

1 Wiederholung

1.1 Matrizennormen

Sei $\|\cdot\|$ eine Norm auf $\mathbb{R}^n, n \geq 1$, dann definiert

$$\|A\| = \sup_{z \neq 0} \frac{\|Az\|}{\|z\|} = \max_{\|z\|=1} \|Az\|$$

für $A \in \mathbb{R}^{n \times n}$ eine Norm. Außerdem gilt:

- Submultiplikatitivität: $\|AB\| \leq \|A\| \cdot \|B\|$
- Verträglichkeit: $\|Az\| \leq \|A\| \cdot \|z\|$

Die von der **Maximumnorm** $\|\cdot\|_\infty$ induzierte Matrizennorm ist die "maximale Zeilensumme".

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

Die von der **L1-Norm** $\|\cdot\|_1$ induzierte Matrizennorm ist die "maximale Spaltensumme":

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

Sei A eine symmetrische Matrix, dann gilt:

$$\|A\|_2 = |\lambda_{\max}| = \{ |\lambda| \mid \lambda \in \text{Rst Eigenwert von } A \}$$

Für beliebige $\mathbb{R}^{n \times n}$ -Matrizen gilt:

$$\|A\|_2 = \sqrt{\lambda_{\max}(A^T A)} = \rho(A^T A)^{\frac{1}{2}} \quad (\text{Spektralradius})$$

Die Eigenwerte von A und A^{-1} sind zueinander invers.

$$\Rightarrow \|A^{-1}\|_2 = \frac{1}{\sqrt{\lambda_{\min}(A^T A)}}$$

1.2 Wichtige Reihen

$$\ln(1+x) = \sum_{k=0}^{\infty} \frac{(-1)^k}{k+1} x^{k+1} = x - \frac{x^2}{2} + \frac{x^3}{3} - \dots, \quad x \in (-1, 1]$$

$$\sin(x) = \sum_{k=0}^{\infty} \frac{(-1)^k}{(2k+1)!} x^{2k+1} = x - \frac{x^3}{3!} + \frac{x^5}{5!} - \dots$$

$$\cos(x) = \sum_{k=0}^{\infty} \frac{(-1)^k}{(2k)!} x^{2k} = 1 - \frac{x^2}{2!} + \frac{x^4}{4!} - \dots$$

$$e^x = \sum_{k=0}^{\infty} \frac{x^k}{k!} = 1 + x + \frac{x^2}{2!} + \frac{x^3}{3!} + \dots$$

Für alternierende Reihen $\sum_{k=0}^{\infty} (-1)^k a_k$ mit $a_k \geq 0$ und monoton fallend (z.B. ln, sin, cos) gilt nach dem **Leibnizkriterium**:

$$\underbrace{\left| \sum_{k=0}^{\infty} (-1)^k a_k - \sum_{k=0}^N (-1)^k a_k \right|}_{\text{Restglied}} \leq a_{N+1}$$

Für die Exponentialreihe gilt:

$$\underbrace{\left| e^z - \sum_{k=0}^N \frac{z^k}{k!} \right|}_{\text{Restglied}} \leq 2 \cdot \frac{|z|^{N+1}}{(N+1)!} \quad \text{für } |z| \leq 1$$

2 Grundbegriffe der Numerik

2.1 Gleitkomma-Arithmetik

Es werden Zahlen der Form

$$a = (-1)^s \cdot m \cdot b^t$$

betrachtet, mit $b \in \mathbb{N}, b \geq 2, s \in \{0, 1\}$ und

$$m = \sum_{i=0}^{t-1} m_i b^{-i}; \quad m_i \in \{0, \dots, b-1\}$$

$$e = \sum_{i=0}^{r-1} e_i b^i - \underbrace{(b^r - 1)}_{\text{Bias}}; \quad e_i \in \{0, \dots, b-1\}$$

wobei $t \geq 2$ und $r \geq 2$ die Genauigkeiten darstellen.

Nachfolgend sei $b=2$.

IEEE "single":
32 Bit (s: 1 Bit, e: 8 Bit, m: 23 Bit)
IEEE "double":
64 Bit (s: 1 Bit, e: 11 Bit, m: 52 Bit)

Definitionen:

- $a \in \mathbb{R}$ heißt **normierte Gleitkommazahl** ($a \in M_{\mathbb{R}}^N$), falls eine Darstellung existiert mit $m_0 = 1$ und $e_{\min} < e < e_{\max}$, wobei gelte:

$$e_{\min} = -b^{r-1} + 1$$

$$e_{\max} = b^{r-1}$$

- $a \in \mathbb{R}$ heißt **subnormale Gleitkommazahl** ($a \in M_{\mathbb{R}}^S$), falls $e = e_{\min}$ und $m_0 = 0$, wobei nicht alle m_i Null sind.

$$\Rightarrow a = (-1)^s \left(\sum_{i=1}^{t-1} m_i 2^{-i} \right) 2^{e+m+1}$$

- Sonderfälle

- "0": $\forall i: m_i = 0, e_i = 0$
- " ∞ ": $\forall i: m_i = 0, e_i = 1$
- "NaN": $\forall i: e_i = 1$, wobei nicht alle m_i Null sind.

