H_1 H_2 H_3 \cdot R$$

$$\dots H_3 H_2 H_1 A = R$$

$$A = \begin{pmatrix} x & x & x \\ x & x & x \\ x & x & x \end{pmatrix} \quad H_1 A = \begin{pmatrix} x & x & x \\ 0 & x & x \\ 0 & 0 & x \end{pmatrix} \quad H_2 H_1 A = \begin{pmatrix} x & x & x \\ 0 & x & x \\ 0 & 0 & x \end{pmatrix}$$

$H_i$ :  $i$ -te Householder-Matrix, löscht Einträge in  
neuem Vektor ab  $i$ -tem Eintrag

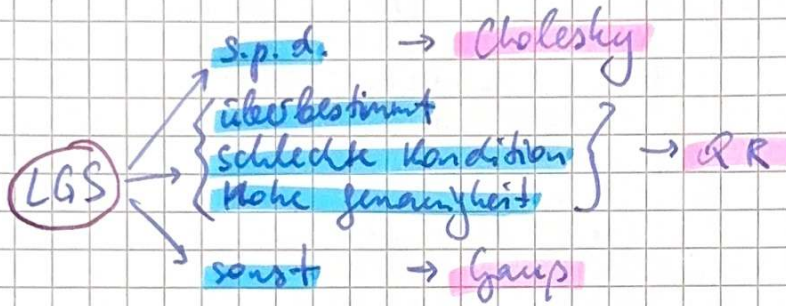
$$H = I - \frac{2}{v^T v} v v^T$$

Skalar Matrix

$v = a - \|a\|_2 \cdot e_i$  für  $i=1$

$v = \tilde{a} - \|\tilde{a}\|_2 \cdot e_i$  für  $i \neq 1$

$\tilde{a} = \begin{pmatrix} 0 \\ \vdots \\ x \end{pmatrix}$  (Einträge bis  $i$  gelöscht)



$$A_i := A - \frac{2}{v^T v} \cdot v \cdot v^T \cdot A$$

$$b_i := b - \frac{2}{v^T v} \cdot v \cdot v^T \cdot b$$

$$\min_{x \in \mathbb{R}^2} \|Ax - b\|_2 = \min_{x \in \mathbb{R}^2} \|A_i x - b_i\|_2 = \min_{x \in \mathbb{R}^2} \|R x - \hat{b}\|_2$$

mit  $R = \begin{pmatrix} \hat{r} \\ 0 \end{pmatrix} \quad \hat{b} = \begin{pmatrix} \hat{b}_1 \\ \hat{b}_2 \end{pmatrix}$

# Num 4

## Lineare Ausgleichsrechnung

$A \in \mathbb{R}^{m \times n}$ ,  $b \in \mathbb{R}^m$ ,  $m > n$

bestimme bestmögliche  $x \in \mathbb{R}^n$

$x^* = \arg \min_{x \in \mathbb{R}^n} \|Ax - b\|_2$

Spalten von  $A$  orthogonal  $\Leftrightarrow \alpha$  gut

Spalten von  $A$  l.o.  $\Leftrightarrow \alpha$  schlecht

Modell:  $y(t; x_1, x_2, \dots, x_n)$   $x_i$ : Parameter  $\rightarrow$  linear in Parametern  
Daten:  $b_i \approx y(t_i; x_1, x_2, \dots, x_n)$   $b_i$ : Messwerte

## Gauss-Fehlerquadratkriterium:

bestimme  $x_i$ , sodass minimiert

$\sum_{i=1}^m [y(t_i; x_1, x_2, \dots, x_n) - b_i]^2 \rightarrow$  ein Maß für Fehler

$\Rightarrow \min_x \sum_{i=1}^m (a_{i1} \cdot x_1 + a_{i2} \cdot x_2 + \dots + a_{in} x_n - b_i)^2$

$\Rightarrow \min_{x \in \mathbb{R}^n} \|Ax - b\|_2^2$

gewöhnliches LAP  $\rightarrow$  voller Spaltenrang  $\rightarrow$   $\text{Rang}(A) = n$   $\rightarrow$  eindeutige Lsg

allgemeines LAP  $\rightarrow$   $\text{Rang}(A) \neq n$   $\rightarrow$  Lsg mit minimaler euklidischer Norm

## Normalgleichungen

$A^T A x = A^T b$

Systemmatrix  $A^T A$  s.p.d.

