

Veranstaltung Titel

Vortragender

Assistenten

Institut XXX

Wintersemester/Sommersemester xyz

Übersicht

Themen: Dahmen & Reusken Kap 2.3-2.4

- ▶ Grundlagen: Normen und Taylor-Entwicklung
- ▶ Kondition eines Problems

Übersicht

Themen: Dahmen & Reusken Kap 2.3-2.4

- ▶ Grundlagen: Normen und Taylor-Entwicklung
- ▶ Kondition eines Problems

Was Sie mitnehmen sollten:

- ▶ Grundbegriffe: Normen, Taylor-Entwicklung
- ▶ Was ist die (relative) Kondition eines Problems?
- ▶ Wie wird Kondition eines Problems berechnet?
- ▶ Wie sind die elementaren Rechenoperationen konditioniert?

Vektornormen

Beispiel

Sei $V = \mathbb{R}^n$, $x = (x_1, \dots, x_n) \in \mathbb{R}^n$.

Für jedes p mit $1 \leq p \leq \infty$ wird eine Norm definiert durch

$$\|x\|_p = \left(\sum_{i=1}^n |x_i|^p \right)^{\frac{1}{p}}$$

Speziell:

► 1-Norm:
$$\|x\|_1 = \sum_{i=1}^n |x_i|$$

Vektornormen

Beispiel

Sei $V = \mathbb{R}^n$, $x = (x_1, \dots, x_n) \in \mathbb{R}^n$.

Für jedes p mit $1 \leq p \leq \infty$ wird eine Norm definiert durch

$$\|x\|_p = \left(\sum_{i=1}^n |x_i|^p \right)^{\frac{1}{p}}$$

Speziell:

► 1-Norm: $\|x\|_1 = \sum_{i=1}^n |x_i|$

► ∞ -Norm: $\|x\|_\infty = \max_{i=1, \dots, n} |x_i|$

Vektornormen

Beispiel

Sei $V = \mathbb{R}^n$, $x = (x_1, \dots, x_n) \in \mathbb{R}^n$.

Für jedes p mit $1 \leq p \leq \infty$ wird eine Norm definiert durch

$$\|x\|_p = \left(\sum_{i=1}^n |x_i|^p \right)^{\frac{1}{p}}$$

Speziell:

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

Bemerkung: 2-Norm wird durch ein Skalarprodukt induziert.

Weitere Beispiele

“Endlich-dimensionaler Vektorraum” beinhaltet nicht nur \mathbb{R}^n :

Beispiel

Die Menge

$$\Pi_m := \left\{ \sum_{i=0}^m a_i t^i \mid a_i \in \mathbb{R} \right\}$$

ist ein \mathbb{R} -Vektorraum der Dimension $m + 1$.

Die Monome $M_i(t) := t^i$, $i = 0, \dots, m$, dienen als Basis.

Weitere Beispiele

“Endlich-dimensionaler Vektorraum” beinhaltet nicht nur \mathbb{R}^n :

Beispiel

Die Menge

$$\Pi_m := \left\{ \sum_{i=0}^m a_i t^i \mid a_i \in \mathbb{R} \right\}$$

ist ein \mathbb{R} -Vektorraum der Dimension $m + 1$.

Die Monome $M_i(t) := t^i$, $i = 0, \dots, m$, dienen als Basis.

Unendlich-dimensionaler Vektorraum:

$V = C^0(I)$, $I = [a, b] \subset \mathbb{R}$, mit Norm

$$\|f\|_p = \left(\int_a^b |f(x)|^p dx \right)^{\frac{1}{p}}$$

Satz 2.10

Auf einem endlich-dimensionalen Vektorraum V sind alle Normen äquivalent, d.h. zu je zwei Normen $\|\cdot\|_*$ und $\|\cdot\|_{**}$ existieren beschränkte, positive Konstanten c und C , so dass

$$c\|v\|_* \leq \|v\|_{**} \leq C\|v\|_*, \quad \text{für alle } v \in V$$

Satz 2.10

Auf einem endlich-dimensionalen Vektorraum V sind alle Normen äquivalent, d.h. zu je zwei Normen $\|\cdot\|_*$ und $\|\cdot\|_{**}$ existieren beschränkte, positive Konstanten c und C , so dass

$$c\|v\|_* \leq \|v\|_{**} \leq C\|v\|_*, \quad \text{für alle } v \in V$$

Beispiel

Sei $V = \mathbb{R}^n$, dann gilt

$$\|x\|_\infty \leq \|x\|_2 \leq \|x\|_1$$

und

$$\|x\|_2 \leq \sqrt{n}\|x\|_\infty$$

$$\|x\|_1 \leq \sqrt{n}\|x\|_2$$

$$\|x\|_1 \leq n\|x\|_\infty$$

Lineare Abbildungen und Operatornormen

X und Y : lineare normierte Räume (über \mathbb{R}) mit Normen $\|\cdot\|_X$, $\|\cdot\|_Y$. Eine Abbildung $\mathcal{L} : X \rightarrow Y$ heißt linear, falls für $x, z \in X$ und $\alpha, \beta \in \mathbb{R}$ gilt

$$\mathcal{L}(\alpha x + \beta z) = \alpha \mathcal{L}(x) + \beta \mathcal{L}(z)$$