- $M_{\mathbb{R},r} = M_{\mathbb{R}}^N \cup M_{\mathbb{R}}^S \cup \{\pm\infty\} \cup \{\text{NaN}\}$
- Der Abstand von 1 zur nächstgrößeren Zahl in $M_{\mathbb{R},r}$ ist:
 $\text{eps} = 2^{-(t-1)}$ (Maschinengenauigkeit)
- Rundung: $\text{rd}_{\mathbb{R},r}: \mathbb{R} \rightarrow M_{\mathbb{R},r}^N$

Für die IEEE-754-Standardrundung gilt:

$$\frac{|x - \text{rd}_{\mathbb{R},r}(x)|}{|x|} \leq \frac{\text{eps}}{2} \quad \text{für } x \neq 0$$

Für alle $x, y \in M_{\mathbb{R},r}^N$ und $*$ in $\{+, -, \cdot, /\}$ gilt:

$$x \odot y = \text{rd}_{\mathbb{R},r}(x * y)$$

2.2 Kondition

Seien x, y normierte Vektorräume (mit Norm $\|\cdot\|$). Ein Problem ist eine Funktion $f: x \rightarrow y$. Gesucht ist $\delta f = f(x + \delta x) - f(x)$ im Vergleich zu δx .

Die **absolute Kondition** von f im Punkt $x \in X$ ist

$$K_{\text{abs}}^f(x) = \limsup_{\delta \rightarrow 0} \sup_{\|\delta x\| < \delta} \frac{\|\delta f\|}{\|\delta x\|}$$

Sei $f: \mathbb{R} \rightarrow \mathbb{R}$ differenzierbar (mit $\| \cdot \| = | \cdot |$), dann gilt:

$$K_{\text{abs}}(x) = |f'(x)|$$

$$\Rightarrow \|\delta f\| \leq K_{\text{abs}} \cdot \|\delta x\|$$

Für die **relative Kondition** gilt:

$$K_{\text{rel}}(x) = \limsup_{\delta \rightarrow 0} \sup_{\|\delta x\| < \delta} \frac{\frac{\|\delta f\|}{|f(x)|}}{\frac{\|\delta x\|}{|x|}} = \limsup_{\delta \rightarrow 0} \sup_{\|\delta x\| < \delta} \frac{\|\delta f\| \cdot \|x\|}{|f(x)| \cdot \|\delta x\|}$$

Sei $f: \mathbb{R} \rightarrow \mathbb{R}$ differenzierbar, dann gilt:

$$K_{\text{rel}} = \frac{|f'(x)| \cdot |x|}{|f(x)|} = \frac{|f'(x)| \cdot |x|}{|f(x)|}$$

$$\Rightarrow \frac{\|\delta f\|}{|f(x)|} \leq K_{\text{rel}} \cdot \frac{\|\delta x\|}{|x|}$$

Sei $A \in \mathbb{R}^{n \times n}, f: \mathbb{R}^n \rightarrow \mathbb{R}^n, b \rightarrow f(b) = A^{-1}b = x$, dann gilt:

$$K_{\text{abs}}(b) = \|f'(b)\| = \|A^{-1}\|$$

$$K_{\text{rel}}(b) = \frac{\|A^{-1}\|}{\|A^{-1}b\|} = \|A^{-1}\| \cdot \frac{\|Ax\|}{\|x\|} \leq \|A^{-1}\| \cdot \|A\|$$

Für die Kondition bzgl. $\|\cdot\|_2$ gilt außerdem:

$$K_{\text{rel}}(A) = \sqrt{\frac{\lambda_{\max}(A^T A)}{\lambda_{\min}(A^T A)}}$$

N.B.:

$$\frac{\|f(x) - f(x')\|}{\|f(x)\|} \leq K_{\text{rel}} \cdot \frac{\|x - x'\|}{\|x\|} + O\left(\frac{\|x - x'\|^2}{\|x\|^2}\right)$$

2.3 Stabilität

Definitionen:

- Ein **Algorithmus** ist eine Abb. $f: x \rightarrow y$ mit $\tilde{f} = \tilde{f}_0 \circ \dots \circ \tilde{f}_1$, wobei jeder Teilschritt $\tilde{f}_i, i=1, \dots, k$ nur Operationen aus $\{\oplus, \ominus, \odot, \oslash, \text{rd}\}$ enthält.
- Ein Algorithmus \tilde{f} für ein Problem f heißt **rückwärtsstabil**, falls $\forall x \exists \delta \in X$ mit

$$\underbrace{\tilde{f}(x)}_{(1+\epsilon)f(x)} = f(x) \text{ und } \frac{\|x - x'\|}{\|x\|} = O(\epsilon) \text{ für } \epsilon \rightarrow 0$$

wobei ϵ den relativen Fehler darstellt.

Ziel:

Finde zu geg. f ein \tilde{f} , sodass der Fehler $\|f(x) - \tilde{f}(x)\|$ bzw. $\frac{\|f(x) - \tilde{f}(x)\|}{\|f(x)\|}$ möglichst "klein" ist.