$\Rightarrow x^* =$  Lsg davon = Lsg des LAP

$\frac{\|\tilde{x} - x^*\|_2}{\|x^*\|_2} \leq \frac{\kappa_2(A)}{\cos(\alpha)} \frac{\|\tilde{b} - b\|_2}{\|b\|_2}$

$\propto$  bzgl.  $\tilde{b}$

$\frac{\|\tilde{x} - x^*\|_2}{\|x^*\|_2} \leq (\kappa_2(A) + \kappa_2(A)^2 \tan(\alpha)) \frac{\|\tilde{A} - A\|_2}{\|A\|_2}$

$\propto$  bzgl.  $\tilde{A}$

## LAP lösen mit Normalenflächenungen

▷ Berechne  $A^T A$ ,  $A^T b$

▷ Berechne Cholesky von  $A^T A = LDL^T$

▷ Löse  $Ly = A^T b$ ,  $L^T x = D^{-1} y$

$$A^T A x = A^T b$$

$$LDL^T x = A^T b$$

$$L^T x = D^{-1} y$$

!  $\rightarrow A^T A$  aufwendig, Gefahr der Instabilität

$\rightarrow$  Rundungsfehler bei Cholesky verstärkt

$$\kappa_2(A^T A) = \kappa_2(A)^2 \quad \text{Fehlerverstärkung}$$

## LAP lösen mit QR-Zerlegung

$$\begin{aligned} &U A x = b_{n_2} \\ &U Q^T A x = Q^T b_{n_2} \\ &R x = R^{-1} b_{n_2} \end{aligned}$$

▷ Berechne QR

$Q A = \begin{pmatrix} \tilde{R} \\ 0 \end{pmatrix}$ ,  $\tilde{R}$  quadratisch  $\tilde{R} \in \mathbb{R}^{n \times n}$

$Q b = \begin{pmatrix} b_1 \\ b_2 \end{pmatrix}$   $n$  Einträge  
 $\tilde{R} x = b_1$   $3$  restliche Einträge

$$A x = b$$

$$Q A x = Q b$$

$$\tilde{R} x = b_1$$

▷ Löse  $\tilde{R} x = b_1$

▷ Norm des Residuums:  $\|b_2\|_2$

!  $\rightarrow$  sehr stabil

$$\kappa_2(A) \quad \text{Fehlerverstärkung}$$

## Singularwertzerlegung (SVD)

$$\begin{aligned} A &= U E V^T \\ A &= U \tilde{Q} \tilde{R} \\ A &= Q R \end{aligned}$$

$$A = \begin{bmatrix} U \\ \cdot \\ \cdot \\ \cdot \end{bmatrix} \cdot \begin{bmatrix} \sigma_1 & & \\ & \sigma_r & \\ & & 0 \end{bmatrix} \cdot \begin{bmatrix} V^T \\ \cdot \\ \cdot \\ \cdot \end{bmatrix}$$

EVs von  $A A^T$

EVs von  $A^T A$

$U, V$  orthogonal

$$\sigma_i = \sqrt{\lambda_i(A^T A)}$$

(von groß nach klein sortiert)

Singularwerte

▷  $\text{rang}(A) = n$ :  $y = E^{-1} (U^T b)$ ,  $x^* = V y$

▷  $\text{rang}(A) < n$ :  $x^* = A^+ b$  mit  $A^+ = V \Sigma^+ U^T$  mit  $\Sigma^+ = \begin{pmatrix} \sigma_1^{-1} & & 0 \\ & \dots & \\ 0 & & \sigma_r^{-1} \\ & & & 0 \end{pmatrix}$

! hoher Rechenaufwand

$$\kappa_2(A) = \frac{\sigma_{\max}}{\sigma_{\min}}$$

# Numa 5

## Nichtlineare GS

geg.:  $f: \mathbb{R}^n \rightarrow \mathbb{R}^n$ , ges.:  $x^* \in \mathbb{R}^n$ , sodass  $f(x^*) = 0$   
(mehr Gleichungen als Unbekannte  $\rightarrow$  nichtlineares Randwertproblem)

$\rightarrow$  iterative Lösungsverfahren

$$\text{Störung: } |\tilde{x}^* - x^*| \approx \varepsilon^{1/m} \left| \frac{m!}{f^{(m)}(x^*)} \right|^{1/m}$$