Beispiel

Eine Matrix $B \in \mathbb{R}^{m \times n}$

$$B = (b_{i,j})_{i,j=1}^{m,n} = \begin{pmatrix} b_{1,1} & \cdots & b_{1,n} \\ \vdots & & \vdots \\ b_{m,1} & \cdots & b_{m,n} \end{pmatrix}, \quad b_{i,j} \in \mathbb{R},$$

entspricht der Abbildung $B : \mathbb{R}^n \rightarrow \mathbb{R}^m$, $Bx = \sum_{j=1}^n x_j b_j$, mit b_j die j -te Spalte der Matrix B .

Lineare Abbildungen und Operatornormen

Beispiel

$X = \mathbb{R}^{m+1}$, $Y = \Pi_m$ mit Basis $\{\phi_0, \dots, \phi_m\}$.

$$\mathcal{L}(a) := \sum_{i=0}^m a_i \phi_i, \quad a \in \mathbb{R}^{m+1}$$

Lineare Abbildungen und Operatornormen

Beispiel

$X = \mathbb{R}^{m+1}$, $Y = \Pi_m$ mit Basis $\{\phi_0, \dots, \phi_m\}$.

$$\mathcal{L}(a) := \sum_{i=0}^m a_i \phi_i, \quad a \in \mathbb{R}^{m+1}$$

Operatornorm

Sei $\mathcal{L} : X \rightarrow Y$ eine lineare Abbildung.

$$\|\mathcal{L}\|_{X \rightarrow Y} := \sup_{x \neq 0} \frac{\|\mathcal{L}(x)\|_Y}{\|x\|_X}$$

Wichtige Eigenschaft:

$$\|\mathcal{L}(x)\|_Y \leq \|\mathcal{L}\|_{X \rightarrow Y} \|x\|_X, \quad \text{für alle } x \in X$$

Matrixnormen

Lineare Abbildung in Form einer Matrix, dann
Matrixnorm:=Operatornorm.

Definition

Sei $A \in \mathbb{R}^{n \times n}$ und $\|\cdot\|$ eine Norm auf \mathbb{R}^n , dann ist durch

$$\|A\| = \sup_{x \neq 0} \frac{\|Ax\|}{\|x\|} = \sup_{\|x\|=1} \|Ax\|$$

eine dazugehörige **Matrixnorm** definiert.

Beachte

Definition gilt entsprechend auch für $A \in \mathbb{R}^{m \times n}$.

Die **induzierte Matrixnorm** $\|A\|$ ist die kleinste Zahl c , so dass gilt

$$\|Ax\| \leq c\|x\| \quad \text{für alle } x \in \mathbb{R}^n.$$

Matrixnormen

Lineare Abbildung in Form einer Matrix, dann
Matrixnorm:=Operatornorm.

Definition

Sei $A \in \mathbb{R}^{n \times n}$ und $\|\cdot\|$ eine Norm auf \mathbb{R}^n , dann ist durch

$$\|A\| = \sup_{x \neq 0} \frac{\|Ax\|}{\|x\|} = \sup_{\|x\|=1} \|Ax\|$$

eine dazugehörige **Matrixnorm** definiert.

Es gilt:

- ▶ $\|A\| \geq 0$, und $\|A\| = 0$ nur wenn $A = 0$.
- ▶ Für alle $\alpha \in \mathbb{R}$: $\|\alpha A\| = |\alpha| \|A\|$
- ▶ Dreiecksungleichung:

$$\|A + B\| \leq \|A\| + \|B\|$$

Matrixnormen

Lineare Abbildung in Form einer Matrix, dann
Matrixnorm:=Operatornorm.

Definition

Sei $A \in \mathbb{R}^{n \times n}$ und $\|\cdot\|$ eine Norm auf \mathbb{R}^n , dann ist durch

$$\|A\| = \sup_{x \neq 0} \frac{\|Ax\|}{\|x\|} = \sup_{\|x\|=1} \|Ax\|$$

eine dazugehörige **Matrixnorm** definiert.

und:

- ▶ $\|Ax\| \leq \|A\| \|x\|$
- ▶ $\|AB\| \leq \|A\| \|B\|$
- ▶ $\|I\| = 1$

Matrixnormen

Aus der Definition ergeben sich folgende Formeln für $A \in \mathbb{R}^{m \times n}$:

► 1-Norm:

(max. Spaltensumme)

$$\|A\|_1 = \max_{j=1,\dots,n} \sum_{i=1}^m |a_{ij}|$$

Matrixnormen

Aus der Definition ergeben sich folgende Formeln für $A \in \mathbb{R}^{m \times n}$:

- 1-Norm: (max. Spaltensumme)

$$\|A\|_1 = \max_{j=1,\dots,n} \sum_{i=1}^m |a_{ij}|$$

- ∞ -Norm: (max. Zeilensumme)

$$\|A\|_\infty = \max_{i=1,\dots,m} \sum_{j=1}^n |a_{ij}|$$

Matrixnormen

Aus der Definition ergeben sich folgende Formeln für $A \in \mathbb{R}^{m \times n}$:

- 1-Norm: (max. Spaltensumme)

$$\|A\|_1 = \max_{j=1,\dots,n} \sum_{i=1}^m |a_{ij}|$$

- ∞ -Norm: (max. Zeilensumme)

$$\|A\|_\infty = \max_{i=1,\dots,m} \sum_{j=1}^n |a_{ij}|$$

- 2-Norm: (Spektralnrm)

$$\|A\|_2 = \sqrt{\lambda_{\max}(A^T A)}$$

wobei $\lambda_{\max}(A^T A)$ der größte Eigenwert von $A^T A$ ist.

Matrixnormen

Beispiel

Für $A = \begin{pmatrix} 2 & -3 \\ 1 & 1 \end{pmatrix}$ ergibt sich:

Matrixnormen

Beispiel

Für $A = \begin{pmatrix} 2 & -3 \\ 1 & 1 \end{pmatrix}$ ergibt sich:

$$\|A\|_1 = 4, \quad \|A\|_\infty = 5, \quad \|A\|_2 = \sqrt{\frac{1}{2} (15 + 5\sqrt{5})},$$

Matrixnormen

Beispiel

Für $A = \begin{pmatrix} 2 & -3 \\ 1 & 1 \end{pmatrix}$ ergibt sich:

$$\|A\|_1 = 4, \quad \|A\|_\infty = 5, \quad \|A\|_2 = \sqrt{\frac{1}{2} (15 + 5\sqrt{5})},$$

denn die Eigenwerte von $A^T A = \begin{pmatrix} 5 & -5 \\ -5 & 10 \end{pmatrix}$ kann man über

$$\det(A^T A - \lambda I) = 0 \iff (5 - \lambda)(10 - \lambda) - 25 = 0$$

bestimmen und damit

$$\lambda_1 = \frac{1}{2} (15 - 5\sqrt{5}), \quad \lambda_2 = \frac{1}{2} (15 + 5\sqrt{5}).$$

Landau-Symbol

Landau-Symbol \mathcal{O}

Betrachte zwei Funktionen $g, h : \mathbb{R} \rightarrow \mathbb{R}$. Wir verwenden die Notation

$$g(x) = \mathcal{O}(h(x)) \quad (x \rightarrow x_0)$$

wenn es Konstanten $C > 0$ und $\delta > 0$ gibt, so dass gilt:

$$|g(x)| \leq C|h(x)|, \quad \forall x \text{ mit } |x - x_0| < \delta$$

- ▶ Anschauliche Bedeutung
 g wächst nicht wesentlich schneller als h (in einer Umgebung von x_0)
- ▶ Definition gilt entsprechend auch für $g, h : \mathbb{R}^n \rightarrow \mathbb{R}^m$.

Taylor-Entwicklung: Skalare Funktionen

Taylor-Entwicklung (von f um x_0)

Für hinreichend oft differenzierbares $f : \mathbb{R} \rightarrow \mathbb{R}$ gilt

$$\begin{aligned} f(x) = & f(x_0) + f'(x_0)(x - x_0) + \frac{f^{(2)}(x_0)}{2}(x - x_0)^2 + \dots \\ & + \frac{f^{(k-1)}(x_0)}{(k-1)!}(x - x_0)^{k-1} + \frac{f^{(k)}(\xi)}{k!}(x - x_0)^k, \end{aligned}$$

wobei ξ eine Zahl zwischen x und x_0 ist.

$f^{(n)}(x_0)$ ist die n -te Ableitung von f an der Stelle x_0 .

Taylor-Entwicklung: Skalare Funktionen

Taylor-Polynom vom Grad $k - 1$ in x_0

$$\begin{aligned} p_{k-1}(x) = & f(x_0) + f'(x_0)(x - x_0) + \frac{f^{(2)}(x_0)}{2}(x - x_0)^2 \\ & + \dots + \frac{f^{(k-1)}(x_0)}{(k-1)!}(x - x_0)^{k-1}. \end{aligned}$$

Taylor-Entwicklung: Skalare Funktionen

Taylor-Polynom vom Grad $k - 1$ in x_0

$$p_{k-1}(x) = f(x_0) + f'(x_0)(x - x_0) + \frac{f^{(2)}(x_0)}{2}(x - x_0)^2 \\ + \dots + \frac{f^{(k-1)}(x_0)}{(k-1)!}(x - x_0)^{k-1}.$$

- Für $k = 1$ erhält man den [Mittelwertsatz](#)

$$\frac{f(x) - f(x_0)}{x - x_0} = f'(\xi),$$

wobei ξ eine Zahl zwischen x und x_0 ist.

