

Numerische Mathematik I

Wintersemester 2007/08

Dr. Serge Kräutle

geT_EXt von A. Schleich und Ch. Basting



Vorlesungsskript

Department für Mathematik

AM1

Friedrich–Alexander–Universität Erlangen–Nürnberg

3 Nichtlineare Gleichungen

Problemstellung:

Definition 3.1 Sei $(X, \|\cdot\|)$ ein normierter Vektorraum, $U \subset X$, $\Phi : U \rightarrow X$, $b \in X$.
Das Problem

$$\text{“Finde } x \in U \text{ mit } \Phi(x) = 0\text{”} \tag{3.1}$$

heißt (allgemeines, nichtlineares) Nullstellenproblem; eine Lösung heißt Nullstelle von Φ .
Das Problem

$$\text{“Finde } x \in U \text{ mit } \Phi(x) = x\text{”} \tag{3.2}$$

heißt Fixpunktproblem; eine Lösung heißt Fixpunkt von Φ .

Ferner betrachten wir noch die allgemeine nichtlineare Gleichung (“Gleichungssystem” im Fall $X = \mathbb{R}^n$)

$$\text{“Finde } x \in U \text{ mit } \Phi(x) = b\text{”} \tag{3.3}$$

Die Probleme (3.1), (3.2), (3.3) sind “gleich schwer” bzw. “äquivalent” in dem Sinne, dass jedes Problem des einen Typus in ein Problem jedes anderen Typus umgewandelt werden kann:

- (3.1) \rightarrow (3.2): Setze z.B.: $\tilde{\Phi}(x) := \Phi(x) + x$
(auch $\tilde{\Phi}(x) := \alpha\Phi(x) + x$, $\alpha \in \mathbb{R} \setminus \{0\}$ ist möglich)
- (3.2) \rightarrow (3.3): Setze z.B.: $\tilde{\Phi}(x) := \Phi(x) - x + b$
- (3.3) \rightarrow (3.1): Setze z.B.: $\tilde{\Phi}(x) := \Phi(x) - b$

Daher können wir uns im folgenden zunächst auf Fixpunktprobleme konzentrieren. Im allgemeinen Fall (wenn also f echt nichtlinear ist) gibt es keinen Algorithmus, der nach endlich vielen Schritten (3.2) löst. Wir werden stattdessen ein *iteratives* Lösungsverfahren der Form

$$x^{(n+1)} := \Phi(x^{(n)})$$

herleiten. Wichtigstes Hilfsmittel: Der Fixpunktsatz vom Banach.

3.1 Fixpunktiterationen

Satz 3.2 (Fixpunktsatz von Banach, 1922) Sei $(X, \|\cdot\|)$ ein Banach-Raum, sei $U \subset X$ eine abgeschlossene Teilmenge; Sei $\Phi : U \rightarrow X$ mit

$$\Phi(U) \subseteq U \quad [\Phi \text{ heißt selbstabbildend}]. \tag{3.4}$$

Es existiere ein $0 < k < 1$ so dass

$$\|\Phi(x) - \Phi(y)\| \leq k\|x - y\| \quad \forall x, y \in U \tag{3.5}$$

[“Kontraktionseigenschaft”].

Dann gilt:

1. Es gibt genau einen Fixpunkt $x^* \in U$ von Φ .
2. Für beliebigen Startwert $x^{(0)} \in U$ konvergiert die Folge

$$x^{(n+1)} := \Phi(x^{(n)}) \tag{3.6}$$

gegen x^* .

3. Es gelten

$$\|x^{(n)} - x^*\| \leq \frac{k}{1-k} \|x^{(n)} - x^{(n-1)}\| \quad \text{a posteriori-Fehlerabschätzung} \tag{3.7}$$

$$\leq \frac{k^n}{1-k} \|x^{(1)} - x^{(0)}\| \quad \text{a priori-Fehlerabschätzung} \tag{3.8}$$

Bemerkung 3.3 :

- (3.6) heißt Fixpunktiteration, k heißt Kontraktionskonstante; der Wert von k ist entscheidend für die Konvergenzgeschwindigkeit.
- Oft wird der Satz mit $U = X$ angewendet. (3.4) ist dann trivialerweise erfüllt.
- Der Satz lässt sich auf vollständige metrische Räume übertragen.
- Über die Probleme aus Definition 3.1 im \mathbb{R}^n hinaus wird der Satz auch z.B. angewendet, um die Existenz und Eindeutigkeit von Lösungen von Anfangswertproblemen von gewöhnlichen Differenzialgleichungen $y'(t) = f(t, y(t))$, $y(t) = y$, bei Lipschitzstetigem f , zu zeigen; dabei $(X, \|\cdot\|) = (\mathcal{C}([a, b]), \|\cdot\|_\infty)$




Abbildung 3: konvergente Fixpunktiteration, $X = \mathbb{R}$




Abbildung 4: divergente Fixpunktiteration, $X = \mathbb{R}$




Abbildung 5: konvergente Fixpunktiteration, $X = \mathbb{R}$

Beweis : Die Folge $(x^{(n)})$ ist wegen (3.4) wohldefiniert. Wir zeigen: $(x^{(n)})_{n \in \mathbb{N}}$ ist CAUCHY-Folge:

$$\begin{aligned}
 \|x^{(n+1)} - x^{(n)}\| &\stackrel{\text{Def. Folge}}{=} \|\Phi(x^{(n)}) - \Phi(x^{(n-1)})\| \stackrel{\text{Kontraktion}}{\leq} k \|x^{(n)} - x^{(n-1)}\| \\
 &\stackrel{\text{Def. Folge}}{\leq} k \|\Phi(x^{(n-1)}) - \Phi(x^{(n-2)})\| \stackrel{\text{Kontraktion}}{\leq} k^2 \|x^{(n-1)} - x^{(n-2)}\| \\
 &\dots \\
 &\leq k^n \|x^{(1)} - x^{(0)}\| \\
 \Rightarrow \|x^{(n+l)} - x^{(n)}\| &\stackrel{\text{Teleskopsumme}}{\leq} \|x^{(n+l)} - x^{(n+l-1)}\| + \dots + \|x^{(n+1)} - x^{(n)}\| \\
 &\stackrel{(3.9)}{\leq} (k^{n+l-1} + \dots + k^n) \|x^{(1)} - x^{(0)}\| \\
 &\leq k^n \left(\sum_{i=0}^{\infty} k^i \right) \|x^{(1)} - x^{(0)}\| \\
 &= \underbrace{k^n \frac{1}{1-k} \|x^{(1)} - x^{(0)}\|}_{\leq \epsilon \text{ f\"ur } n \text{ hinreichend gro\ss}} \Rightarrow \text{CAUCHY-Eigenschaft}
 \end{aligned} \tag{3.9}$$

Da $(X, \|\cdot\|)$ vollständig und $U \subset X$ abgeschlossen, ist $(x^{(n)})$ konvergent gegen ein $x^* \in U$. Wir zeigen: x^* ist Fixpunkt:

$$x^* = \lim_{n \rightarrow \infty} x^{(n)} \stackrel{\text{Def. Folge}}{=} \lim_{n \rightarrow \infty} \Phi(x^{(n-1)}) \stackrel{\Phi \text{ stetig}}{=} \Phi(\lim_{n \rightarrow \infty} x^{(n-1)}) = \Phi(x^*) \Rightarrow x^* \text{ ist Fixpunkt}$$

Eindeutigkeit: Angenommen $x^*, x^{**} \in U$ seien Fixpunkte, dann:

$$\begin{aligned} \Rightarrow \|x^* - x^{**}\| &\stackrel{\text{Fixpunkt}}{=} \|\Phi(x^*) - \Phi(x^{**})\| \stackrel{\text{Kontraktion}}{\leq} k \|x^* - x^{**}\| \\ &\stackrel{k < 1}{\Rightarrow} \|x^* - x^{**}\| = 0 \Rightarrow x^* = x^{**} \end{aligned}$$

Zu den Abschätzungen (3.7) und (3.8):

$$\begin{aligned} \|x^{(n)} - x^*\| &\stackrel{\text{Def. Folge}}{=} \|\Phi(x^{(n-1)}) - \Phi(x^*)\| \stackrel{\text{Kontraktion}}{\leq} k \|x^{(n-1)} - x^*\| \quad (3.10) \\ &\leq k \cdot (\|x^{(n-1)} - x^{(n)}\| + \|x^{(n)} - x^*\|) \\ \Rightarrow \|x^{(n)} - x^*\| &\leq \frac{k}{1-k} \|x^{(n-1)} - x^{(n)}\| \rightsquigarrow (3.7) \\ &\stackrel{(3.9)}{\leq} \frac{k^n}{1-k} \|x^{(1)} - x^{(0)}\| \rightsquigarrow (3.8) \end{aligned}$$

□

Lemma 3.4 Eine stetig differenzierbare Abbildung $\Phi : U \rightarrow \mathbb{R}$, $U \subset \mathbb{R}$ offenes Intervall, ist genau dann Lipschitz-stetig mit Lipschitz-Konstante $k > 0$, d.h.

$$|\Phi(x) - \Phi(y)| \leq k|x - y| \quad \forall x, y \in U, \quad (3.11)$$

wenn

$$|\Phi'(x)| \leq k \quad \forall x \in U. \quad (3.12)$$

Beweis:

„ \Leftarrow “ Es gelte (3.12). Der Mittelwertsatz liefert: $\Phi(x) = \Phi(y) + \Phi'(\zeta)(x - y)$, $\zeta \in U$.

$$\Rightarrow |\Phi(x) - \Phi(y)| \leq |\Phi'(\zeta)| \cdot |x - y| \leq k \cdot |x - y|$$

„ \Rightarrow “ Sei (3.12) falsch, es gibt also $x \in U$ mit $|\Phi'(x)| > k$. Dann gibt es (da f' stetig) eine zusammenhängende Umgebung $\tilde{U} \subseteq U$ von x , so dass $|\Phi'(\zeta)| > k \quad \forall \zeta \in \tilde{U}$.

$$\Rightarrow \text{für } y \in \tilde{U}, y \neq x \quad |\Phi(x) - \Phi(y)| = |\Phi'(\zeta)| \cdot |x - y| > k|x - y|$$

□

Für stetig differenzierbares $\Phi : U \rightarrow \mathbb{R}$ kann die Bedingung (3.5) also durch die einfacher überprüfbare Bedingung

$$k := \sup_{x \in U} |\Phi'(x)| < 1 \quad (3.13)$$

ersetzt werden.