$\rightarrow$  Probleme mit mehrfachen Nullstellen sehr schlecht konditioniert

## Fixpunktiteration

$M_x \in \mathbb{R}^{n \times n}$ , invertierbar in Umgebung von  $x^*$ . Dann

$$f(x^*) = 0 \Leftrightarrow M_{x^*} f(x^*) = 0$$

$$M_{x^*} f(x^*) = 0 \Leftrightarrow x^* = x^* - M_{x^*} \cdot f(x^*)$$

$x^*$  ist problem äquivalent zum Fixpunktproblem

$$x^* = \Phi(x^*), \text{ mit } \Phi(x) := x - M_x \cdot f(x)$$

wähle  $x_0$  in Umgebung von  $x^*$

$$x_{k+1} = \Phi(x_k)$$

$|\Phi'(x^*)| < 1$ : konvergiert

$|\Phi'(x^*)| > 1$ : divergiert

$\rightarrow$  wähle  $M_x$  bzw.  $\Phi$  geeignet

Lipschitz-stetig:

$$\exists L: \|f(x) - f(y)\| \leq L \|x - y\|$$

Selbstabb.:

$$\Phi: E \rightarrow E, \quad E \subset \mathbb{R}^n$$

Kontraktion:

$$\|\Phi(x) - \Phi(y)\| \leq L \|x - y\|, \quad L < 1$$

## Banachscher Fixpunktsatz

$$1 > L := \max_{x \in [a, b]} |\Phi'(x)|$$

J-Matrix für  $\Phi \in \mathbb{R}^n$

$\Phi$  Selbstabb. und Kontraktion

$\Rightarrow$  genau ein Fixpunkt  $x^*$

Fixpunktiteration konvergent für bel.  $x_0$

a-priori Abschätzung  $\|x_k - x^*\| \leq \frac{L^k}{1-L} \|x_1 - x_0\|$

a-posteriori Abschätzung  $\|x_k - x^*\| \leq \frac{L}{1-L} \|x_k - x_{k-1}\|$

max # Iterationen:

$$k \geq \log\left(\frac{\varepsilon(1-L)}{\|x_1 - x_0\|}\right) / \log(L)$$

Konvergenzordnung einer Folge  $(p)$

$$\|x_{k+1} - x^*\| \leq c \cdot \|x_k - x^*\|^p \quad \forall k \geq k_0, \quad 0 < c < 1 \text{ für } p=1$$

Konvergenzordnung eines iterativen Verfahrens

es gibt Umgebung  $U$  um  $x^*$ , sodass für alle  $x_0$  die erzeugte Folge Konv.-ordnung  $p$  hat

$$\Phi'(x^*) = 0$$

quadratische Konv.

$$0 \neq k \Phi'(x^*) k < 1$$

lineare Konv.

Skalare Folgen mit LS.17: a-posteriori Absch., große  $k$

$$p=1: x^* - x_k \approx \frac{A_k}{1-A_k} \cdot (x_k - x_{k-1}), \quad A_k = \frac{x_k - x_{k-1}}{x_{k-1} - x_{k-2}} \approx \text{const}$$

$$p>1: x^* - x_k \approx x_{k+1} - x_k$$

Vektorfolgen:

$$p>1: \|x_k - x^*\| \approx \|x_{k+1} - x_k\|, \quad \text{große } k$$

## Newton-Verfahren (skalare gl.)

▷  $\phi$  wählen, sodass möglichst schnell konv.

▷  $\phi(x) = x - M_x f(x)$  (hier  $M_x = f'(x)$ )

▷ wähle  $f(x)$  so, dass  $\phi'(x^*) = 0$

▷  $\phi(x^*) = 0 \Leftrightarrow f(x^*) = \frac{1}{f'(x^*)}$

▷  $\phi(x) := x - \frac{f(x)}{f'(x)}$

$$x_{k+1} = x_k - \frac{f(x_k)}{f'(x_k)}$$

▷ lokal quadratisch konvergent → braucht guten Startwert

## Schäbterverfahren

$$x_{k+1} = \frac{x_{k+1} \cdot f(x_k) - x_k \cdot f(x_{k+1})}{f(x_k) - f(x_{k+1})} = x_k - f(x_k) \frac{x_k - x_{k+1}}{f(x_k) - f(x_{k+1})}$$