- Oft verwendete Darstellung

$$f(x) = p_{k-1}(x) + \mathcal{O}(|x - x_0|^k) \quad (x \rightarrow x_0)$$

Taylor-Entwicklung: Skalare Funktionen

Taylor-Polynom vom Grad $k - 1$ in x_0

$$p_{k-1}(x) = f(x_0) + f'(x_0)(x - x_0) + \frac{f^{(2)}(x_0)}{2}(x - x_0)^2 \\ + \dots + \frac{f^{(k-1)}(x_0)}{(k-1)!}(x - x_0)^{k-1}.$$

- Für $k = 1$ erhält man den [Mittelwertsatz](#)

$$\frac{f(x) - f(x_0)}{x - x_0} = f'(\xi),$$

wobei ξ eine Zahl zwischen x und x_0 ist.

- Oft verwendete Darstellung


$$f(x) = p_{k-1}(x) + \mathcal{O}(|x - x_0|^k) \quad (x \rightarrow x_0)$$

Siehe auch Matlab-Demo 2.23.

Taylor-Entwicklung: Skalare Funktionen

Taylor-Reihenentwicklung 0., 1. und 2. Ordnung um $x_0 = 0$ von


$$f(x) = -0.1x^4 - 0.15x^3 - 0.5x^2 - 0.25x + 1.2$$



Taylor-Entwicklung: Skalare Funktionen

Taylor-Reihenentwicklung 0., 1. und 2. Ordnung um $x_0 = 0$ von


$$f(x) = -0.1x^4 - 0.15x^3 - 0.5x^2 - 0.25x + 1.2$$



Taylor-Entwicklung: Skalare Funktionen

Taylor-Reihenentwicklung 0., 1. und 2. Ordnung um $x_0 = 0$ von


$$f(x) = -0.1x^4 - 0.15x^3 - 0.5x^2 - 0.25x + 1.2$$




Taylor-Entwicklung: Skalare Funktionen

Taylor-Reihenentwicklung 0., 1. und 2. Ordnung um $x_0 = 0$ von


$$f(x) = -0.1x^4 - 0.15x^3 - 0.5x^2 - 0.25x + 1.2$$



Taylor-Entwicklung: Skalare Funktionen




Taylor-Entwicklung: Skalare Funktionen




Taylor-Pol. 0. Grades in 0: $p_0(x) = 1$

Taylor-Entwicklung: Skalare Funktionen




Taylor-Pol. 1. Grades in 0: $p_1(x) = 1 + x$

Taylor-Entwicklung: Skalare Funktionen




Taylor-Pol. 2. Grades in 0: $p_2(x) = 1 + x + \frac{x^2}{2!}$

Taylor-Entwicklung: Skalare Funktionen




Taylor-Pol. 3. Grades in 0: $p_3(x) = 1 + x + \frac{x^2}{2!} + \frac{x^3}{3!}$

Taylor-Entwicklung: Skalare Funktionen



Taylor-Pol. 4. Grades in 0: $p_4(x) = 1 + x + \frac{x^2}{2!} + \frac{x^3}{3!} + \frac{x^4}{4!}$

Taylor-Entwicklung: Skalare Funktionen



Taylor-Pol. 5. Grades in 0: $p_5(x) = 1 + x + \frac{x^2}{2!} + \frac{x^3}{3!} + \frac{x^4}{4!} + \frac{x^5}{5!}$

Taylor-Entwicklung: Vektorwertige Funktionen

Taylor-Entwicklung (von f um x)

Für hinreichend oft differenzierbares $f : \mathbb{R}^n \rightarrow \mathbb{R}$ gilt

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

Taylor-Entwicklung: Vektorwertige Funktionen

Taylor-Entwicklung (von f um x)

Für hinreichend oft differenzierbares $f : \mathbb{R}^n \rightarrow \mathbb{R}$ gilt

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

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

Taylor-Entwicklung: Vektorwertige Funktionen

Kompakte Schreibweise

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

oder

$$f(\tilde{x}) = f(x) + (\nabla f(x))^T (\tilde{x} - x) + \mathcal{O}(\|\tilde{x} - x\|_2^2).$$

Falls $\|\tilde{x} - x\| \ll 1$:

$$f(\tilde{x}) \doteq f(x) + (\nabla f(x))^T (\tilde{x} - x)$$

\doteq : Terme höherer Ordnung werden vernachlässigt.

Fehlerquellen

Fehler im Resultat auf Grund von

- ▶ Datenfehlern (oder Eingabefehlern)

⇒ **Kondition eines Problems**

- können häufig nicht vermieden werden

Fehlerquellen

Fehler im Resultat auf Grund von

- ▶ Datenfehlern (oder Eingabefehlern)

⇒ **Kondition eines Problems**


– können häufig nicht vermieden werden

- ▶ Fehler(akkumulation) im Algorithmus (z.B. Rundungsfehler)

⇒ **Stabilität eines Algorithmus**

– kann man beeinflussen durch Anpassung des Verfahrens

Fehleranalyse: Kondition, Rundungsfehler, Stabilität



Kondition

Ziel: Analyse der Fehlerverstärkung bei Datenfehlern

Konzept der Kondition eines Problems

Kondition

Ziel: Analyse der Fehlerverstärkung bei Datenfehlern

Konzept der Kondition eines Problems

Beachte: Kondition

- ▶ ist **unabhängig** von einem speziellen Lösungsweg (Algorithmus)
- ▶ gibt an, welche Genauigkeit man **bestenfalls** (bei **exakter Rechnung**) bei gestörten Eingangsdaten erwarten kann.