Beispiel 3.5 Gesucht sind die Nullstellen von $f(x) = \cos x - 2x$ also $X = \mathbb{R}$, $U = \mathbb{R}$. Umwandlung in ein Fixpunktproblem:

erster Versuch:

$$\begin{aligned} \cos x - 2x &\stackrel{!}{=} 0 & | & +x \\ \underbrace{\cos x - x}_{=: \Phi(x)} &= x \end{aligned}$$

Prüfe die Kontraktionseigenschaft. Wegen $\Phi \in \mathcal{C}^1(\mathbb{R}) \Rightarrow$ Lemma 3.4 ist anwendbar:

$$\Phi'(x) = -(\sin x + 1)$$

Erfüllt *nicht* (3.13)! Problem! Kann diese Problem durch Wahl von kleinerem $U \subsetneq \mathbb{R}$ behoben werden?

Wir erwarten Nullstelle von f im Bereich $[0, \frac{\pi}{2}]$, da $f(0) = 1 > 0$, $f(\frac{\pi}{2}) = -\pi < 0$. Aber selbst auf $[0, \frac{\pi}{2}] =: U$ ist $|\Phi'(x)| \geq 1$, da \sin dort größer gleich 0 ist.

neuer Versuch:

$$f(x) = \cos x - 2x \stackrel{!}{=} 0 \quad | \cdot \alpha, \alpha \neq 0, +x \Leftrightarrow \underbrace{\alpha(\cos x - 2x) + x}_{=: \Phi(x)} = x$$

Kontraktionseigenschaft :

$$\Phi'(x) = \overbrace{-\alpha \sin x}^{\in [-\alpha, \alpha]} - 2\alpha + 1 \in [1 - 3\alpha, 1 - \alpha] \stackrel{!}{\subseteq} (-1, 1)$$

Wähle zum Beispiel $\alpha := \frac{1}{2}$. Dann ist $\Phi'(x) \in [-\frac{1}{2}, \frac{1}{2}]$ und damit gilt für die Kontraktionskonstante

$$k = \sup_{x \in U} |\Phi'(x)| \leq \frac{1}{2}$$

($\alpha \in (0, \frac{2}{3})$, damit $k < 1$ gilt).

Der Fixpunktsatz von Banach liefert also: f hat genau eine Nullstelle x^* .

Die Folge $x^{(n+1)} := \Phi(x^{(n)}) = \frac{1}{2} \cos x^{(n)}$ konvergiert gegen x^* mit Kontraktionsrate $k = \frac{1}{2}$ (\sim ca. 3 Iterationsschritte pro gewonnene Dezimalstelle), bei beliebigem Startwert $x^{(0)} \in U = \mathbb{R}$.




Abbildung 7: Wahl von α aus Beispiel 3.5, zweiter Versuch

3.2 Konvergenzordnung von Fixpunktverfahren und das Newton-Verfahren für skalare Nullstellenprobleme

Im Beispiel 3.5 haben wir das Nullstellenproblem $f(x) = 0$ umgewandelt in ein Fixpunktproblem $\Phi(x) = x$. Wir haben

$$\Phi(x) := x + \alpha f(x) \tag{3.14}$$

gewählt. Wie ist $\alpha \in \mathbb{R}$, $\alpha \neq 0$, allgemein zu wählen? Für $\alpha := 1$ wäre die „Kontraktionsrate“

$$k := \sup_{x \in U = \mathbb{R}} |\Phi'(x)| > 1$$

\Rightarrow Divergenz, für $\alpha := \frac{1}{2}$ ist $k = \frac{1}{2} < 1$. Welches α ist optimal? Oder, noch allgemeiner als (3.13): Wie soll Φ (in Abhängigkeit von f) gewählt werden? Bedingungen an Φ :

- (a) **Konsistenz:** x^* soll genau dann Fixpunkt von Φ sein, wenn x^* Nullstelle von f ist.
- (b) **schnelle Konvergenz:** $k := \sup_{x \in U} |\Phi'(x)|$, wobei U eine Umgebung von x^* ist, sollte möglichst klein sein, bzw.
- (b*) **asymptotisch** für $x^{(k)} \approx x^*$, sollte $k^* := |\Phi'(x^*)|$, die sogenannte asymptotische Kontraktionskonstante, möglichst klein sein.

Wenn wir Φ von der Form (3.14) wählen, so ist (a) erfüllt; und für (b) bzw. (b*) wäre $\alpha := \frac{1}{f'(x^*)}$ günstig (falls $f'(x^*) \neq 0$), da dann

$$\Phi(x) = x - \frac{1}{f'(x^*)} f(x) \quad \Rightarrow \quad \Phi'(x^*) = 1 - \frac{f'(x^*)}{f'(x^*)} = 0$$

(optimale asymptotische Kontraktionskonstante).

[Wir können erwarten, dass $\Phi'(x)$ auch in einer Umgebung U von x^* *klein* ist und damit die Kontraktionskonstante k klein ist.]

Aber: x^* ist ja a priori unbekannt, daher ist die Wahl $\alpha := -\frac{1}{f'(x^*)}$ unpraktikabel. Eine praktisch durchführbare Wahl, die um so besser ist, je näher $x^{(n)}$ bei x^* liegt, ist es, bei der Berechnung von $x^{(n+1)}$ aus $x^{(n)}$,

$$\alpha = \alpha(n) := -\frac{1}{f'(x^{(n)})}$$

zu wählen, also:

$$\begin{aligned} \Phi(x) &:= x - \frac{f(x)}{f'(x)} \\ x^{(n+1)} &:= \Phi(x^{(n)}) = x^{(n)} - \frac{f(x^{(n)})}{f'(x^{(n)})} \end{aligned} \tag{3.15}$$

Dann ist

$$\Phi'(x) = 1 - \frac{f'(x)^2 - f(x)f''(x)}{f'(x)^2} = \frac{f(x)f''(x)}{f'(x)^2},$$

und damit $\Phi'(x^*) = 0$ (falls $f'(x^*) \neq 0$).

Diese Iteration zur Bestimmung von Nullstellen von f heißt *NEWTON-Iteration*/ *NEWTON-Verfahren*. Nach obigen Überlegungen erwarten wir für das NEWTON-Verfahren besonders gute Konvergenzeigenschaften. Dies werden wir im folgenden genauer untersuchen (Def. 3.6 - Satz 3.10).

Zuvor noch eine *geometrische* Interpretation des NEWTON-Verfahrens (für skalare Probleme):

Sei $x^{(n)}$ eine Näherung für die Nullstelle x^* von f . Anstatt die Nullstelle von f direkt zu berechnen, wird f approximiert durch eine Funktion \tilde{f} , deren Nullstelle \tilde{x}^* man *leicht* berechnen kann. \tilde{x}^* wird als neue, bessere Approximation $x^{(n+1)}$ an die Nullstelle x^* von f verwendet. Als \tilde{f} nehmen wir die *Tangente* (=Linearisierung von f) an f in der Stelle $x^{(n)}$ (setzt $f \in \mathcal{C}^1$ voraus, außerdem $f'(x^{(n)}) \neq 0$). Steigungsdreieck: $f'(x^{(n)}) = \frac{f(x^{(n)}) - 0}{x^{(n)} - x^{(n+1)}} \Leftrightarrow x^{(n)} - x^{(n+1)} = \frac{f(x^{(n)})}{f'(x^{(n)})} \Leftrightarrow$

(3.15)




Abbildung 8: geometrische Interpretation des NEWTON-Verfahrens

Um das Konvergenzverhalten des NEWTON-Verfahrens beschreiben zu können, sind folgende Definitionen nützlich:

Definition 3.6 Sei $(X, \|\cdot\|)$ ein normierter Vektorraum, $U \subset X$ offen. Eine Folge $x^{(n+1)} := \Phi(x^{(n)})$, $\Phi : U \rightarrow U$ heißt lokal konvergent gegen $x^* \in U$, falls es eine Umgebung $V \subseteq U$ von x^* gibt, so dass für beliebigen Startwert $x^{(0)} \in V$ die Folge gegen x^* konvergiert. Die Folge heißt global konvergent, falls für beliebigen Startwert $x^{(0)} \in U$ die Folge gegen x^* konvergiert.

Wir wissen (Satz 3.2): Unter den Voraussetzungen des Fixpunktsatzes von Banach ist die Fixpunktiteration *global konvergent*.

Definition 3.7 Sei $(X, \|\cdot\|)$ ein normierter Vektorraum, $U \subseteq X$ offen, $x^* \in U$, $x^{(0)} \in U$, $x^{(n+1)} := \Phi(x^{(n)})$, $p \in \mathbb{R}$, $p \geq 1$. Falls es ein $c > 0$ gibt mit

$$\|x^{(n+1)} - x^*\| \leq c \|x^{(n)} - x^*\|^p \quad \forall n \in \mathbb{N} \quad (3.16)$$

und, nur im Fall $p = 1$, zusätzlich $c < 1$ gilt, so heißt die Folge $(x^{(n)})$ (lokal) konvergent von der Ordnung p .

Im Fall $p = 1$ sprechen wir von (lokal) **linearer** Konvergenz.

Im Fall $p = 2$ sprechen wir von (lokal) **quadratischer** Konvergenz.

Im Fall $p = 3$ sprechen wir von (lokal) **kubischer** Konvergenz.

Bemerkung: In Büchern wird das Wort "lokal" in obiger Definition meist weggelassen. Das ist aber irreführend, denn die Bedingung (3.16) impliziert im Allgemeinen nicht für beliebige Startwerte $x^{(0)} \in U$ Konvergenz der Folge $(x^{(n)})$ („globale Konvergenz“), sondern nur für $x^{(0)}$ hinreichend nahe bei x^* („lokale Konvergenz“) (z.B. für $\|x^{(0)} - x^*\| < 1$, wenn $c \leq 1$) siehe dazu auch das folgende Lemma 3.8.

Wir wissen (siehe (3.10) im Beweis des Fixpunktsatzes von Banach): Unter den Voraussetzungen des Fixpunktsatzes ist die Fixpunktiteration global konvergent *von der Ordnung mindestens 1*.

Lemma 3.8 Sei $(X, \|\cdot\|)$ normierter Vektorraum, $U \subset X$ offen, $\Phi : U \rightarrow U$ stetig, $x^{(0)} \in U$ gegeben, $x^{(n+1)} := \Phi(x^{(n)})$, $x^* \in U$, $p \geq 1$, $c > 0$, sowie $c < 1$ falls $p = 1$. Es gelte

$$\|\Phi(x) - x^*\| \leq c\|x - x^*\|^p \quad \forall x \in U \quad (3.17)$$

Dann konvergiert die Iteration lokal (d.h. es gibt eine Umgebung $\tilde{U} \subset U$ von x^* und für alle $x^{(0)} \in \tilde{U}$ konvergiert sie) gegen x^* mit Konvergenzordnung mindestens p , und x^* ist Fixpunkt von Φ .