Sei \tilde{f} ein rückwärtsstabiler Algorithmus für f , dann gilt:

$$\frac{\|\tilde{f}(x) - f(x)\|}{\|f(x)\|} \leq O(K_{\text{rel}}(x) \cdot \text{eps}) \text{ für } \text{eps} \rightarrow 0$$

3 Numerische lineare Algebra

3.1 Dreiecksmatrizen

Satz:

Falls $A = LR$ mit $L \in \mathbb{R}^{n \times n}$ untere und $R \in \mathbb{R}^{n \times n}$ obere Dreiecksmatrix, $\det(A) \neq 0$, so ist das LGS $Ax = b$ für alle $b \in \mathbb{R}^n$ in $2n^2$ Operationen lösbar.

N.B.

$$\sum_{k=1}^n (ak - b) = \frac{1}{2}n(an + a - 2b)$$

3.1.1 Vorwärts- / Rückwärtssubstitution

Falls A obere oder untere Dreiecksmatrix, so kann das LGS $Ax = b$ durch Vorwärts- bzw. Rückwärtssubstitution gelöst werden.

Matlab-Code für Vorwärtssubstitution:

```
for j = 1:n
    x(j) = (b(j) - A(j,1:j-1)*x(1:j-1))/A(j,j);
end
```

Matlab-Code für Rückwärtssubstitution:

```
for j = n:-1:1
    x(j) = (b(j) - A(j,j+1:n)*x(j+1:n))/A(j,j);
end
```

Aufwand: je n^2 Flops

3.2 Nachiteration

Mit Hilfe der Nachiteration kann eine Näherungslösung \tilde{x} eines LGS $Ax = b$ genauer approximiert werden.

Vorgehensweise:

- Berechne \tilde{x} : $A\tilde{x} = b$
- Berechne r : $r = b - A\tilde{x}$
- Berechne z : $Az = r$
- Die genauere Näherungslösung \hat{x} lautet: $\hat{x} = \tilde{x} + z$

3.3 LR/LU-Zerlegung

Sei $A \in \mathbb{R}^{n \times n}, \det(A) \neq 0, a_{ii} \neq 0, L \in \mathbb{R}^{n \times n}$ untere und $R \in \mathbb{R}^{n \times n}$ obere Dreiecksmatrix. Dann kann das LGS $Ax = b$ wie folgt gelöst werden:

- Berechne L und R , sodass $A = LR$
- Berechne y , sodass $Ly = b$ (für LRP-Zerlegung: $Ly = Pb$)
- Berechne x , sodass $Rx = y$

Für die Berechnung von L und R wird folgender Algorithmus angewendet:

- Setze $i_1 = \underset{j}{\text{arg max}} |a_{ij}|$ für $j \geq 1$.
- Setze $a_{ij} = a_{ij} - l_{i1} \cdot a_{1j}$ für alle j und $i \geq 2$:
 $z_{i1} = \text{Zeile } i - l_{i1} \cdot \text{Zeile } 1, \quad i \geq 2$
- Gehe zu Schritt 1 und ersetze alte 1er durch 2,3,4,...

Beispiel:

2	3	1	5	2	3	1	5	2	3	1	5
6	13	5	19	3	4	2	4	3	4	2	4
2	19	10	23	1	16	9	18	1	4	1	2
4	10	11	31	2	4	9	21	2	1	7	17
1. Iteration				2. Iteration				3. Iteration			

$$\Rightarrow \left(\begin{array}{ccc|ccc} 2 & 3 & 1 & 5 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 6 & 13 & 5 & 19 & 3 & 1 & 0 & 0 & 0 & 4 & 2 & 4 \\ 2 & 19 & 10 & 23 & 1 & 4 & 1 & 0 & 0 & 0 & 1 & 2 \\ 4 & 10 & 11 & 31 & 2 & 1 & 7 & 1 & 0 & 0 & 0 & 3 \end{array} \right)$$

Aufwand für Zerlegung: $\frac{2}{3}n^3 - \frac{1}{2}n^2 - \frac{1}{3}n$ Flops

Das oben genannte Verfahren ist ein **direktes/exaktes** Lösungsverfahren (keine Verfahrensfehler; nur Rundungsfehler)

Matlab-Code:

```
[n,n] = size(A);
for k = 1:n
    I = k+1:n;
    A(I,k) = A(I,k)/A(k,k);
    A(I,I) = A(I,I) - A(I,k)*A(k,I);
end
```

3.4 LRP/LUP-Zerlegung

Die LRP-Zerlegung ist eine LU-Zerlegung mit Pivoting-Strategie:

Suche $j \geq k$, sodass $|a_{kj}^{(k)}| \geq |a_{ik}^{(k)}| \quad \forall i \geq k$ und vertausche die j -te mit der k -ten Zeile in $A^{(k)}$.

Für $\det(A) \neq 0$ existiert eine Permutationsmatrix $P \in \mathbb{R}^{n \times n}$, sodass gilt:

$$PA = LR$$

Definition:

Eine Matrix heißt **Permutationsmatrix**, falls sie in jeder Zeile und jeder Spalte jeweils eine 1 enthält und sonst nur 0.