Kondition

Ziel: Analyse der Fehlerverstärkung bei Datenfehlern

Konzept der Kondition eines Problems

Beachte: Kondition

- ▶ ist **unabhängig** von einem speziellen Lösungsweg (Algorithmus)
- ▶ gibt an, welche Genauigkeit man **bestenfalls** (bei **exakter Rechnung**) bei gestörten Eingangsdaten erwarten kann.

Wir fassen den “mathematischen Prozess” oder das “Problem” als Aufgabe auf, eine gegebene Funktion

$$f : X \rightarrow Y$$

an einer Stelle $x \in X$ auszuwerten.

Elementare Beispiele

- ▶ Die Berechnung der Multiplikation von x_1 und x_2 :

$$f(x_1, x_2) = x_1 x_2$$

und $X = \mathbb{R}^2$, $Y = \mathbb{R}$.

Elementare Beispiele

- ▶ Die Berechnung der Multiplikation von x_1 und x_2 :

$$f(x_1, x_2) = x_1 x_2$$

und $X = \mathbb{R}^2$, $Y = \mathbb{R}$.

- ▶ Die Berechnung der Summe von x_1 und x_2 :

$$f(x_1, x_2) = x_1 + x_2$$

und $X = \mathbb{R}^2$, $Y = \mathbb{R}$.

Elementare Beispiele

- Man bestimme die kleinere Nullstelle der Gleichung

$$y^2 - 2x_1 y + x_2 = 0,$$

mit $x_1^2 > x_2$. Die Lösung y^* ist

$$y^* = f(x_1, x_2) = x_1 - \sqrt{x_1^2 - x_2}.$$

mit

$$X = \{(x_1, x_2) \in \mathbb{R}^2 \mid x_1^2 > x_2\},$$

$$Y = \mathbb{R}.$$

Elementare Beispiele

- Bestimmung des Schnittpunktes zweier Geraden:

$$G_1 = \{(y_1, y_2) \in \mathbb{R}^2 \mid a_{1,1} y_1 + a_{1,2} y_2 = x_1\}$$

$$G_2 = \{(y_1, y_2) \in \mathbb{R}^2 \mid a_{2,1} y_1 + a_{2,2} y_2 = x_2\}$$

wobei $(x_1, x_2)^T \in \mathbb{R}^2$ und $a_{i,j}$ gegeben seien.

Mit

$$A = \begin{pmatrix} a_{1,1} & a_{1,2} \\ a_{2,1} & a_{2,2} \end{pmatrix}$$

ergibt sich

$$Ay = x.$$

Elementare Beispiele

► Bestimmung des Schnittpunktes zweier Geraden: (Fortsetzung)

Es gilt also

$$A \cdot y = \begin{pmatrix} a_{1,1} & a_{1,2} \\ a_{2,1} & a_{2,2} \end{pmatrix} \cdot \begin{pmatrix} y_1 \\ y_2 \end{pmatrix} = \begin{pmatrix} x_1 \\ x_2 \end{pmatrix} = x$$

Annahme: $\det A \neq 0$

Dann ist y durch

$$y = A^{-1}x$$


gegeben. Also Auswertung der Funktion

$$f(x) = A^{-1}x,$$

d.h. $X = Y = \mathbb{R}^2$.


Begriff der Kondition

Ungestörtes Problem




Begriff der Kondition

Ungestörtes Problem



Gestörtes Problem




mit Eingabefehler $\Delta x = \tilde{x} - x$


Ausgabefehler $\Delta y = \tilde{y} - y = f(\tilde{x}) - f(x)$

Begriff der Kondition

Ungestörtes Problem



Gestörtes Problem



mit Eingabefehler $\Delta x = \tilde{x} - x$

Ausgabefehler $\Delta y = \tilde{y} - y = f(\tilde{x}) - f(x)$

Ziel: Verhältnis Ausgabefehler Δy zu Eingabefehler Δx .

Begriff der Kondition

Arten von Fehlern

- ▶ absoluter Eingabefehler: $\|\Delta x\|_X$
- ▶ absoluter Ausgabefehler: $\|\Delta y\|_Y$
- ▶ relativer Eingabefehler: $\delta_x = \frac{\|\Delta x\|_X}{\|x\|_X}$
- ▶ relativer Ausgabefehler: $\delta_y = \frac{\|\Delta y\|_Y}{\|y\|_Y}$

Begriff der Kondition

Definition

Mit der **relativen Kondition** eines (durch f beschriebenen) Problems bezeichnet man das Verhältnis

$$\frac{\delta_y}{\delta_x}$$

des relativen Ausgabefehlers zum relativen Eingabefehler, d.h. die **Sensitivität** des Problems unter Störungen der Eingabedaten.