Beweis : Wähle $r > 0$ so dass die Kugel $B_r(x^*) \subseteq U$ und

$$c \cdot r^{p-1} =: k < 1 \quad (3.18)$$

Es ist $x^{(n)} \in U \quad \forall n \in \mathbb{N}$, und für $x^{(n)} \in B_r(x^*)$ gilt

$$d^{(n+1)} := \|x^{(n+1)} - x^*\| = \|\Phi(x^{(n)}) - x^*\| \stackrel{(3.17)}{\leq} c\|x^{(n)} - x^*\|^p \stackrel{x^{(n)} \in B_r(x^*)}{\leq} cr^p \stackrel{(3.18)}{<} r \quad (3.19)$$

d.h. auch $x^{(n+1)} \in B_r(x^*)$. Falls also der Anfangswert $x^{(0)} \in B_r(x^*) =: \tilde{U}$ gewählt wird, ist die gesamte Folge $(x^{(n)})$ in \tilde{U} . Weiter gilt

$$d^{(n+1)} \stackrel{(3.19)}{\leq} c \cdot \underbrace{\|x^{(n)} - x^*\|^{p-1}}_{\leq r \text{ da } x^{(n)} \in \tilde{U}} \underbrace{\|x^{(n)} - x^*\|}_{=d^{(n)}} \leq cr^{p-1}d^{(n)} \stackrel{(3.18)}{=} kd^{(n)}, \quad k < 1$$

$$\Rightarrow x^{(n)} \rightarrow x^*, \quad x^* = \lim_n x^{(n)} = \lim_n \Phi(x^{(n-1)}) = \Phi(\lim_n x^{(n-1)}) = \Phi(x^*)$$

Die Konvergenzordnung ist (mindestens) p nach (3.19). □

Wir wissen: Fixpunktiterationen konvergieren unter den Voraussetzungen von Satz 3.2 *mindestens linear*. Aus Lemma 3.8 folgt der folgende Satz 3.9, der uns sagt, unter welcher Voraussetzungen an Φ wir sogar Konvergenz p -ter Ordnung der Folge $x^{(n+1)} = \Phi(x^{(n)})$ haben; vgl. die Konstruktionsversuche von Φ am Anfang von Kapitel 3.2, wo wir versucht haben, möglichst gute Konvergenz zu erreichen und so die Wahl $\Phi(x) := x - \frac{f(x)}{f'(x)}$ zur Lösung von $f(x) = 0$ motiviert haben.

Satz 3.9 (Konvergenzordnung von Fixpunktverfahren)

Sei $X = \mathbb{R}$, $U \subset \mathbb{R}$ offen, $\Phi : U \rightarrow U$ p -mal stetig differenzierbar. Sei $x^* \in U$ Fixpunkt von Φ , sei $p \in \mathbb{N}$. Ist

$$\Phi'(x^*) = \dots = \Phi^{(p-1)}(x^*) = 0, \quad \Phi^{(p)}(x^*) \neq 0 \quad \text{im Fall } p > 1$$

bzw.

$$\Phi'(x^*) \neq 0, \quad |\Phi'(x^*)| < 1 \quad \text{im Fall } p = 1$$

dann konvergiert die durch Φ definierte Fixpunktiteration $x^{(n+1)} = \Phi(x^{(n)})$ lokal gegen x^* genau mit Ordnung p , und x^* ist Fixpunkt von Φ .

Beweis : TAYLOR-Entwicklung von Φ um x^* :

$$\Phi(x) = \underbrace{\Phi(x^*)}_{=x^*} + \frac{\Phi^{(p)}(\zeta)}{p!} (x - x^*)^p \quad \forall x \in U \text{ mit } \zeta = \zeta(x) \in U \quad | - x^* \quad (3.20)$$

$$\Rightarrow \quad |\Phi(x) - x^*| \leq c|x - x^*|^p \text{ mit } c := \max_{\zeta \in \tilde{U}} \frac{|\Phi^{(p)}(\zeta)|}{p!}, \quad \tilde{U} \subset U \text{ kompakte Umgebung von } x^*$$

\Rightarrow Lemma 3.8 liefert lokale Konvergenz der Ordnung mindestens p . Angenommen die Ordnung sei höher als p . Dann müsste (3.17) für ein $\tilde{p} > p$ statt p gelten:

$$|\Phi(x) - x^*| \leq c|x - x^*|^{\tilde{p}} \quad \forall x \in U \quad (3.21)$$

Dies kann nicht sein, da

$$\Phi^{(p)}(x^*) \neq 0, \text{ also } \Phi^{(p)}(\zeta) \neq 0 \text{ nach Vor.}$$

in einer Umgebung \tilde{U} von x^* in (3.20), also

$$|\Phi(x) - x^*| \geq \min_{\zeta \in \tilde{U}} |\Phi^{(p)}(\zeta)| |x - x^*|^p \quad \forall x \in \tilde{U},$$

was ein Widerspruch zu (3.21) ist. □

Satz 3.9 im Fall $p = 2$ besagt: Wir bekommen *quadratische* Konvergenz (als Verbesserung der linearen Konvergenz, die allgemein in der Situation des Fixpunktsatzes von Banach gilt) genau dann wenn

$$\Phi'(x^*) = 0 \quad , \quad \Phi''(x^*) \neq 0.$$

Dies wird in der Tat vom NEWTON-Verfahren

$$\Phi(x) = x - \frac{f(x)}{f'(x)}, \quad x^{(n+1)} = \Phi(x^{(n)}), \quad (3.22)$$

wenn $f'(x^*) = 0$, erfüllt:

Satz 3.10 Sei $f \in \mathcal{C}^3(\mathbb{R})$ und x^* eine einfache Nullstelle von f (also $f'(x^*) \neq 0$). Dann ist das NEWTON-Verfahren lokal konvergent, mindestens von Ordnung 2.

Beweis : Wegen der Stetigkeit existiert eine offene Umgebung V von x^* , auf der $f'(x) \neq 0$ ist, d.h. Φ aus (3.22) ist wohldefiniert und stetig auf V , es ist

$$\Phi(x^*) = x^* - \overbrace{\frac{f(x^*)}{f'(x^*)}}{=0} = x^*$$

(Konsistenz des Nullstellenproblems $f(x) = 0$ mit dem Fixpunktproblem $\Phi(x) = x$), es ist

$$\Phi'(x) = 1 - \frac{f'(x)^2 - f(x)f''(x)}{f'(x)^2} = \frac{f(x)f''(x)}{f'(x)^2}, \text{ also } \Phi'(x^*) = 0,$$

und $\Phi''(x)$ existiert und ist stetig.

Nach Satz 3.9 folgt die Behauptung. □

Zur Vorgehensweise bei *mehrfacher* Nullstelle (siehe Übung): Setze $\Phi(x) := x - \gamma \frac{f(x)}{f'(x)}$ wobei $\gamma = p$ die Vielfachheit der Nullstelle ist. Hier für $p = 2$ (= doppelte Nullstellen), also $f(x^*) = f'(x^*) = 0, f''(x^*) \neq 0$ hergeleitet:

$$\begin{aligned}\Phi(x) &:= x - \gamma \frac{f(x)}{f'(x)}, \quad x \neq x^* \\ \lim_{x \rightarrow x^*} \Phi(x) &= x - \gamma \lim_{x \rightarrow x^*} \frac{f'(x)}{f''(x)} = x^*\end{aligned}$$

⇒ Mit der Setzung $\Phi(x^*) := x^*$ wird die Definitionslücke von Φ stetig geschlossen.

$$\Phi'(x) = 1 - \gamma \frac{f'(x)^2 - f(x)f''(x)}{f'(x)^2} = 1 - \gamma + \gamma \frac{f(x)f''(x)}{f'(x)^2}, \quad x \neq x^*$$

Es folgt mit L'HOPITAL:

$$\begin{aligned}\Phi'(x^*) &= \lim_{x \rightarrow x^*} \frac{f(x) - f(x^*)}{x - x^*} = \lim_{x \rightarrow x^*} \frac{x - \gamma \frac{f(x)}{f'(x)} - x^*}{x - x^*} = 1 - \gamma \lim_{x \rightarrow x^*} \frac{f(x)}{f'(x)(x - x^*)} \\ &= 1 - \frac{\gamma}{\lim_{x \rightarrow x^*} \frac{f'(x)(x - x^*)}{f(x)}} = 1 - \frac{\gamma}{\lim_{x \rightarrow x^*} \frac{f''(x)(x - x^*) + f'(x)}{f'(x)}} \\ &= 1 - \frac{\gamma}{1 + f''(x^*) \lim_{x \rightarrow x^*} \frac{x - x^*}{f'(x)}} = 1 - \frac{\gamma}{1 + f''(x^*) \lim_{x \rightarrow x^*} \frac{1}{f''(x)}} \\ &= 1 - \frac{\gamma}{2}\end{aligned}$$

sowie:

$$\begin{aligned}\lim_{x \rightarrow x^*} \Phi'(x) &= 1 - \gamma + \gamma f''(x^*) \lim_{x \rightarrow x^*} \frac{f(x)}{f'^2(x)} = 1 - \gamma + \gamma f''(x^*) \cdot \lim_{x \rightarrow x^*} \frac{f'(x)}{2f'(x)f''(x)} \\ &= 1 - \gamma + \gamma f''(x^*) \cdot \frac{1}{2f''(x^*)} = 1 - \frac{\gamma}{2}.\end{aligned}$$

Also: Φ ist stetig differenzierbar an der Stelle $x = x^*$, und die Forderung

$$\Phi'(x^*) = 1 - \frac{\gamma}{2} \stackrel{!}{=} 0$$

erfordert $\gamma := 2$.

Fazit soweit: Das NEWTON-Verfahren zur Nullstellenbestimmung konvergiert nur dann sicher gegen eine Nullstelle x^* , wenn der Startwert hinreichend nahe bei x^* liegt. Der Konvergenzbereich kann sehr klein sein, Insbesondere wenn Extrem- und Wendepunkte in der Nähe von x^* (zwischen x^* und $x^{(0)}$) liegen: Um sich eine bessere Startlösung $x^{(0)}$ fürs Newton-Verfahren zu verschaffen, kann man zunächst einige Schritte eines anderen Verfahrens (z.B. Bisektion, s. Kapitel 3.4) vorab durchführen, oder gegebenenfalls ein "gedämpftes Newton-Verfahren" durchführen (s. Kapitel 3.3).

Wenn das NEWTON-Verfahren konvergiert, dann extrem schnell. (**lokal quadratische** Konvergenz)




Abbildung 9: NEWTON-Verfahren bei Extrem- und Wendepunkten

3.3 Das Bisektions- und das Sekantenverfahren

Als Alternative zum NEWTON-Verfahren für skalare Nullstellenprobleme gibt es das *Bisektionsverfahren* (= *Intervallhalbierungsverfahren*) sowie das *Sekantenverfahren*.