Beispiel:

1. Iteration														
1	2	0	2	0,6	3	5	5	4	2	3	5	5	4	2
2	3	3	4	-2	2	3	3	4	-2	2	0,6	0	1,6	-3,2
3	5	5	4	2	1	2	0	2	0,6	1	0,4	-2	0,4	-0,2
4	-1	-2	3,4	-1	4	-1	-2	3,4	-1	4	-0,2	-1	4,2	-0,6
2. Iteration														
3	5	5	4	2	3	5	5	4	2	3	5	5	4	2
2	0,6	0	1,6	-3,2	1	0,4	-2	0,4	-0,2	1	0,4	-2	0,4	-0,2
1	0,4	-2	0,4	-0,2	2	0,6	0	1,6	-3,2	2	0,6	0	1,6	-3,2
4	-0,2	-1	4,2	-0,6	4	-0,2	-1	4,2	-0,6	4	-0,2	0,5	4	-0,5
3. Iteration														
3	5	5	4	2	3	5	5	4	2	3	5	5	4	2
1	0,4	-2	0,4	-0,2	1	0,4	-2	0,4	-0,2	1	0,4	-2	0,4	-0,2
2	0,6	0	1,6	-3,2	4	-0,2	0,5	4	-0,5	4	-0,2	0,5	4	-0,5
4	-0,2	0,5	4	-0,5	2	0,6	0	1,6	-3,2	2	0,6	0	1,6	-3,2

$$\Rightarrow \left(\begin{array}{ccc|ccc} 0 & 0 & 1 & 0 & 0 & 0 & 2 & 0 & 2 & 0,6 \\ 1 & 0 & 0 & 0 & 0 & 3 & 3 & 3 & 4 & -2 \\ 0 & 0 & 0 & 1 & 0 & 0 & 5 & 5 & 4 & 2 \\ 0 & 1 & 0 & 0 & 0 & -1 & -2 & 3,4 & -1 & \end{array} \right)$$

$$= \underbrace{\left(\begin{array}{cccc|cccc} 1 & 0 & 0 & 0 & 5 & 5 & 4 & 2 \\ 0,4 & 1 & 0 & 0 & 0 & -2 & 0,4 & -0,2 \\ -0,2 & 0,5 & 1 & 0 & 0 & 0 & 4 & -0,5 \\ 0,6 & 0 & 0,4 & 1 & 0 & 0 & 0 & -3 \end{array} \right)}_L \underbrace{\left(\begin{array}{cccc} 2 & 0 & 2 & 0,6 \\ 3 & 3 & 4 & -2 \\ 5 & 5 & 4 & 2 \\ -1 & -2 & 3,4 & -1 \end{array} \right)}_R$$

Matlab-Code:

```
[n,n] = size(A);
p = 1:n;
for k = 1:n
    [i,j] = max(abs(A(p(k:n),k)));
    j = j + (k-1);
    p(k,j) = p(j,k);
    I = k+1:n;
    A(p(I),k) = A(p(I),k)/A(p(k),k);
    A(p(I),I) = A(p(I),I) - A(p(k),k)*A(p(k),I);
end
```

3.5 Cholesky-Zerlegung

Sei $A \in \mathbb{R}^{n \times n}$ symmetrisch und positiv definit, dann existiert eine rechte obere Dreiecksmatrix R mit

$$A = R^T R$$

3.5.1 Rekursiver Algorithmus zur Berechnung von R:

- Ersetze a_{11} durch $\sqrt{a_{11}}$
- Ersetze alte Einträge unter a_{11} durch 0
- Ersetze alte Einträge rechts von a_{11} durch $\frac{a_{1j}}{a_{11}}$
- Beeide die Funktion, falls $n == 1$
- Um den inneren Teil der Matrix zu berechnen ($A(2 : n, 2 : n)$), rufe die Funktion mit folgender Matrix auf:
 $A(2 : n, 2 : n) - A(1, 2 : n)^T \cdot A(1, 2 : n)$

Die entstandene Matrix stellt dann R dar.

Aufwand für Zerlegung: $\frac{1}{2}n^3$ Flops

3.6 Householder-Spiegelung

Die Spiegelung \tilde{x} von $x \in \mathbb{R}^n$ an der Hyperebene E_v senkrecht zu $v \in \mathbb{R}^n$ heißt Householder-Spiegelung. Es gilt:

$$\tilde{x} = \underbrace{\left(I_n - \frac{2vv^T}{\|v\|^2} \right)}_{H_v \in \mathbb{R}^{n \times n}} \cdot x</$$

```
function B = Qmult_householder(A,B)
[m,n] = size(A);
for k = 1:min(m-1,n)
    v = [1; A(k+1:end,k)];
    B(k:end,:) = B(k:end,:) - (2/(v'*v))*v*(v'*B(k:end,:));
end
```

```
Matlab-Code (LGS Ax = b lösen):
A = QR_householder(A);
x = rsub(triu(A), Qmult_householder(A,b));
```

4 Ausgleichsprobleme

Seien Messpunkte $t_i, b_i \in \mathbb{R} \times \mathbb{R}, i = 1, \dots, m$ gegeben. Ziel: Bestimme die n Parameter x_1 bis x_n , sodass gilt:

$$b_i \approx \varphi(t_i, x), \quad i = 1, \dots, m$$

Falls φ linear in x ist, so ist x die Lösung eines überbestimmten GLS:

$$\begin{pmatrix} b_1 \\ \vdots \\ b_m \end{pmatrix} \approx A x = \begin{pmatrix} a(t_1)^T \\ \vdots \\ a(t_m)^T \end{pmatrix} x$$