Begriff der Kondition

Definition


Mit der **relativen Kondition** eines (durch f beschriebenen) Problems bezeichnet man das Verhältnis

$$\frac{\delta_y}{\delta_x}$$

des relativen Ausgabefehlers zum relativen Eingabefehler, d.h. die **Sensitivität** des Problems unter Störungen der Eingabedaten.


- ▶ **Absolute Kondition**: Verhältnis $\frac{\|\Delta y\|_Y}{\|\Delta x\|_X}$
- ▶ Mit Kondition wird meistens die **relative** Kondition gemeint.
- ▶ Ein Problem ist umso besser **konditioniert**, je kleinere Schranken für δ_y/δ_x (mit $\delta_x \rightarrow 0$) existieren.

Taylorentwicklung 1. Ordnung




Relative / absolute Kondition: Verhältnis $\frac{\delta_y}{\delta_x}$ bzw. $\frac{\|\Delta y\|_Y}{\|\Delta x\|_X}$.

Taylorentwicklung 1. Ordnung



Relative / absolute Kondition: Verhältnis $\frac{\delta_y}{\delta_x}$ bzw. $\frac{\|\Delta y\|_Y}{\|\Delta x\|_X}$.

Taylorentwicklung 1. Ordnung



Relative / absolute Kondition: Verhältnis $\frac{\delta_y}{\delta_x}$ bzw. $\frac{\|\Delta y\|_Y}{\|\Delta x\|_X}$.

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

Taylor-Entwicklung 1. Ordnung von f um festes x

$$f(\tilde{x}) \doteq f(x) + f'(x) (\tilde{x} - x)$$

Daraus erhält man die Kondition für

► $f : \mathbb{R} \rightarrow \mathbb{R}$ (Eingabe: Skalar, Ausgabe: Skalar)

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

Taylor-Entwicklung 1. Ordnung von f um festes x

$$f(\tilde{x}) \doteq f(x) + f'(x) (\tilde{x} - x)$$

Daraus erhält man die Kondition für

► $f : \mathbb{R} \rightarrow \mathbb{R}$ (Eingabe: Skalar, Ausgabe: Skalar)

$$\left| \frac{f(\tilde{x}) - f(x)}{f(x)} \right| \doteq \kappa_{\text{rel}}(x) \left| \frac{\tilde{x} - x}{x} \right|$$

mit

$$\kappa_{\text{rel}}(x) := \left| f'(x) \frac{x}{f(x)} \right|$$

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

Für $f : \mathbb{R}^n \rightarrow \mathbb{R}$ lautet die Taylor-Reihenentwicklung 1. Ordnung

$$f(\tilde{x}) \doteq f(x) + (\nabla f(x))^T \cdot (\tilde{x} - x)$$

mit

$$x = \begin{pmatrix} x_1 \\ \vdots \\ x_n \end{pmatrix} \in \mathbb{R}^n.$$

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

Für $f : \mathbb{R}^n \rightarrow \mathbb{R}$ lautet die Taylor-Reihenentwicklung 1. Ordnung

$$f(\tilde{x}) \doteq f(x) + (\nabla f(x))^T \cdot (\tilde{x} - x)$$

mit

$$x = \begin{pmatrix} x_1 \\ \vdots \\ x_n \end{pmatrix} \in \mathbb{R}^n.$$

Hieraus folgt

$$\frac{f(\tilde{x}) - f(x)}{f(x)} \doteq \sum_{j=1}^n \left(\frac{\partial f(x)}{\partial x_j} \cdot \frac{x_j}{f(x)} \right) \cdot \frac{\tilde{x}_j - x_j}{x_j}$$

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

Mit den Verstärkungsfaktoren

$$\phi_j(x) = \frac{\partial f(x)}{\partial x_j} \cdot \frac{x_j}{f(x)}$$

erhält man

$$\underbrace{\frac{f(\tilde{x}) - f(x)}{f(x)}}_{\text{relativer Fehler der Ausgabe}} \doteq \sum_{j=1}^n \underbrace{\phi_j(x)}_{\text{Fehlerverstärkung}} \cdot \underbrace{\frac{\tilde{x}_j - x_j}{x_j}}_{\text{relativer Fehler der Eingabe in } x_j}$$

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

Damit erhält man die Kondition für

► $f : \mathbb{R}^n \rightarrow \mathbb{R}$ (Eingabe: Vektor, Ausgabe: Skalar)

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

Damit erhält man die Kondition für

► $f : \mathbb{R}^n \rightarrow \mathbb{R}$ (Eingabe: Vektor, Ausgabe: Skalar)

$$\left| \frac{f(\tilde{x}) - f(x)}{f(x)} \right| \stackrel{\cdot}{\leq} \kappa_{\text{rel}}(x) \sum_{j=1}^n \left| \frac{\tilde{x}_j - x_j}{x_j} \right|$$

mit

$$\kappa_{\text{rel}}(x) = \kappa_{\text{rel}}^{\infty}(x) := \max_j |\phi_j(x)|$$

und den Verstärkungsfaktoren

$$\phi_j(x) = \frac{\partial f(x)}{\partial x_j} \cdot \frac{x_j}{f(x)}$$

wobei $\stackrel{\cdot}{\leq}$ entsprechend $\stackrel{\cdot}{=}$ zu verstehen ist.