Bisektionsverfahren : Sei $f : \mathbb{R} \rightarrow \mathbb{R}$ stetig, sei $x^{(0)} < y^{(0)}$ bekannt mit

$$f(x^{(0)}) \cdot f(y^{(0)}) \leq 0$$

$\Rightarrow f$ besitzt eine Nullstelle im Intervall $I^{(0)} := [x^{(0)}, y^{(0)}]$. Man zerteilt das Intervall in

$$[x^{(0)}, m^{(0)}] \text{ und } [m^{(0)}, y^{(0)}], \quad m^{(0)} := \frac{x^{(0)} + y^{(0)}}{2}.$$

In mindestens einem der beiden Intervalle muss eine Nullstelle liegen, man testet also: Falls

$$f(x^{(0)}) \cdot f(m^{(0)}) < 0,$$

dann

$$x^{(1)} := x^{(0)}, \quad y^{(1)} := m^{(0)},$$

andernfalls

$$x^{(1)} := m^{(0)}, \quad y^{(1)} := y^{(0)},$$

und setzt

$$I^{(1)} := [x^{(1)}, y^{(1)}]$$

dies wird iteriert. \Rightarrow Jedes der Intervalle $I^{(n)}$ enthält eine Nullstelle, es ist

$$|I^{(n)}| = |y^{(n)} - x^{(n)}| = \left(\frac{1}{2}\right)^n \cdot |I^{(0)}|$$

d.h. wir wissen

$$|x^* - x^{(n)}| \leq \left(\frac{1}{2}\right)^n |I^0|,$$

$$|x^* - y^{(n)}| \leq \left(\frac{1}{2}\right)^n |I^0|.$$

Deswegen ist das Verfahren (nur) *linear* konvergent. Es wird *Bisektions-* oder *Intervallhalbierungsverfahren* genannt.




Abbildung 10: Bisektionsverfahren

Vorteile:

- Konvergiert *immer* (globale Konvergenz), sobald $x^{(0)}, y^{(0)}$ mit $f(x^{(0)}) \cdot f(y^{(0)}) < 0$ bekannt.
- Braucht kein f' ; Stetigkeit von f reicht.
- Liefert *Einschließung* der Lösung.

Nachteile:

- Nur linear konvergent.
- Nicht auf $X = \mathbb{R}^n$ zu verallgemeinern (vgl. Kapitel 3.4: NEWTON-Verfahren im \mathbb{R}^n)

Das Sekantenverfahren : Man ersetzt im NEWTON-Verfahren die Ableitung $f'(x^{(n)})$ durch einen Differenzenquotienten $\frac{f(x^{(n)})-f(x^{(n-1)})}{x^{(n)}-x^{(n-1)}}$, also

$$\begin{aligned}
 x^{(n+1)} &= x^{(n)} - \frac{f(x^{(n)})}{\frac{f(x^{(n)})-f(x^{(n-1)})}{x^{(n)}-x^{(n-1)}}} = \frac{x^{(n)}(f(x^{(n-1)}) - f(x^{(n)})) - f(x^{(n-1)})(x^{(n)} - x^{(n-1)})}{f(x^{(n)} - f(x^{(n-1)}))} = \\
 &= \frac{x^{(n-1)}f(x^{(n)}) - x^{(n)}f(x^{(n-1)})}{f(x^{(n)}) - f(x^{(n-1)})} \tag{3.23}
 \end{aligned}$$

Es hängt $x^{(n+1)}$ also nicht nur von $x^{(n)}$, sondern auch von $x^{(n-1)}$ ab es handelt sich um ein *Zweischrittverfahren*. Ein solches hat allgemein die Form:

$$x^{(n+1)} = \Phi(x^{(n-1)}, x^{(n)}), \quad \Phi : \mathbb{R}^2 \rightarrow \mathbb{R} \text{ (bzw. } \Phi : X^2 \rightarrow X \text{ im allgemeinen Fall)}$$

Man benötigt also 2 Startwerte $x^{(0)}, x^{(1)}$. Beim Sekantenverfahren ist offensichtlich $f(x^{(0)}) \neq f(x^{(1)})$ erforderlich. Rein formal kann man jedes Zweischrittverfahren in \mathbb{R} (bzw. X) als ein *Einschrittverfahren* in \mathbb{R}^2 (bzw. X^2) auffassen, indem man jeweils Paare von aufeinanderfolgenden Iterationen zusammenfasst und den Übergang

$$\tilde{x}^{(n)} = (x^{(n-1)}, x^{(n)}) \rightarrow (x^{(n)}, x^{(n+1)}) = \tilde{x}^{(n+1)}$$

durch ein




Abbildung 11: geometrische Interpretation des Sekantenverfahrens




Abbildung 12: Probleme bei lokalen Extrema

Lemma 3.11 Sei $f \in \mathcal{C}^2(U)$, $U \subset \mathbb{R}$ offen, $x^* \in U$ einfache Nullstelle, $x^{(0)} \neq x^{(1)}$. Dann ist das Sekantenverfahren lokal konvergent gegen x^* mit Konvergenzordnung

$$p = \frac{1}{2}(1 + \sqrt{5}) \approx 1.618 \quad (\text{„goldener Schnitt“}, \text{Lösung von } p^2 = p + 1).$$

Beweisskizze : (nur für Konvergenzordnung und Wohldefiniertheit)

Da $f'(x^*) \neq 0$, ist f in einer Umgebung $\tilde{U} \subseteq U$ von x^* streng monoton, also injektiv. Wir gehen davon aus, dass wir ein $n_0 \in \mathbb{N}$ haben mit $x^{(n)} \in \tilde{U} \forall n \geq n_0$ (ohne Beweis). Aus

$$x^{(n)} \neq x^{(n-1)}$$

folgt

$$x^{(n+1)} = x^{(n)} - \overbrace{\frac{(x^{(n)} - x^{(n-1)}) f(x^{(n)})}{f(x^{(n)}) - f(x^{(n-1)})}}^{\neq 0} \neq x^{(n)}$$

(es sei denn, $f(x^{(n)}) = 0$, d.h. $x^{(n)} = x^*$, in welchem Falle man abbrechen kann). Per Induktion folgt:

$$x^{(n+1)} \neq x^{(n)} \quad \forall n \geq n_0$$

(bis ggf. zum Abbruch $x^{(n)} = x^*$).

Sei $e^{(n)} := x^{(n)} - x^*$ der Fehler. Subtraktion von x^* von (3.23) ergibt:

$$\begin{aligned} e^{(n+1)} &= x^{(n+1)} - x^* = \frac{x^{(n-1)} f(x^{(n)}) - x^{(n)} f(x^{(n-1)})}{f(x^{(n)}) - f(x^{(n-1)})} - x^* \\ &= \frac{e^{(n-1)} f(x^{(n)}) - e^{(n)} f(x^{(n-1)})}{f(x^{(n)}) - f(x^{(n-1)})}. \end{aligned} \quad (3.24)$$

Unter der Annahme $|e^{(n)}|, |e^{(n-1)}| \ll 1$ bekommen wir näherungsweise mittels TAYLOR-Entwicklung:

$$\begin{aligned} \text{Nenner} &\approx f(x^*) + f'(x^*)(x^{(n)} - x^*) - [f(x^*) + f'(x^*)(x^{(n-1)} - x^*)] \\ &= f'(x^*)(e^{(n)} - e^{(n-1)}) \\ \text{Zähler} &\approx e^{(n-1)} \cdot \left[\underbrace{f(x^*)}_{=0} + f'(x^*)e^{(n)} + f''(x^*)\frac{e^{(n)^2}}{2} \right] \\ &\quad - e^{(n)} \left[\underbrace{f(x^*)}_{=0} + f'(x^*)e^{(n-1)} + f''(x^*)\frac{e^{(n-1)^2}}{2} \right] \\ &= \frac{1}{2} e^{(n-1)} e^{(n)} (e^{(n)} - e^{(n-1)}) f''(x^*) \quad [\text{Annahme: } f''(x^*) \neq 0] \\ \Rightarrow e^{(n+1)} &\approx \frac{f''(x^*)}{2f'(x^*)} e^{(n-1)} e^{(n)} \end{aligned}$$

Insbesondere gilt

$$e^{(n+1)} \leq \underbrace{\left(\left| \frac{f''(x^*)}{2f'(x^*)} \right| + \epsilon \right)}_{=:c} e^{(n-1)} e^{(n)}.$$

Sei $E_{n_0} \geq |e^{(n_0)}|$, $E_{n_0+1} \geq |e^{(n_0+1)}|$, $E_{n+1} \stackrel{(*)}{:=} c E_n E_{n-1}$ ($\Rightarrow |e^{(n)}| \leq E_n \quad \forall n \geq n_0$, d.h. es reicht

E_n abzuschätzen)². Der Ansatz $E_n \stackrel{!}{=} k \cdot E_{n-1}^p$ wird eingesetzt in die Rekursionsgleichung (*):

$$\left. \begin{array}{l} \text{links } E_{n+1} = k \cdot E_n^p = k \cdot (kE_{n-1}^p)^p \\ \text{rechts } cE_n E_{n-1} = ckE_{n-1}^p E_{n-1} \end{array} \right\} \stackrel{!}{=} \Rightarrow k^p E_{n-1}^{p^2} = cE_{n-1}^{p+1} \quad \forall n \geq n_0.$$

Dies wird gelöst durch $k = \sqrt[p]{c}$, $p^2 = p + 1 \Rightarrow p = \frac{1}{2}(1 \pm \sqrt{5})$. Die negative Wurzel kann man ausschließen, indem man die “Anfangswerte” E_{n_0+1} und E_{n_0} so wählt, dass

$$E_{n_0+1} = \frac{1}{2}(1+\sqrt{5})\sqrt[p]{c}E_{n_0}^{\frac{1}{2}(1+\sqrt{5})}.$$

□

Effizienzanalyse :

Durch Zwischenspeicherung der Werte $f(x^{(n)})$ kann man das Sekantenverfahren so formulieren, dass in jedem Iterationsschritt (außer dem ersten) nur *eine* Funktionsauswertung nötig ist. Beim NEWTON-Verfahren dagegen sind Auswertung von f und f' nötig.

Unter der Annahme, dass daher die Durchführung eines NEWTON-Schritts in etwa so lange dauert wie die Durchführung von zwei Schritten des Sekantenverfahrens ($x^{(n)} \rightarrow x^{(n+2)}$), ergibt sich: Fehlerordnung eines Doppel-Schritts des Sekantenverfahrens: $p^2 = p + 1 \approx 2.61 > 2$!

In diesem Sinne kann das Sekantenverfahren durchaus effizienter sein als das NEWTON-Verfahren!