4.1 Lineare Ausgleichsproblem

Bestimme $x \in \mathbb{R}^n$ zu $A \in \mathbb{R}^{m \times n}$ und $b \in \mathbb{R}^m$, sodass gilt: $\|b - Ax\|_2^2 = \min$

4.2 Lösen mit Normalgleichung

Für ein Polynom $b = f(t) = x_0 + x_1 t + \dots + x_n t^n$ als Ausgleichskurve gilt:

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

$$A = \begin{pmatrix} 1 & t_1 & t_1^2 & \dots & t_1^n \\ 1 & t_2 & t_2^2 & \dots & t_2^n \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 1 & t_m & t_m^2 & \dots & t_m^n \end{pmatrix}$$

4.3 Lösen mit QR-Zerlegung

Sei eine QR-Zerlegung gegeben mit

$$Q^T b = b^{(q+1)} = \begin{pmatrix} b_1 \\ b_2 \end{pmatrix}, \quad R = Q^T A = A^{(q+1)} = \begin{pmatrix} \tilde{R} \\ 0 \end{pmatrix}$$

mit $R \in \mathbb{R}^{n \times n}, b_1 \in \mathbb{R}^n, b_2 \in \mathbb{R}^{m-n}$.

Dann gilt für das Minimierungsproblem:

$$\|b - Ax\|_2^2 = \|(Q^T(b - Ax))\|_2^2 = \|Q^T b - Q^T A x\|_2^2$$

$$= \left\| \begin{pmatrix} b_1 \\ b_2 \end{pmatrix} - \begin{pmatrix} \tilde{R} \\ 0 \end{pmatrix} x \right\|_2^2 = \|b_1 - R x\|_2^2 + \|b_2\|_2^2$$

Somit folgt

$$\|b_1 - \tilde{R}x\|_2^2 + \|b_2\|_2^2 = \min_x \Leftrightarrow \tilde{R}x = b_1$$

5 Fixpunktiteration

Ziel: Gesucht wird ein Fixpunkt $x^* \in X$ der Abbildung $\varphi : X \rightarrow X$:

$$\varphi(x^*) = x^*$$

- Ein FP x^* heißt stabil, falls $\|\varphi'(x^*)\| < 1$
- Ein FP x^* heißt instabil/abstoßend, falls $\|\varphi'(x^*)\| > 1$

5.1 Kontraktion

Eine (Selbst-)Abbildung $\varphi : X \rightarrow X$ heißt Kontraktion, falls es ein festes $0 \leq L < 1$ gibt mit:

$$\|\varphi(x) - \varphi(y)\| \leq L \cdot \|x - y\|, \quad \forall x, y \in X \quad (\text{Lipschitz-stetig})$$

Ist $\varphi : X \rightarrow X$ stetig differenzierbar, so gilt:

$$L = \sup_{x \in X} \|\varphi'(x)\| = \sup_{x \in X} \|J_\varphi(x)\|$$

5.2 Banach'scher Fixpunktsatz

Sei X abgeschlossen und $\varphi : X \rightarrow X$ (Selbstabbildung) eine Kontraktion. Dann besitzt φ einen eindeutigen Fixpunkt $x^* \in X$ und die Iteration

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

konvergiert für jeden Startwert $x_0 \in X$ gegen x^* . Außerdem gelten folgende Abschätzungen:

$$\|x_n - x^*\| \leq \frac{L^n}{1-L} \|x_1 - x_0\| \quad \text{und} \quad \|x_n - x^*\| \leq \frac{L}{1-L} \|x_n - x_{n-1}\|$$

A-Priori A-Posteriori

5.3 Konvergenzgeschwindigkeit

Die Konvergenz der Folge (x_k) ist von der Ordnung p , wenn gilt:

$$\|x_{k+1} - x^*\| \leq C \|x_k - x^*\|^p, \quad \forall k = 0, 1, \dots$$

Falls $\varphi : X \rightarrow X$ zweimal stetig diffbar ist mit FP x^* und $\varphi'(x^*) = 0$, dann konvergiert die Iteration $x_{k+1} = \varphi(x_k)$ mindestens lokal quadratisch.

6 Iterative Löser für LGS

6.1 Stationäre Fixpunktiteration

Idee: Zerlege A additiv in $A = B - C$ mit $\det(B) \neq 0$, dann gilt:

$$Ax = b \Leftrightarrow Bx = b + Cx$$

$$\Leftrightarrow x = B^{-1}b + B^{-1}Cx = \varphi(x)$$

$$\Rightarrow x^{(k+1)} = \varphi(x^{(k)}) = B^{-1}b + B^{-1}Cx^{(k)}$$

$$= x^{(k)} + B^{-1}(b - Ax^{(k)})$$

$$\varphi(x) = Nb + Mx^{(k)}$$

Sei $M \in \mathbb{R}^{n \times n}$. Dann ist $\|M\| < 1$ für eine Operatornorm $\|\cdot\|$ hinreichend für die Konvergenz des Iteration $\varphi(x) = Nb + Mx$.