⊕ keine  $f'(x)$ , Effizienter

⊖  $\rho \approx 1,6$  lokal, zwei Startwerte

## Newton-Iteration (für Systeme)

▷  $f = (f_1, \dots, f_n)^T: \mathbb{R}^n \rightarrow \mathbb{R}^n$ , suche  $x^* = (x_1^*, \dots, x_n^*)^T$  sodass  $|f(x^*)| = 0$

$x^k := (x_1^k, \dots, x_n^k)^T \in \mathbb{R}^n$

▷ ggf.:  $x^0$

▷ berechne  $f(x^k)$  u.  $f'(x^k)$

▷ löse LGS  $f'(x^k) \cdot s^k = -f(x^k)$  } LR-Zerlegung

▷ setze  $x^{k+1} = x^k + s^k$

▷ Vereinfachtes Newton-Verfahren:

$$f'(x^0) \cdot s^k = -f(x^k)$$

⊖ keine quadratische Konv., evtl.  $f'(x)$  neu berechnen nach 3-5 Schr.

▷ Annäherung der Jacobi-Matrix

$$\frac{\partial f_i(x)}{\partial x_j} = \frac{f_i(x + h \cdot e^j) - f_i(x)}{h}$$

$e^j = j$ ter Einheitsvektor  
?  $h$  passend wählen

▷ Homotopieverfahren

▷ gedämpftes Newton-Verfahren

▷ Wahl von  $x_0$  aus Hintergrundinfos

# Nulla 6

## Nichtlineares AP

Messungen  $b_1, b_2, \dots, b_m$  an Zeitpunkten  $t_1, t_2, \dots, t_m$

Parameter  $x_1, x_2, \dots, x_n$

$$F_i(x) := y(t_i; x) - b_i$$

$$F: \mathbb{R}^n \rightarrow \mathbb{R}^m$$

→ Bestimme  $x^*$ , sodass  $\|F(x^*)\|_2 = \min_{x \in \mathbb{R}^n} \|F(x)\|_2$

bzw.  $\varphi(x^*) = \min_{x \in \mathbb{R}^n} \varphi(x)$

mit  $\varphi(x) := \frac{1}{2} \|F(x)\|_2^2 = \frac{1}{2} F(x)^T F(x)$

↳ lokales Min, wenn

•  $\nabla \varphi(x^*) = 0$

$\nabla \varphi(x) = F'(x)^T F(x)$  Jacobi-Matrix

•  $\varphi''(x^*) \in \mathbb{R}^{n \times n}$  ist spd

## Gauss-Newton-Verfahren

• lineare Approx. mit Taylor

• schrittweise Annäherung

• Berechne  $F(x^k)$ ,  $F'(x^k)$

• finde  $s^k \in \mathbb{R}^n$  sodass

$$\|F'(x^k)s^k + F(x^k)\|_2 = \min_{s \in \mathbb{R}^n} \|F'(x^k)s + F(x^k)\|_2$$

} **LAP**

• setze  $x^{k+1} = x^k + s^k$

• Abbruch bei  $\|F'(x^k)^T F(x^k)\|_2 \leq \varepsilon$

→ Fixpunktiteration,

konv. nicht schneller als linear

→ Sattelp./Max. abstoppen

→ lok. Min. haben abstoppen  
→ konv. nicht garantiert

# NUMA 8


Lagrange Interpolation • über Stützstellen,  $(x_0, f(x_0)), \dots$   
 • stets eindeutig lösbar

$$P_n(x) = \sum_{j=0}^n f(x_j) \cdot l_{jn}(x),$$

$$l_{jn}(x) = \prod_{\substack{k=0 \\ k \neq j}}^n \frac{x - x_k}{x_j - x_k}$$

Lagrange-Fundamentalphynome

für jeden Punkt konstruieren  
 mit ein  $l_{jn}(x)$



punktweise Anweisung mit Ai-then:  
 → festes  $x$

→ Reduktion des Grades

$$P(f|x_0, x_1, \dots, x_n)(x) = \frac{x - x_0}{x_n - x_0} \cdot P(f|x_1, \dots, x_n)(x) + \frac{x_n - x}{x_n - x_0} \cdot P(f|x_0, \dots, x_{n-1})(x)$$

rekursiv:

$$P_{i,k} = P_{i,k-1} + \frac{x - x_i}{x_i - x_{i-k}} (P_{i,k-1} - P_{i-1,k-1})$$

Neville-Ai-then:

	$P_{i,0}$	$P_{i,1}$	$P_{i,2}$	...
$x_0$	$f(x_0)$			
$x_1$	$f(x_1)$	$P_{1,1}$		
$x_2$	$f(x_2)$	$P_{2,1}$	$P_{2,2}$	
...	...	...	...	...
$x_n$	$f(x_n)$	$P_{n,1}$	$P_{n,2}$	... $P_{n,n-1}$

→ keine explizite  
 Darstellung von  $P$

$$P(x) = a_0 \cdot x^0 + a_1 \cdot x^1 + \dots + a_n \cdot x^n$$

$$\rightarrow \begin{bmatrix} 1 & x_0 & x_0^2 & \dots & x_0^n \\ 1 & x_1 & x_1^2 & \dots & x_1^n \\ \dots & \dots & \dots & \dots & \dots \\ 1 & x_n & x_n^2 & \dots & x_n^n \end{bmatrix} \cdot \begin{bmatrix} a_0 \\ a_1 \\ \dots \\ a_n \end{bmatrix} = \begin{bmatrix} f(x_0) \\ f(x_1) \\ \dots \\ f(x_n) \end{bmatrix} \Leftrightarrow V_n^{-1} \cdot \begin{bmatrix} f(x_0) \\ \dots \\ f(x_n) \end{bmatrix} = \begin{bmatrix} a_0 \\ \dots \\ a_n \end{bmatrix}$$

Vandermonde Matrix  $V_n$

Kondition  $\kappa(V_n) = \|V_n\| \cdot \|V_n^{-1}\|$

→ meist W.F. schlecht

## Newton'sche Interpolationsformel

$P_{n-1} \rightarrow P_n$  (einen Wert mit einbezogen)

$$P_n(x) = P_{n-1}(x) + \delta_n \cdot (x-x_0) \dots (x-x_{n-1})$$

mit

$$\delta_n = \frac{f(x_n) - P_{n-1}(x_n)}{(x_n - x_0) \dots (x_n - x_{n-1})} \in \mathbb{R}$$

Newton'sche Basis: Konstantpolynome

$$\omega_0 = 1, \omega_1 = (x-x_0), \dots, \omega_n = (x-x_0) \dots (x-x_{n-1})$$

► Lagrange-Basis

$$P_n(x) = \sum_{j=0}^n f(x_j) \cdot l_{jn}(x), \quad l_{jn}(x) = \prod_{\substack{k=0 \\ k \neq j}}^n \frac{x-x_k}{x_j-x_k}$$

► monomiale Basis

$$P_n(x) = \sum_{j=0}^n a_j x^j, \quad V_n \cdot \begin{pmatrix} a_0 \\ \vdots \\ a_n \end{pmatrix} = \begin{pmatrix} f(x_0) \\ \vdots \\ f(x_n) \end{pmatrix}$$

► Newton'sche Basis

$$P_n(x) = \sum_{j=0}^n [x_0, \dots, x_j] f \cdot \omega_j(x), \quad [x_0, \dots, x_j] f = \frac{[x_1, \dots, x_n] f - [x_0, \dots, x_{n-1}] f}{x_n - x_0}$$

Fehleranalyse - Restglieddarstellung

$$f(x) - P(f|x_{x_0, \dots, x_n})(x) = \left( \prod_{j=0}^n (x-x_j) \right) \cdot \frac{f^{(n+1)}(\xi)}{(n+1)!}$$

# NuMa 10

Trapezregel:

$$\int_a^b f = \frac{b-a}{2} [f(a) + f(b)]$$

Summierte

Trapezregel:

$$\int_a^b f = h \left[ \frac{1}{2} f(a) + f(t_1) + \dots + f(t_{n-1}) + \frac{1}{2} f(b) \right]$$

Fehler:  $\frac{|f''(\xi)|}{12} \cdot h^3 \cdot n = \frac{h^2}{12} (b-a) |f''(\xi)|$

$$|f''(\xi)| = \max_{x \in [a,b]} |f''(x)|$$

$$\approx \frac{h^2}{12} (f''(b) - f''(a))$$

Newton-Cotes-Formeln:

$$\int = h \cdot \sum_{j=0}^m c_j \cdot f(x_j)$$

$$\frac{1}{h} \int_c^d c_j(x) dx$$

integrierte  
Lagrange-Polynom

Fehler:  $\frac{h^{m+2}}{(m+1)!} \|f^{(m+1)}\|_{\infty}$