Bewertung :

- + sehr schnell;
- + braucht nur f , nicht f' ;
- + realistische a priori-Abschätzung verfügbar (Stummel & Hainer: Praktische Mathematik);
- keine globale Konvergenz, Probleme bei Extrema;
- Probleme bei mehrfachen Nullstellen möglich (siehe Übung);
- schwierig auf mehrdimensionale Probleme ($X = \mathbb{R}^n$) zu verallgemeinern.

Weitere Verfahren:

- **Regula Falsi:** s. Stummel & Hainer: Praktische Mathematik, Knabner-Skript;
Kann als “Mischung” aus Sekanten und Bisektionsverfahren betrachtet werden. Startet mit $x^{(0)}, x^{(1)}$ so dass $f(x^{(0)}) \cdot f(x^{(1)}) < 0$, $x^{(2)}$ sei Nullstelle der Sekante durch $x^{(0)}, x^{(1)}$; liefert *Einschließung* der Lösung;
aber Vorsicht: im Allgemeinen $|I^{(n)}| = |x^{(n+1)} - x^{(n)}| \not\rightarrow 0$, sondern nur $\text{dist}(x^*, \partial I^{(n)}) \rightarrow 0$ für $n \rightarrow \infty$, im Allgemeinen von erster Ordnung; nur historisch interessant;

²Rekursionsgleichungen der Form $x_n = b + \alpha_1 x_{n-1} + \dots + \alpha_k x_{n-k}$ ($b, \alpha_1, \dots, \alpha_{n-k}$ gegeben) werden auch Differenzgleichungen genannt; für diese gibt es eine Lösungstheorie, die die Struktur der Lösungsmenge charakterisiert. Gleichung (*) hat, wenn logarithmiert, diese Struktur bzgl. der Unbekannten $\ln E_n$. Wir verwenden einen *Ansatz*, um Lösungen auch ohne theoretische Betrachtung zu bestimmen.




Abbildung 13: geometrische Interpretation des Sekantenverfahrens

- **Hybridverfahren**, wie z.B.: Starte mit einschließendem Intervall $x^* \in I^{(0)} = [a^{(0)}, b^{(0)}]$, probiere NEWTON-Schritt; falls das Ergebnis $x^{(1)} \in I^{(0)}$, so akzeptiere; bilde je nach Vorzeichen von $f(x^{(1)})$ das Intervall $I^{(1)} = [a^{(0)}, x^{(1)}]$ bzw. $I^{(1)} = [x^{(1)}, b^{(0)}]$; falls dagegen $x^{(1)} \notin I^{(0)}$, so verwirfe das Ergebnis des NEWTON-Schritts und führe Intervallhalbierungsschritt stattdessen durch.

3.4 Das Newton-Verfahren im \mathbb{R}^m

Für $f : \mathbb{R} \rightarrow \mathbb{R}$ hatten wir das Newton-Verfahren durch *Linearisierung* gewonnen: Die TAYLOR-Entwicklung von f um $x^{(n)}$ (wenn wir uns an die geometrische Konstruktion auf S. 46 erinnern):

$$f(x) = \underbrace{f(x^{(n)}) + f'(x^{(n)}) \cdot (x - x^{(n)})}_{\text{lineare Approximation an } f \text{ (=Tangente!)}} + O(|x - x^{(n)}|^2)$$

$x^{(n+1)}$ wurde durch *Nullsetzen der Linearisierung*

$$f(x^{(n)}) + f'(x^{(n)}) \cdot (x^{(n+1)} - x^{(n)}) \stackrel{!}{=} 0$$

$$\Leftrightarrow x^{(n+1)} = x^{(n)} - \frac{f(x^{(n)})}{f'(x^{(n)})}$$




Abbildung 14: Linearisierung von f

gewonnen. Naheliegend im Fall $f : \mathbb{R}^m \rightarrow \mathbb{R}^m$ ist: Wir verwenden die TAYLOR-Entwicklung

$$f(x) = \underbrace{f(x^{(n)}) + (Jf)(x^{(n)})(x - x^{(n)})}_{\text{lineare Approximation an } f} + O(\|x - x^{(n)}\|^2),$$

und $x^{(n+1)}$ sei wieder die Nullstelle der Linearisierung:

$$f(x^{(n)}) + Jf(x^{(n)})(x^{(n+1)} - x^{(n)}) \stackrel{!}{=} 0 \quad \Leftrightarrow \quad \boxed{x^{(n+1)} = x^{(n)} - Jf(x^{(n)})^{-1}f(x^{(n)})} \quad (3.25)$$

NEWTON-Verfahren im \mathbb{R}^m

Erforderlich: Die Matrix $Jf(x^{(n)})$ muss invertierbar sein. Nach (3.25) scheint es, dass $(Jf(x^{(n)}))^{-1}$ explizit berechnet werden muss. Folgende Umformulierung zeigt, dass es stattdessen reicht, ein lineares Gleichungssystem zu lösen:

Setze $\Delta x^{(n)} := x^{(n+1)} - x^{(n)}$. Dann ist (3.25) $\Leftrightarrow Jf(x^{(n)})\Delta x^{(n)} = -f(x^{(n)})$. Der NEWTON-Schritt (3.25) wurde so äquivalent umgeschrieben zu:

- (1) Löse das Lineare Gleichungssystem $Jf(x^{(n)})\Delta x^{(n)} = -f(x^{(n)})$
 - (2) Setze $x^{(n+1)} := x^{(n)} + \Delta x^{(n)}$
- (3.26)

$\Delta x^{(n)}$ bzw. Teilschritt (2) heißt auch *Newton-Update*.

Das nichtlineare Problem $f(x) = 0$ wurde ersetzt durch eine Folge von *linearen* Problemen.

Aufwandsvergleich: Bei Verwendung von *LR* erfordert (3.26)

$$\underbrace{\frac{1}{3}m^3}_{LR\text{-Zerlegung}} + \underbrace{\frac{m^2}{2} + \frac{m^2}{2}}_{\text{Vor- und Rückwärtseinsetzen}} \doteq \frac{1}{3}m^3 \text{ Additionen und Multiplikationen}$$

Bei (3.25) mit *LR* brauchen wir ebenfalls eine *LR*-Zerlegung für $A := Jf(x^{(n)})$, allerdings brauchen wir zum Aufstellen von A^{-1} m -maliges Vor-/Rückwärtseinsetzen:

$$LRu_j = e_j; \{e_1, \dots, e_n\} = \text{Standard-Basis}$$

Die u_j bilden die Spalten von A^{-1} , insgesamt $\frac{1}{3}m^3 + m \cdot m^2 = \frac{4}{3}m^3$ Operationen!

(3.25) ist also viermal so teuer wie (3.26)! Man kann auch im vektoriellen Fall $X = \mathbb{R}^m$ zeigen, dass das NEWTON-Verfahren (3.25) bzw. (3.26) *lokal quadratisch* konvergent ist; man kann sogar konkrete Angaben über die *Mindestgröße* des Konvergenzbereichs machen (die aber in der Praxis mühsam zu überprüfen sind):

Satz 3.12 (*Konvergenz Newton-Verfahren für $X = \mathbb{R}^m$*)

Sei $U \subset \mathbb{R}^m$ offen und konvex, sei $f : U \rightarrow \mathbb{R}^m$ differenzierbar, sei $x^{(0)} \in U$. Es gebe Zahlen $\alpha, \beta, \gamma, h, r > 0$ mit

$$h := \frac{\alpha\beta\gamma}{2} < 1, \quad r := \frac{\alpha}{1-h}, \quad \overline{B_r}(x^{(0)}) \subseteq U.$$

Ferner sei vorausgesetzt:

- (a) $\|Jf(x) - Jf(y)\| \leq \gamma\|x - y\| \quad \forall x, y \in \tilde{U} := B_{r+\epsilon}(x^{(0)}) \subset U$ für ein $\epsilon > 0$, (“*Jf* ist Lipschitzstetig”).³
- (b) Für alle $x \in \overline{B_r}(x^{(0)})$ existiert $(Jf(x))^{-1}$ und $\|Jf(x)^{-1}\| \leq \beta$
- (c) $\|Jf(x^{(0)})^{-1}f(x^{(0)})\| \leq \alpha$

Dann gilt:

- (1) Die Newton-Iteration (3.25)/(3.26) ist wohldefiniert und $x^{(n)} \in B_r(x^{(0)}) \quad \forall n \in \mathbb{N}$

³Dies ist eine Abschwächung der Voraussetzung “ $f \in \mathcal{C}^3$ ” aus Satz 3.10.

(2) $(x^{(n)})$ konvergiert gegen eine Nullstelle x^* von f .

(3) $\|x^{(n+1)} - x^*\| \leq \frac{\beta\gamma}{2}\|x^{(n)} - x^*\|^2$ (d.h. quadratische Konvergenz)
sowie $\|x^{(n)} - x^*\| \leq \alpha \frac{h^{2^n - 1}}{1 - h^{2^n}} \forall n \in \mathbb{N}$ (a priori-Abschätzung)

Beweis: s. Knabner-Skript S. 107-109

Bemerkung:

- Die Aussagen gelten natürlich erst recht im skalaren Fall $X = \mathbb{R}$.
- Durch die Wahl von $x^{(0)}$ hinreichend nahe bei einer Nullstelle x^* (also $f(x^{(0)})$ hinreichend nahe bei 0) kann $\alpha > 0$ beliebig klein gemacht werden (vgl. (c)), so dass die Bedingungen des Satzes erfüllt werden (\rightarrow lokale Konvergenz).
- Stellt man die Frage nach der *Größe* des Konvergenzbereichs *nicht*, so lässt sich Satz 3.12 vereinfachen zu:

f differenzierbar auf einer Umgebung U von x^* mit $f(x^*) = 0$ und $Jf(x^*)$ invertierbar, Jf L-stetig auf U . Dann ist das NEWTON-Verfahren *lokal quadratisch* konvergent.

Beweis: (sowie weitere Infos:)

P. Deuffhard, Newton methods for nonlinear problems, Springer, 2004, 430 Seiten.

In der Praxis wird man, um das Verfahren auf Konvergenz/Divergenz zu prüfen, weniger die Voraussetzung von Satz 3.12 überprüfen, sondern eher einen sogenannten *Monotonietest* durchführen:

Das Nullstellenproblem $f(x) = 0$ ist offensichtlich äquivalent zum Lösen von:

$$\text{minimiere } g(x) := \|f(x)\|^2 \quad \text{für } x \in \mathbb{R}^n \quad (3.27)$$

Man könnte also einen "Abstieg" $g(x^{(n+1)}) \stackrel{!}{\leq} g(x^{(n)})$ in diesem Funktional erwarten und daher

$$\|f(x^{(n+1)})\| \leq \Theta \|f(x^{(n)})\| \quad \text{für ein } \Theta \in (0, 1) \quad (3.28)$$

testen. Falls (3.28) nicht erfüllt ist, wird für die neue Newton-Iterierte $x^{(n+1)} = x^{(n)} + \Delta x^{(n)}$, so kann man den Newton-Schritt "dämpfen" d.h. man setzt

$$x^{(n+1)} := x^{(n)} + t\Delta x^{(n)} \quad \text{mit } t \in (0, 1], \quad (3.29)$$

wobei ein t so zu finden ist, dass (3.28) erfüllt ist oder besser

$$\|f(x^{(n)} + t\Delta x^{(n)})\| \leq (1 - \Theta t)\|f(x^{(n)})\|$$

erfüllt ist („ARMIJO-Regel“).