6.1.1 Dämpfung

Durch Dämpfung der FP-Iteration mit $\omega \in (0, 1)$ können die verschiedenen Verfahren noch beschleunigt werden:

$$x^{(k+1)} = \omega \cdot (Nb + Mx^{(k)}) + (1 - \omega) \cdot x^{(k)}$$

$$= \omega \cdot Nb + [\omega \cdot M + (1 - \omega) \cdot I] \cdot x^{(k)}$$

Falls $M \in \mathbb{R}^{n \times n}$ nur reelle Eigenwerte $\lambda_1 \leq \dots \leq \lambda_n < 1$ besitzt, dann gilt

$$\omega_{opt} = \frac{2}{2 - \lambda_1 - \lambda_n}$$

6.2 Jacobi-Verfahren

Zerlege A additiv in eine Diagonalmatrix D und obere/untere Dreiecksmatrizen R und L :

$$A = D - (L + R)$$

Dann lautet das Jacobi-Verfahren:

$$x^{(k+1)} = D^{-1}b + D^{-1}(L + R) x^{(k)} = D^{-1} \cdot [b + (L + R) \cdot x^{(k)}]$$

6.2.1 Konvergenz

Das Jacobi-Verfahren konvergiert, falls eine der beiden folgenden Bedingungen erfüllt ist:

- A ist strikt diagonaldominant: $|a_{ii}| > \sum_{i \neq j} |a_{ij}|, \quad \forall i = 1, \dots, n$
- Für den Spektralradius gilt: $\rho(D^{-1}(L + R)) = \rho(M) = \max |\lambda_i(M)|, i = 1, \dots, n < 1$

6.3 Gauß-Seidel-Verfahren

Zerlege A additiv in eine Diagonalmatrix D und obere/untere Dreiecksmatrizen R und L :

$$A = (D - L) - R$$

Dann lautet das Gauß-Seidel-Verfahren:

$$x^{(k+1)} = \underbrace{(D - L)^{-1}b}_N + \underbrace{(D - L)^{-1}R}_M x^{(k)} = (D - L)^{-1} \cdot (b + Rx^{(k)})$$

Aufwand: $2n^2$ Flops

6.3.1 Konvergenz

Das Gauß-Seidel-Verfahren konvergiert, falls eine der folgenden Bedingungen erfüllt ist:

- A ist strikt diagonaldominant
- A ist symmetrisch und positiv definit
- Für den Spektralradius gilt: $\rho((D - L)^{-1}R) = \rho(M) = \max |\lambda_i(M)|, i = 1, \dots, n < 1$

7 Nichtlineare Gleichungen

7.1 Lösbarkeit

Sei $f : X \rightarrow \mathbb{R}^n$ stetig differenzierbar und $x^* \in X$ mit $f(x^*) = 0$. Falls $\det(f'(x^*)) \neq 0$, so ist x^* lokal eindeutig, d.h. \exists Umgebung U von x^* , sodass $x \in U, f(x) = 0 \Rightarrow x = x^*$.

7.2 Kondition

Für die absolute Kondition des Problems $F : f \rightarrow x^*$ bzgl. einer Norm $\|\cdot\|$ gilt:

$$\kappa = \|(f'(x^*))^{-1}\|$$

7.3 Bisektionsverfahren

7.3.1 Algorithmus

$x_0 = \frac{1}{2}(a_0 + b_0)$
 Für $k = 0, 1, \dots$:
 STOP, falls $f(x_k) = 0$
 $a_{k+1} = a_k, b_{k+1} = x_k$, falls $f(a_k)f(x_k) < 0$
 $a_{k+1} = x_k, b_{k+1} = b_k$, falls $f(x_k)f(b_k) < 0$
 $x_{k+1} = \frac{1}{2}(a_{k+1} + b_{k+1})$
 STOP, falls $|a_{k+1} - b_{k+1}| < 2 \cdot \text{TOL}$

Globale Konvergenz:

$$\|x_k - x^*\| \leq \frac{1}{2} \|x_k - a_0\| = \frac{1}{2^{k+1}} \|b_0 - a_0\|$$

7.4 Newton-Verfahren

Sei $f : X \rightarrow \mathbb{R}$ zweimal stetig differenzierbar, $f(x^*) = 0, f'(x^*) \neq 0$, dann konvergiert das Newton-Verfahren

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

lokal quadratisch.

7.4.1 Mehrdimensional

Sei $f : X \rightarrow \mathbb{R}^n, X \subset \mathbb{R}^n$ zweimal stetig differenzierbar, $f(x^*) = 0$, dann gilt:

$$x_{k+1} = x_k - J_x^{-1}(x_k) f(x_k)$$

8 Optimierung

8.1 Optimalitätsbedingungen

Definitionen:

- $C^m(x) = \{f : X \rightarrow \mathbb{R}^m$ m -mal stetig differenzierbar}
- Sei $f \in C^1(x)$ und $\nabla f(x) = 0$ für ein $x \in X$. Dann heißt x **stationärer Punkt**.
- Sei $X \subset \mathbb{R}^m$ offen, $f \in C^1(x)$, x^* lokales Minimum. Dann ist x^* stationärer Punkt mit $H_f(x^*) = \nabla^2 f(x^*)$ positiv definit, dann ist x^* ein **lokales Minimum**. (positive Definitheit ist hinreichend, aber nicht unbedingt notwendig)
- Sei $X \subset \mathbb{R}^n$ offen, $f \in C^2(x)$, x^* stationärer Punkt mit $H_f(x^*) = \nabla^2 f(x^*)$ negativ definit, dann ist x^* ein **lokales Maximum**. (negative Definitheit ist hinreichend, aber nicht unbedingt notwendig)
- Sei $X \subset \mathbb{R}^n$ offen, $f \in C^2(x)$, x^* stationärer Punkt mit $H_f(x^*) = \nabla^2 f(x^*)$ indefinit, dann ist x^* ein **Sattelpunkt**.

8.2 Newton-Verfahren

Sei $f \in C^2(x)$. Gesucht sei die Lösung von $\nabla f(x) = 0$.

$$x_{k+1} = x_k - H_f(x_k)^{-1} \nabla f(x_k); \quad H_f(x) = \begin{pmatrix} \partial_{x_1 x_1} f(x) & \dots & \partial_{x_1 x_n} f(x) \\ \vdots & \ddots & \vdots \\ \partial_{x_n x_1} f(x) & \dots & \partial_{x_n x_n} f(x) \end{pmatrix}$$

Das Iterationsverfahren besitzt lokal quadratische Konvergenz zu einem stationären Punkt x^* von f , falls $H_f(x^*)$ invertierbar ist.

8.3 Abstiegsverfahren

Definition:

- $d \in \mathbb{R}^n$ heißt **Abstiegsrichtung** von f an der Stelle x , falls $\exists \delta > 0$, sodass gilt: $f(x + sd) < f(x) \quad \forall s \in (0, \delta]$

8.3.1 Algorithmus

Wähle $x^{(0)}$
 Für $k = 0, 1, \dots$:
 STOP, falls $\nabla f(x^{(k)}) \approx 0$
 Bestimme Abstiegsrichtung $d^{(k)}$ für f in $x^{(k)}$
 Bestimme Schrittweite $s_k > 0$ mit $f(x^{(k)} + s_k d^{(k)}) < f(x^{(k)})$
 Setze $x^{(k+1)} = x^{(k)} + s_k d^{(k)}$

8.3.2 Gradientenverfahren

Wähle im obigen Algorithmus: $d^{(k)} = -\nabla f(x^{(k)})$

Bestimmung der Schrittweite (2 Möglichkeiten):

- 1) "Exakte Schrittweite": $\min_{s > 0} f(x^{(k)} + s d^{(k)})$
- 2) "Armijo-Schrittweite":
 Wähle Parameter $\sigma \in (0, \frac{1}{2})$
 Setze $s = 1$
 Für $l = 1, 2, \dots$:
 Falls $f(x^{(k)} + s d^{(k)}) - f(x^{(k)}) \leq \sigma \cdot \nabla f(x^{(k)})^T d^{(k)}$:
 Akzeptiere Schrittweite: $s_k = s$
 Sonst: $s = \frac{s}{2}$

Dieses Verfahren konvergiert gegen einen stationären Punkt von f oder es erzeugt eine Folge $\{x^{(k)}\}_{k \in \mathbb{N}}$, für die gilt:

- $f(x^{(k+1)}) < f(x^{(k)}) \quad \forall k$ und
- alle Häufungspunkte sind stat. Punkte von f

8.4 Globalisiertes Newton-Verfahren

Wähle $x^{(0)} \in \mathbb{R}^n$ und $\sigma \in (0, \frac{1}{2}), \rho > 0$.
 Für $k = 0, 1, \dots$:
 STOP, falls $\nabla f(x^{(k)}) \approx 0$
 Löse $H_f(x^{(k)}) d^{(k)} = -\nabla f(x^{(k)})$, falls möglich
 Falls Newton-Gleichung nicht lösbar oder $\nabla f(x^{(k)})^T d^{(k)} > -\rho \|\nabla f(x^{(k)})\|^2$
 $d^{(k)} = -\nabla f(x^{(k)})$
 Sonst: $d^{(k)} = d^{(k)}$
 Bestimme Armijo-Schrittweite s_k (siehe oben)
 Setze $x^{(k+1)} = x^{(k)} + s_k d^{(k)}$

9 Funktionentheorie

9.1 Komplexe Differenzierbarkeit

Eine Funktion $f : U \rightarrow \mathbb{C}$ heißt in z_0 komplex differenzierbar, falls der Grenzwert

$$\lim_{z \rightarrow z_0} \frac{f(z) - f(z_0)}{z - z_0} = f'(z_0)$$

existiert.