Beispiel 2.26.

Gegeben sei

$$f : \mathbb{R} \rightarrow \mathbb{R}, \quad f(x) = e^{3x^2}.$$

Relative Konditionszahl:

$$\kappa_{\text{rel}}(x) = \left| f'(x) \frac{x}{f(x)} \right| = 6x^2.$$

\leadsto für $|x|$ klein/groß ist f gut/schlecht konditioniert.

Beispiel 2.26.

Gegeben sei

$$f : \mathbb{R} \rightarrow \mathbb{R}, \quad f(x) = e^{3x^2}.$$

Relative Konditionszahl:

$$\kappa_{\text{rel}}(x) = \left| f'(x) \frac{x}{f(x)} \right| = 6x^2.$$

\rightsquigarrow für $|x|$ klein/groß ist f gut/schlecht konditioniert.

Beispiel

► $x = 0.1, \tilde{x} = 0.10001: \kappa_{\text{rel}}(0.1) = 6 \cdot 10^{-2}$

$$\left| \frac{\tilde{x} - x}{x} \right| = 10^{-4} \rightarrow \left| \frac{f(x) - f(\tilde{x})}{f(x)} \right| = 6.03 \cdot 10^{-6}$$

Beispiel 2.26.

Gegeben sei

$$f : \mathbb{R} \rightarrow \mathbb{R}, \quad f(x) = e^{3x^2}.$$

Relative Konditionszahl:

$$\kappa_{\text{rel}}(x) = \left| f'(x) \frac{x}{f(x)} \right| = 6x^2.$$

\rightsquigarrow für $|x|$ klein/groß ist f gut/schlecht konditioniert.

Beispiel

► $x = 0.1, \tilde{x} = 0.10001: \kappa_{\text{rel}}(0.1) = 6 \cdot 10^{-2}$

$$\left| \frac{\tilde{x} - x}{x} \right| = 10^{-4} \rightarrow \left| \frac{f(x) - f(\tilde{x})}{f(x)} \right| = 6.03 \cdot 10^{-6}$$

► $x = 4, \tilde{x} = 4.0004: \kappa_{\text{rel}}(4) = 96$

$$\left| \frac{\tilde{x} - x}{x} \right| = 10^{-4} \rightarrow \left| \frac{f(x) - f(\tilde{x})}{f(x)} \right| = 9.65 \cdot 10^{-3}$$

Elementare Rechenoperationen

Kondition bei

- ▶ Multiplikation: $x = (x_1, x_2)^T$, $f(x) = x_1 x_2$

Elementare Rechenoperationen

Kondition bei

- ▶ Multiplikation: $x = (x_1, x_2)^T$, $f(x) = x_1 x_2$

$$\kappa_{\text{rel}}(x) = 1 \text{ (von } x \text{ unabhängig!)}$$

Multiplikation für alle Eingangsdaten gut konditioniert.

Ein ähnliches Resultat gilt für die Division.

Elementare Rechenoperationen

Kondition bei

- ▶ Multiplikation: $x = (x_1, x_2)^T$, $f(x) = x_1 x_2$

$$\kappa_{\text{rel}}(x) = 1 \text{ (von } x \text{ unabhängig!)}$$

Multiplikation für alle Eingangsdaten gut konditioniert.

Ein ähnliches Resultat gilt für die Division.

- ▶ Addition: $x = (x_1, x_2)^T$, $f(x) = x_1 + x_2$

Elementare Rechenoperationen

Kondition bei

- ▶ Multiplikation: $x = (x_1, x_2)^T$, $f(x) = x_1 x_2$

$$\kappa_{\text{rel}}(x) = 1 \text{ (von } x \text{ unabhängig!)}$$

Multiplikation für alle Eingangsdaten gut konditioniert.

Ein ähnliches Resultat gilt für die Division.

- ▶ Addition: $x = (x_1, x_2)^T$, $f(x) = x_1 + x_2$

$$\kappa_{\text{rel}}(x) = \max \left\{ \left| \frac{x_1}{x_1 + x_2} \right|, \left| \frac{x_2}{x_1 + x_2} \right| \right\}$$

Bei zwei Zahlen mit gleichem Vorzeichen: $\kappa_{\text{rel}} \leq 1$.

ABER: $\kappa_{\text{rel}}(x) \gg 1$ wenn $x_1 \approx -x_2$.