In der Praxis probiert man nacheinander $t = 1$, $t = \gamma$, $t = \gamma^2$, ... für ein festes $\gamma \in (0, 1)$, z.B.: $\gamma = 0,5$, aus, bis (3.28) erfüllt wird:




Abbildung 15: “NEWTON-ARMIJO-Regel”

gegeben: Startwert x , Parameter γ , $\tilde{\Theta} \in (0, 1]$, $l_{\max} \in \mathbb{N}$;

```

1: wiederhole {
2:    $t := 1$ 
3:   löse  $Jf(x) \Delta x = -f(x)$ 
4:    $l := 0$ 
5:   solange  $\|f(x + t \Delta x)\| > (1 - t \tilde{\Theta}) \|f(x)\|$ 
      und  $l \leq l_{\max}$ 
6:      $t := t \cdot \gamma$ ;  $l := l + 1$ 
7:     falls  $l > l_{\max}$ : Abbruch
8:      $x := x + t \Delta x$ 
9: } bis Abbruchkriterium erfüllt

```

Dieser Algorithmus (gedämpftes NEWTON-Verfahren nach Armijo) hat im allgemeinen einen größeren Konvergenzbereich als das reine Newton-Verfahren.

Literatur: Kelley: Iterative methods for linear and nonlinear problems

Die Suche nach der geeigneten “Schrittweite” t nennt man auch *Line Search*, da die neue Iteration entlang der durch (3.29) beschriebenen *Geraden* gesucht wird.

Zur Übung: Der Line Search sollte, zumindest für $\Theta \approx 1$, bzw. $\tilde{\Theta} = 0$ sofern $Jf(x)$ immer invertierbar und $x \mapsto Jf(x)$ stetig differenzierbar ist, irgendwann erfolgreich ein t finden, denn die Richtung

$$r := \Delta x^{(n)} = -(Jf(x^{(n)}))^{-1} f(x^{(n)})$$

stellt eine *Abstiegsrichtung* für das Funktional $g(x) = \|f(x)\|^2$ dar, sofern $\|\cdot\| = \|\cdot\|_2$:

$$\begin{aligned} \frac{\partial g(x^{(n)})}{\partial r} &= \langle \nabla g(x^{(n)}), \Delta x^{(n)} \rangle = \langle 2Jf(x^{(n)})^t f(x), -Jf(x^{(n)})^{-1} f(x^{(n)}) \rangle \\ &= -2 \langle f(x^{(n)}), \underbrace{Jf(x^{(n)})Jf(x^{(n)})^{-1}}_{=Id} f(x^{(n)}) \rangle \\ &= -2\|f(x^{(n)})\|^2 \leq 0 \end{aligned}$$

(sogar < 0 solange $f(x^{(n)}) \neq 0$).

Um bei Nichtexistenz von $(Jf(x^{(n)}))^{-1}$ einen Abbruch des Verfahrens zu vermeiden, kann man in diesem Fall die Suchrichtung $\Delta x^{(n)} = (Jf(x^{(n)}))^{-1} f(x^{(n)})$ durch die Richtung des stärksten Abstiegs des Funktionals g , also $-\nabla g(x^{(n)}) = -2Jf(x^{(n)})^t f(x^{(n)})$, multipliziert mit einer geeigneten Schrittweite t , ersetzen (s. Hanke-Bourgeois).

Vereinfachtes NEWTON-Verfahren :

Um Rechenzeiten zu sparen, kann man alle (oder zumindest jeweils 2 oder 3) Newton-Schritte mit ein und derselben Jacobi-Matrix $Jf(x^{(0)})$ durchführen;

$$x^{(n+1)} = x^{(n)} - (Jf(x^{(0)})^{-1} f(x^{(n)}). \quad (3.30)$$

Diese *LR*-Zerlegung der Jacobi-Matrix ist dann nur einmal durchzuführen. Diesen Rechenzeitvorteil erkaufte man sich allerdings mit dem Verlust der quadratischen Konvergenz; die Konvergenz ist nur noch linear (wenn auch mit kleiner Kontraktionskonstanten k , falls $x^{(0)}$ nahe bei x^* ist). Beachte:

(3.30) ist von der Form (3.14), d.h.

$$\Phi(x) = x + \alpha f(x), \text{ mit } \alpha = -Df(x^{(0)})^{-1} \text{ bzw. } \alpha = -\frac{1}{f'(x^{(0)})} \text{ im 1-D-Fall.}$$

Eine weitere Vereinfachungsmöglichkeit ist es, beim Assemblieren (=Aufstellen) der linearen Gleichungssysteme die Ableitung $\frac{\partial f_i}{\partial x_j}$ durch diskrete Differenzenquotienten (vgl. Kapitel 1.5) zu ersetzen, um das Assemblieren zu beschleunigen, da die Ableitungen oft kompliziertere Funktionen sind als die f_i selbst.

4 Iterative Verfahren für lineare Gleichungssysteme. Teil I: Fixpunktverfahren

4.1 Einführung

Wir betrachten das lineare Gleichungssystem $Ax = b$, $A \in \mathbb{C}^{n \times n}$, invertierbar, $b \in \mathbb{C}^n$. Wir wollen dieses Problem auf *Fixpunktgestalt* bringen und per Fixpunktverfahren iterativ lösen. Die Konvergenz wird mit dem Fixpunktsatz von Banach untersucht.

Mögliche elementare Ansätze:

1. (In Anlehnung an den nichtlinearen Fall Kapitel 3.2)

$$\begin{array}{rcl} Ax - b & = & 0 \quad | \cdot (-\omega), \omega \neq 0 \\ (-\omega)(Ax - b) & = & 0 \quad | + x \\ \underbrace{(Id - \omega A)x + \omega b}_{=: \Phi(x)} & = & x \quad \text{Fixpunktgleichung} \end{array}$$

Fixpunktiteration: $x^{(k+1)} := (Id - \omega A)x^{(k)} + \omega b$.

2. Statt mit $\omega \in \mathbb{R}$ kann man in 1. auch mit einer nichtsingulären Matrix $-B \in \mathbb{C}^{n \times n}$ multiplizieren. Man erhält die Fixpunktgleichung

$$\underbrace{(Id - BA)x + Bb}_{=: \Phi(x)} = x$$

und die Fixpunktiteration $x^{(k+1)} := (Id - BA)x^{(k)} + Bb$.

3. Man zerlegt A in einen “wesentlichen Anteil” W und einen “Rest” S :

$$A = W + S. \tag{4.1}$$

W soll dabei leicht invertierbar sein (z.B. bei diagonaldominantem A : $W := \text{diag}(a_{ii})$ und $S := A - W$):

$$Ax = b \Leftrightarrow Wx = -Sx + b \Leftrightarrow x = \underbrace{-W^{-1}Sx + W^{-1}b}_{=: \Phi(x)} \tag{4.2}$$

In allen Fällen hat Φ die Form

$$\Phi(x) = Mx + \tilde{b} \tag{4.3}$$

wobei M, \tilde{b} derart, dass

$$\Phi(x) = x \Leftrightarrow Ax = b$$

(“Konsistenz” des linearen Gleichungssystems und des Fixpunktproblems) (mit $M = Id - \omega A$ bzw. $M = Id - BA$ bzw. $M = -W^{-1}S$). Wann liefert der Fixpunktsatz von BANACH Konvergenz der Fixpunktiteration

$$x^{(k+1)} = \Phi(x^{(k)}) ? \tag{4.4}$$

Wir wollen eine Matrixnorm $\|\cdot\|$ als *Operatornorm* bezeichnen, falls es eine zugehörige Vektornorm $\|\cdot\|$ gibt mit

$$\|A\| = \sup_{0 \neq x \in \mathbb{C}^n} \frac{\|Ax\|}{\|x\|} \quad \forall A \in \mathbb{C}^{n \times n}.$$

Lemma 4.1 Sei $x^{(0)} \in \mathbb{C}^n$, sei $\|\cdot\|$ eine beliebige Norm des \mathbb{C}^n sowie eine verträgliche Matrixnorm (z.B. die zugeordnete Matrixnorm/Operatornorm). Falls $\|M\| < 1$, so ist die Iteration (4.4)/(4.3) konvergent (sogar in jeder beliebigen Norm des \mathbb{C}^n).

Beweis: $\Phi : \mathbb{C}^n \rightarrow \mathbb{C}^n$ ist trivialerweise selbstabbildend.

$$\|\Phi(x) - \Phi(y)\| = \|M(x - y)\| \stackrel{\text{verträglich}}{\leq} \underbrace{\|M\|}_{<1} \|x - y\| \quad \forall x, y \in \mathbb{C}^n$$

Fixpunktsatz
 \Rightarrow
 von BANACH Behauptung

□

Es kann vorkommen, dass für *eine* Matrix M *eine* Matrixnorm $\|M\|_a > 1$, und eine *andere* Matrixnorm $\|M\|_b < 1$ erfüllt (in diesem Fall hätten wir nach Lemma 4.1 Konvergenz!). Welche Norm ist zu prüfen? Kann man (für festes M)

$$\inf\{\|M\| \mid \|\cdot\| \text{ ist zu einer Vektornorm des } \mathbb{C}^n \text{ verträgliche Matrixnorm}\} \quad (4.5)$$

charakterisieren? (Prüfe dann, ob dies < 1 ist!)

Es reicht in (4.5) nur die *Operatornormen* zu betrachten, denn für eine *beliebige* verträgliche Matrixnorm $\|\cdot\|$, d.h. $\|Ax\| \leq \|A\| \cdot \|x\| \quad \forall A, x$, also $\|A\| \geq \frac{\|Ax\|}{\|x\|} \quad \forall A, x \neq 0$, gibt es immer eine Operatornorm $\|\cdot\|$ mit $\|A\| \leq \|A\|$, nämlich $\|A\| := \sup_{x \neq 0} \frac{\|Ax\|}{\|x\|} \leq \|A\|$. Also gilt:

$$(4.5) = \inf\{\|M\| \mid \|\cdot\| \text{ ist eine Operatornorm}\}$$

Lemma 4.2 Sei $\varrho(M) = \max\{|\lambda| \mid \lambda \in \mathbb{C} \text{ ist Eigenwert von } M\}$ der *Spektralradius* von $M \in \mathbb{C}^{n \times n}$. Dann gilt

(a) Für jede Operatornorm $\|M\| = \sup_{0 \neq x \in \mathbb{C}^n} \frac{\|Ax\|}{\|x\|}$ gilt:

$$\varrho(M) \leq \|M\|$$

(d.h. $\varrho(M)$ ist eine untere Schranke für die Menge (4.5)).