- Ist f auf ganz U komplex differenzierbar, so heißt f analytisch.
- Kompositionen, Summen, Differenzen, Produkte und Quotienten analytischer Funktionen sind wieder analytisch.
- Potenzreihen sind analytisch in ihrem Konvergenzbereich

Wir schreiben $f(z) = f(x + iy) = F_1(x, y) + i \cdot F_2(x, y)$ und setzen:

$$F(x, y) = \begin{pmatrix} F_1(x, y) \\ F_2(x, y) \end{pmatrix}$$

9.1.1 Cauchy-Riemannsches DGL

f ist genau dann in $z = x + iy$ komplex differenzierbar, falls F in (x, y) differenzierbar ist und folgende DGL erfüllt sind:

$$\partial_x F_1(x, y) = \partial_y F_2(x, y)$$

$$\partial_y F_1(x, y) = -\partial_x F_2(x, y)$$

9.1.2 Folgerungen

Sei $f : U \rightarrow \mathbb{C}$ analytisch und das zugehörige reelle $F : U \rightarrow \mathbb{R}^2$ 2-mal stetig differenzierbar, dann gilt:

$$\Delta F_1(x, y) = \partial_x^2 F_1(x, y) + \partial_y^2 F_1(x, y) = 0$$

$$\Delta F_2(x, y) = \partial_x^2 F_2(x, y) + \partial_y^2 F_2(x, y) = 0$$

9.2 Komplexe Integration

9.2.1 Kurvenintegral

Sei $f : U \rightarrow \mathbb{C}$ stetig, $\gamma \in C^1([a, b], U)$, dann lautet das komplexe Kurvenintegral von f entlang von γ :

$$\int_{\gamma} f(z) dz = \int_a^b f(\gamma(t)) \gamma'(t) dt$$

Mit

$$f(z) = f(x_1 + iy_2) = f_1(z) + i f_2(z); \quad \gamma(t) = \gamma_1(t) + i \gamma_2(t)$$

folgt

$$\int_{\gamma} f(z) dz = \int_a^b \begin{pmatrix} f_1(\gamma(t)) \\ -f_2(\gamma(t)) \end{pmatrix}^T \begin{pmatrix} \gamma_1(t) \\ \gamma_2(t) \end{pmatrix} dt + i \int_a^b \begin{pmatrix} f_2(\gamma(t)) \\ f_1(\gamma(t)) \end{pmatrix}^T \begin{pmatrix} \gamma_1(t) \\ \gamma_2(t) \end{pmatrix} dt$$

Definitionen:

- $U \subset \mathbb{C}$ heißt **zusammenhängend**, falls es $\forall z_1, z_2 \in U$ einen Weg $\gamma : [0, 1] \rightarrow U$ gibt, sodass $\gamma(0) = z_1, \gamma(1) = z_2$.
- $U \subset \mathbb{C}$ heißt **einfach zusammenhängend**, falls das Innere jeder ganz in U verlaufenden geschlossenen Kurve γ $\int_{\gamma} f(z) dz = 0$ gehört.

Sei $U \subset \mathbb{C}$ einfach zusammenhängend, $f : U \rightarrow \mathbb{C}$ analytisch:

- Dann gilt für jede geschlossene Kurve γ , die ganz in U verläuft:

$$\int_{\gamma} f(z) dz = 0$$

- Bei nicht geschlossenen Kurven ist das komplexe Kurvenintegral wegunabhängig.
- Dann ist für jedes $a \in U$

$$F(z) = \int_a^z f(\xi) d\xi$$

eine Stammfunktion von f und es gilt:

$$\int_{z_0}^{z_1} f(\xi) d\xi = F(z_1) - F(z_0)$$

9.2.2 Cauchy-Integralformel

Sei $U \subset \mathbb{C}, f : U \rightarrow \mathbb{C}$ analytisch, γ geschlossen mit Innerem ganz in U , dann gilt für jeden Punkt z im Inneren von γ :

$$f(z) = \frac{1}{2\pi i} \int_{\gamma} \frac{f(\xi)}{\xi - z} d\xi$$

9.3 Potenzreihendarstellung analytischer Funktionen

Sei $f : U \rightarrow \mathbb{C}$ analytisch, $\{z - a\} \in \tau \subset U$ für ein $a \in U, \tau > 0$, dann gilt für $|z - a| < \rho < \tau$:

$$f(z) = \sum_{n=0}^{\infty} c_n (z - a)^n$$

$$\text{mit } c_n = \frac{1}{2\pi i} \int_{|\xi - a| = r} \frac{f(\xi)}{(\xi - a)^{n+1}} d\xi$$

Jede beschränkte analytische Funktion $f : \mathbb{C} \rightarrow \mathbb{C}$ ist konstant.

9.4 Laurent-Reihen und Singularitäten

Idee: Entwickle $f : \mathbb{C} \setminus \{z_0\} \rightarrow \mathbb{C}$ analytisch in einer Reihe um die Singularität z_0 :

$$f(z) = \sum_{n=-\infty}^{\infty} c_n (z - z_0)^n = \underbrace{\sum_{n=-\infty}^{-1} c_n (z - z_0)^n}_{\text{Hauptteil (HT)}} + \underbrace{\sum_{n=0}^{\infty} c_n (z - z_0)^n}_{\text{Nebenanteil (NT)}}$$

Definitionen:

- Sei $U \subset \mathbb{C}, f : U \rightarrow \mathbb{C}$ analytisch. Dann heißt $z_0 \in U$ **Nullstelle der Ordnung m** , falls $f(z_0) = f'(z_0) = \dots = f^{(m-1)}(z_0) = 0$ und <