Beispiel 2.29 (Nullstelle)

Bestimmung der kleineren Nullstelle y^* von $y^2 - 2x_1y + x_2 = 0$:

$$x = (x_1, x_2)^T, \quad y^* = f(x) = x_1 - \sqrt{x_1^2 - x_2}$$

► Partielle Ableitungen

$$\frac{\partial f(x)}{\partial x_1} = \frac{\sqrt{x_1^2 - x_2} - x_1}{\sqrt{x_1^2 - x_2}} = \frac{-y^*}{\sqrt{x_1^2 - x_2}}$$

$$\frac{\partial f(x)}{\partial x_2} = \frac{1}{2\sqrt{x_1^2 - x_2}}$$

► Verstärkungsfaktoren

$$\phi_j(x) = \frac{\partial f(x)}{\partial x_j} \cdot \frac{x_j}{f(x)}$$

Beispiel 2.29 (Nullstelle)

► Verstärkungsfaktoren

$$\phi_1(x) = \frac{-y^*}{\sqrt{x_1^2 - x_2}} \cdot \frac{x_1}{y^*} = \frac{-x_1}{\sqrt{x_1^2 - x_2}}$$

$$\phi_2(x) = \frac{1}{2\sqrt{x_1^2 - x_2}} \cdot \frac{x_2}{y^*} = \frac{1}{2} - \frac{1}{2}\phi_1(x)$$

► Kondition: $\kappa_{\text{rel}}(x) = \max_j |\phi_j(x)|$

Beispiel 2.29 (Nullstelle)

► Verstärkungsfaktoren

$$\phi_1(x) = \frac{-y^*}{\sqrt{x_1^2 - x_2}} \cdot \frac{x_1}{y^*} = \frac{-x_1}{\sqrt{x_1^2 - x_2}}$$

$$\phi_2(x) = \frac{1}{2\sqrt{x_1^2 - x_2}} \cdot \frac{x_2}{y^*} = \frac{1}{2} - \frac{1}{2}\phi_1(x)$$

► Kondition: $\kappa_{\text{rel}}(x) = \max_j |\phi_j(x)|$

Kondition hängt stark von der Stelle (x_1, x_2) ab:

Beispiel 2.29 (Nullstelle)

- ▶ Verstärkungsfaktoren

$$\phi_1(x) = \frac{-y^*}{\sqrt{x_1^2 - x_2}} \cdot \frac{x_1}{y^*} = \frac{-x_1}{\sqrt{x_1^2 - x_2}}$$

$$\phi_2(x) = \frac{1}{2\sqrt{x_1^2 - x_2}} \cdot \frac{x_2}{y^*} = \frac{1}{2} - \frac{1}{2}\phi_1(x)$$

- ▶ Kondition: $\kappa_{\text{rel}}(x) = \max_j |\phi_j(x)|$

Kondition hängt stark von der Stelle (x_1, x_2) ab:

- ▶ Wenn $x_2 < 0$: $|\phi_1(x)| \leq 1$ und $\kappa_{\text{rel}}(x) \leq 1$
- ▶ Wenn $x_2 \approx x_1^2$: $|\phi_1(x)| \gg 1$ und $\kappa_{\text{rel}}(x) \gg 1$

Zusammenfassung

Kondition

- ▶ ist **unabhängig** von einem speziellen Lösungsweg (Algorithmus)
- ▶ gibt an, welche Genauigkeit man **bestenfalls (bei exakter Rechnung)** bei gestörten Eingangsdaten erwarten kann.

Zusammenfassung

Kondition

- ▶ ist **unabhängig** von einem speziellen Lösungsweg (Algorithmus)
- ▶ gibt an, welche Genauigkeit man **bestenfalls (bei exakter Rechnung)** bei gestörten Eingangsdaten erwarten kann.

Frage:

- ▶ Was ist die (relative) Kondition eines Problems?

⇒ Die relative Kondition eines Problems bezeichnet **das Verhältnis des relativen Ausgabefehlers zum relativen Eingabefehler**, d.h. die Sensitivität des Problems unter Störungen der Eingabedaten.

Zusammenfassung

Wie wird die Kondition analysiert?

- ▶ Wir haben folgende Fälle betrachtet
 - ▶ $f : \mathbb{R} \rightarrow \mathbb{R}$
 - ▶ $f : \mathbb{R}^n \rightarrow \mathbb{R}$

Zusammenfassung

Wie wird die Kondition analysiert?

- ▶ Wir haben folgende Fälle betrachtet
 - ▶ $f : \mathbb{R} \rightarrow \mathbb{R}$
 - ▶ $f : \mathbb{R}^n \rightarrow \mathbb{R}$

Wie sind die elementaren Rechenoperationen konditioniert?

- ▶ Multiplikation und Division sind für alle Eingangsdaten **gut konditioniert**.
- ▶ Addition ist
 - ▶ **gut konditioniert**, wenn beide Zahlen das gleiche Vorzeichen haben;
 - ▶ **sehr schlecht konditioniert**, wenn $x_1 \approx -x_2$.