(b) Für jedes $\epsilon > 0$ und jede Matrix $M \in \mathbb{C}^{n \times n}$ gibt es eine Operatornorm

$$\|M\|_M = \sup_{0 \neq x \in \mathbb{C}^n} \frac{\|Mx\|_M}{\|x\|_M}, \quad (4.6)$$

so dass

$$\|M\|_M \leq \varrho(M) + \epsilon.$$

Also: $\varrho(M)$ ist der gesuchte Wert (4.5)!

Bemerkung: Wir wissen: Für *symmetrisches* M können wir in (b) $\|\cdot\|_M := \|\cdot\|_2$ wählen (für beliebiges $\epsilon > 0$); es gilt $\|M\|_2 = \varrho(M)$.

Beweis von Lemma 4.2:

(a) Mit $Mx = \lambda x, x \neq 0$, folgt $\|M\|_{\text{Operatornorm}} \geq \frac{\|Mx\|}{\|x\|} = |\lambda| \Rightarrow \|M\| \geq \varrho(M)$.

(b) siehe Stoer & Bulirsch, Satz 6.8.2 oder Schwarz, 3. Auflage, Satz 11.4.

□

Lemma 4.2 besagt: $\varrho(M) < 1$ ist notwendig und hinreichend für die Existenz einer Operatornorm $\|\cdot\|_M$, so dass $\|M\|_M < 1$ ist. Damit folgt:

Lemma 4.3 Sei $M \in \mathbb{C}^{n \times n}$, $\tilde{b} \in \mathbb{C}^n$. Die Fixpunktiteration $x^{(k+1)} = \Phi(x^{(k)})$, mit $\Phi(x) = Mx + \tilde{b}$, ist genau dann für beliebige Startwerte $x^{(0)}$ konvergent gegen den eindeutig bestimmten Fixpunkt x^* von Φ (d.h. $Mx^* + \tilde{b} = x^*$), wenn $\varrho(M) < 1$.

Beweis:

“ $\varrho(M) < 1 \Rightarrow$ **Konvergenz**“: Aus $\varrho(M) < 1$ folgt mit Lemma 4.2 (b) die Existenz einer Vektornorm $\|\cdot\|_M$, so dass die zugehörige Matrixnorm $\|M\|_M < 1$ erfüllt. Die Behauptung folgt mit Lemma 4.1 (d.h. Fixpunktsatz von BANACH in $(\mathbb{C}^n, \|\cdot\|_M)$)

“ $\varrho(M) \geq 1 \Rightarrow$ **keine Konvergenz für beliebige** $x^{(0)}$ “ : Sei $\varrho(M) \geq 1$. Angenommen $x^{(k)} \rightarrow x^*$ (x^* Fixpunkt von Φ), für beliebigen Startpunkt $x^{(0)} \in \mathbb{C}^n$. Sei x Eigenvektor von M zu einem Eigenwert $|\lambda| \geq 1$: Setze $x^{(0)} := x + x^*$

$$\begin{aligned} \Rightarrow x^{(1)} &= Mx^{(0)} + \tilde{b} = Mx + \underbrace{Mx^* + \tilde{b}}_{=x^*} = \lambda x + x^* \\ x^{(2)} &= Mx^{(1)} + \tilde{b} = \lambda Mx + \underbrace{Mx^* + \tilde{b}}_{=x^*} = \lambda^2 x + x^* \\ &\vdots \\ \|x^{(k)} - x^*\| &= \|\lambda^k x\| = \underbrace{|\lambda|^k}_{\geq 1} \|x\| \geq \underbrace{\|x\|}_{\neq 0} \quad \forall k \in \mathbb{N} \\ &\Rightarrow x^{(k)} \not\rightarrow x^* \end{aligned}$$

□

Für die Verfahrensklassen (1) - (3) ist also sicherzustellen:

$$\varrho(Id - \omega A) < 1 \quad \text{bzw.} \quad \varrho(Id - BA) < 1 \quad \text{bzw.} \quad \varrho(W^{-1}S) < 1.$$

Im Folgenden konzentrieren wir uns auf Verfahren der Kategorie (3). Zu Kategorie (1) siehe Übung. Kategorie (2) und (3) lassen sich ineinander umwandeln (siehe ebenfalls Übung) durch:

$$B := (Id + W^{-1}S)A^{-1} \quad \text{bzw.} \quad W := B^{-1}, \quad S := A - B^{-1}.$$

4.2 Jacobi- und Gauß-Seidel-Verfahren

Man zerlegt $A = L + D + R$, wobei L und R eine strikte (linke bzw. rechte) Dreiecksmatrix und $D = \text{diag}(a_{ii})$ eine Diagonalmatrix ist. Wir setzen voraus, dass $a_{ii} \neq 0 \forall i$, d.h. D^{-1} existiert. In der Notation von Verfahrensklasse (3) in Kapitel 4.1 setzt man $W := D$ und $S = L + R$, d.h.:

$$\begin{aligned} Ax = b &\Leftrightarrow Dx = -(L + R)x + b \\ &\Leftrightarrow x = \underbrace{-D^{-1}(L + R)x + D^{-1}b}_{\Phi(x)} \end{aligned}$$

Die zugehörige Fixpunktiteration

$$\begin{aligned} x^{(k+1)} = \Phi(x^{(k)}) &= M_J x^{(k)} + \tilde{b} \\ \text{mit } M_J &= -D^{-1}(L + R), \quad \tilde{b} = D^{-1}b \end{aligned} \quad (4.7)$$

heißt *JACOBI-Verfahren* (Carl Jacobi, 1804-51, Berlin) oder *Gesamtschrittverfahren*. Komponentenweise geschrieben:

$$x_i^{(k+1)} := \frac{1}{a_{ii}} \left(- \sum_{\substack{j=1 \\ j \neq i}}^n a_{ij} x_j^{(k)} + b_i \right), \quad i = 1, \dots, n.$$

Das Update des i -ten Vektoreintrags verwendet also die Komponenten $x_1^{(k)}, \dots, x_{i-1}^{(k)}, x_{i+1}^{(k)}, \dots, x_n^{(k)}$ der alten Iterierten $x^{(k)}$. Naheliegender ist die Vermutung, dass man schnellere Konvergenz bekommt, wenn man stattdessen die bereits berechneten Werte $x_1^{(k+1)}, \dots, x_{i-1}^{(k+1)}$ (sowie weiterhin $x_{i+1}^{(k)}, \dots, x_n^{(k)}$) benutzt:

$$x_i^{(k+1)} := \frac{1}{a_{ii}} \left(- \sum_{j < i} a_{ij} x_j^{(k+1)} - \sum_{j > i} a_{ij} x_j^{(k)} + b_i \right), \quad i = 1, \dots, n. \quad (4.8)$$

(4.8) heißt *GAUSS-SEIDEL-Verfahren* oder *Einzelschrittverfahren* (SEIDEL: 1821-96, München). Im Computer kann (4.8) einfach mittels Überschreiben implementiert werden:

$$x_i := \frac{1}{a_{ii}} \left(- \sum_{\substack{j=1 \\ j \neq i}}^n a_{ij} x_j + b_i \right) \quad (4.9)$$

Um die Iterationsmatrix M_{GS} des Gauß-Seidel-Verfahrens (4.8) zu identifizieren, schreiben wir es als

$$\begin{aligned} x^{(k+1)} &= D^{-1}(-Lx^{(k+1)} - Rx^{(k)} + b) \quad |D \cdot & (4.10) \\ \Leftrightarrow (D + L)x^{(k+1)} &= -Rx^{(k)} + b \\ \Leftrightarrow x^{(k+1)} &= -(D + L)^{-1}Rx^{(k)} + (D + L)^{-1}b, & (4.10a) \\ \text{also } M_{GS} &= -(D + L)^{-1}R, \quad \tilde{b} = (D + L)^{-1}b. \end{aligned}$$

Die Invertierung von $D + L$ in (4.10) muss nur *scheinbar* erfolgen, siehe Darstellungen (4.8), (4.9). Ein Schritt des JACOBI- und des GAUSS-SEIDEL-Verfahrens sind gleich aufwändig.

Satz 4.4 Sei A (zeilenweise) diagonaldominant, d.h.

$$\sum_{\substack{j=1 \\ j \neq i}}^n |a_{ij}| < |a_{ii}| \quad \forall i = 1, \dots, n .$$

Dann gilt:

(a) $\|M_J\|_\infty < 1$.

(b) $\|M_{GS}\|_\infty \leq \|M_J\|_\infty (< 1)$.

d.h. das JACOBI- und das GAUSS-SEIDEL-Verfahren sind konvergent. ⁴

Bemerkung: Ist A spaltenweise diagonaldominant, so gelten in Satz 4.4 die entsprechenden Aussagen für $\|\cdot\|_1$ statt $\|\cdot\|_\infty$.

Beweis:

(a) $\|M_J\|_\infty = \|D^{-1}(L + R)\|_\infty = \max_i \sum_{\substack{j=1 \\ j \neq i}}^n \left| \frac{a_{ij}}{a_{ii}} \right| < 1$.

(b) Wir zeigen:

$$\| \underbrace{(D + L)^{-1} R x}_{=y} \|_\infty \leq \| \underbrace{D^{-1}(L + R)}_{-M_J} \|_\infty \quad \forall x \in \mathbb{C}^n \quad \text{mit } \|x\|_\infty = 1. \quad (4.11)$$

daraus folgt durch sup-Bildung die Behauptung.

Setze $y := (D + L)^{-1} R x$, also $(D + L)y = R x$, $Dy = -Ly + R x$; komponentenweise heißt das:

$$a_{ii}y_i = - \sum_{j < i} a_{ij}y_j + \sum_{j > i} a_{ij}x_j \quad \forall i = 1, \dots, n. \quad (4.12)$$

Wir zeigen per Induktion nach i , dass

$$|y_i| \leq \|D^{-1}(L + R)\|_\infty, \quad \forall i = 1, \dots, n \quad (4.13)$$

(woraus dann $\|y\|_\infty \leq \|D^{-1}(L + R)\|_\infty$, also (4.11), und somit die Behauptung, folgt)

$$\begin{aligned} \underline{i=1}: |y_1| &\stackrel{(4.12)}{=} \left| \frac{1}{a_{11}} \sum_{j=2}^n a_{1j}x_j \right| \leq \sum_{j=2}^n \left| \frac{a_{1j}}{a_{11}} \right| \cdot \underbrace{|x_j|}_{\leq 1} \leq \sum_{j=2}^n \left| \frac{a_{1j}}{a_{11}} \right| = \text{erste Zeilensumme von } D^{-1}(L + R), \\ &\text{also } \leq \|D^{-1}(L + R)\|_\infty. \end{aligned}$$

⁴Aussage (b) "passt" zu der zuvor geäußerten Intuition, dass das Gauß-Seidel-Verfahren schneller sein sollte als das Jacobi-Verfahren, ist aber *kein* strenger Beweis einer solchen Behauptung. Vergleiche auch S.76, L.A. II.

$$\underline{\{1, \dots, i-1\} \rightarrow i}: \|y_i\| \stackrel{(4.12)}{\leq} \sum_{j < i} \underbrace{\left| \frac{a_{ij}}{a_{ii}} \right|}_{<1} \cdot \underbrace{|x_j|}_{\leq 1} + \sum_{j > i} \left| \frac{a_{ij}}{a_{ii}} \right| \cdot \underbrace{|x_j|}_{\leq 1}.$$

Nach Induktionsvoraussetzung ist

$$\begin{aligned} |y_j| &\stackrel{\text{I.V. f\"ur } j < i}{\leq} \|D^{-1}(L+R)\|_\infty < 1 \text{ f\"ur } j < i \\ \Rightarrow |y_i| &\leq \sum_{j \neq i} \left| \frac{a_{ij}}{a_{ii}} \right| = i\text{-te Zeilensumme von } D^{-1}(L+R) \\ &\leq \|D^{-1}(L+R)\|_\infty \end{aligned}$$

Also: (4.13) gilt f\"ur alle $i = 1, \dots, n$.

$$\Rightarrow \|(D+L)^{-1}R\|_\infty = \max_{\|x\|_\infty=1} \underbrace{\|(D+L)^{-1}Rx\|_\infty}_{=y} \stackrel{(4.13)}{\leq} \|D^{-1}(L+R)\|_\infty$$

□

Die Forderung der Diagonaldominanz in Satz 4.4 ist in der Praxis oft zu restriktiv. Siehe zum Beispiel die Diskretisierung der POISSON-Gleichung

$$-\Delta u = f \quad (\text{bzw. } -u'' = f \text{ in 1-D})$$

[vgl. L.A.I Blatt 7 sowie L.A. II Seite 75 f., L.A. II Blatt 8]. Dort hat man Matrizen A , die nur

$$|a_{ii}| \geq \sum_{\substack{j=1 \\ j \neq n}} |a_{ij}| \quad \forall i = 1, \dots, n \quad (4.14)$$

und

$$\exists i \in \{1, \dots, n\} \quad |a_{ii}| > \sum_{\substack{j=1 \\ j \neq n}}^n |a_{ij}| \quad (4.15)$$

erf\"ullen.

Eine Matrix $A \in \mathbb{C}^{n \times n}$, die (4.14) und (4.15) erf\"ullt, hei\ss t *schwach diagonaldominant*. Man kann zeigen, dass Satz 4.4 auch f\"ur schwach diagonaldominante Matrizen g\"ultig ist, sofern zus\"atzlich vorausgesetzt wird, dass A *irreduzibel* ist. Eine Matrix $A \in \mathbb{C}^{n \times n}$ hei\ss t *irreduzibel*, falls es f\"ur jede disjunkte Zerlegung der Indexmenge

$$\{1, \dots, n\} = I_1 \cup I_2, \quad I_1, I_2 \neq \emptyset, \quad I_1 \cap I_2 = \emptyset,$$

stets Indizes $i \in I_1, j \in I_2$ gibt mit $a_{ij} \neq 0$. \u00c4quivalent dazu ist:

Es gibt keine Permutationsmatrix P , so dass

$$P^{-1}AP = \begin{pmatrix} B_1 & 0 \\ B_2 & B_3 \end{pmatrix},$$

wobei B_1 und B_3 quadratische Bl\"ocke sind. Es gibt einen grafentheoretischen Algorithmus zum Testen der Irreduzibilit\u00e4t (s. Schwarz & K\"ockler, Seite 497 f.). Ist A *reduzibel*, so kann das L\u00f6sen von $Ax = b$ offensichtlich in zwei (oder mehr) getrennte lineare Gleichungssysteme, deren Matrix jeweils irreduzibel ist, gesplittet werden, d.h. die Forderung der Irreduzibilit\u00e4t ist keine gro\ss e Einschr\u00e4nkung. Zum Beweis der Verallgemeinerung von Satz 4.4 auf schwach diagonaldominante irreduzible Matrizen siehe z.B. Schwarz & K\"ockler.

4.3 Relaxation für Gauß-Seidel- und Jacobi-Verfahren

Iterative Verfahren lohnen sich im Allgemeinen dann, wenn nicht allzuvielen Iterationsschritten nötig sind⁵. Daher ist es aus Effizienzgründen erforderlich, dass die Kontraktionsrate $\varrho(T)$ hinreichend klein ist. Für lineare Gleichungssysteme, die aus der Diskretisierung von PDEs entstehen, hat man oft

$$\varrho(M_{GS}) \rightarrow 1, \varrho(M_J) \rightarrow 1$$

für Diskretisierungsparameter $h \rightarrow 0$ (d.h. $n \rightarrow \infty$), d.h. asymptotisch immer schlechter werdende Konvergenzraten (s. Übung). Eine Möglichkeit, die Konvergenzrate zu verbessern, bietet oft die *Relaxation*. Beim JACOBI-Verfahren

$$\begin{aligned} x^{(k+1)} &:= -D^{-1}(L + R)x^{(k)} + D^{-1}b \\ &= x^{(k)} - \underbrace{D^{-1}(L + D + R)x^{(k)}}_{=: \Delta x^{(k)}} + D^{-1}b \end{aligned}$$

ersetzt man einfach das Update $\Delta x^{(k)} = x^{(k+1)} - x^{(k)}$ durch $\omega \cdot \Delta x^{(k)}$, $\omega \in \mathbb{R}$, d.h.

$$\begin{aligned} x^{(k+1)} &= x^{(k)} + \omega \Delta x^{(k)} \\ &= (1 - \omega)x^{(k)} - \omega D^{-1}(L + R)x^{(k)} + \omega D^{-1}b. \end{aligned} \quad (4.16)$$

(4.16) heißt *relaxiertes JACOBI-Verfahren*, $\omega \in \mathbb{R}$ heißt *Relaxationsparameter*. Für $\omega > 1$ spricht man von *Überrelaxation*, für $\omega < 1$ von *Unterrelaxation*. Nichtsdestotrotz hat sich für (4.16), $\omega \in \mathbb{R}$, der Begriff *JOR-Verfahren* (Jacobi overrelaxation) eingebürgert. Das JOR-Verfahren hat die Iterationsmatrix

$$\begin{aligned} M_{\text{JOR}}(\omega) &= (1 - \omega)Id - \omega D^{-1}(L + R) \\ &= (1 - \omega)Id + \omega M_J, \\ M_{\text{JOR}}(1) &= M_J. \end{aligned} \quad (4.17)$$

Beim GAUSS-SEIDEL-Verfahren geht man ähnlich vor. Die Darstellungen (4.8)/(4.10) (*nicht* Darstellung (4.10a)!) werden verwendet, um $\Delta x^{(k)}$ zu erklären:

$$\begin{aligned} x^{(k+1)} &= D^{-1}(-Lx^{(k+1)} - Rx^{(k)} + b) \\ &= x^{(k)} - \underbrace{D^{-1}Lx^{(k+1)} - D^{-1}(D + R)x^{(k)}}_{=: \Delta x^{(k)}} + D^{-1}b \end{aligned}$$

Dies wird modifiziert zu

$$\begin{aligned} x^{(k+1)} &= x^{(k)} + \omega \Delta x^{(k)} \\ &= (1 - \omega)x^{(k)} - \omega D^{-1}(Lx^{(k+1)} + Rx^{(k)}) + \omega D^{-1}b. \end{aligned} \quad (4.18)$$

Für dieses Verfahren hat sich der Name *SOR-Verfahren* (successive overrelaxation) eingebürgert. Die Darstellung (4.18) des SOR-Verfahrens ist ideal für die Implementierung. Zur Ermittlung der

⁵z.B. wenn die Anzahl der Schritte $\approx n^\alpha$ mit $\alpha < 1$ für $n \times n$ Matrizen, die aus der Diskretisierung von partiellen Differentialgleichungen hervorgehen.


Iterationsmatrix formen wir um:

$$\begin{aligned}
 (4.18) \quad &\Leftrightarrow (Id + \omega D^{-1}L)x^{(k+1)} = (1 - \omega)x^{(k)} - \omega D^{-1}Rx^{(k)} + \omega D^{-1}b \quad | \cdot D \\
 &\Leftrightarrow (D + \omega L)x^{(k+1)} = (1 - \omega)Dx^{(k)} - \omega Rx^{(k)} + \omega b \\
 &\Leftrightarrow x^{(k+1)} = (D + \omega L)^{-1}[(1 - \omega)D - \omega R]x^{(k)} + \omega(D + \omega L)^{-1}b,
 \end{aligned}$$

die Iterationsmatrix lautet also:

$$M_{\text{SOR}}(\omega) = (D + \omega L)^{-1}[(1 - \omega)D - \omega R]$$

Lemma 4.5 Falls das JACOBI-Verfahren konvergent ist, so ist auch das JOR-Verfahren konvergent für $0 < \omega \leq 1$.



Beweis:

Nach Voraussetzung erfüllen alle Eigenwerte $\lambda_i \in \mathbb{C}$ von M_J : $|\lambda_i| < 1$. Nach (4.17) lauten die Eigenwerte von $M_{\text{JOR}}(\omega)$: $\mu_i = (1 - \omega) \cdot 1 + \omega \lambda_i$.

Das heißt $\mu_i \in \mathbb{C}$ ist Konvexkombination von λ_i und 1 (wobei der Koeffizient von 1 nicht null ist). Daraus folgt $|\mu_i| < 1$.

□

Abbildung 16: Konvexkombination

Lemma 4.6 Es sei $A \in \mathbb{R}^{n \times n}$ s.p.d., und das JACOBI-Verfahren sei konvergent. Dann ist das JOR-Verfahren konvergent für alle $\omega \in \mathbb{R}$ mit

$$0 < \omega < \frac{2}{1 - \mu_{\min}} \left(\leq 2 \right),$$

wobei μ_{\min} der kleinste Eigenwert von M_J ist; dieser ist insbesondere kleiner gleich 0.

Beweis : A symmetrisch $\Rightarrow L + R$ symmetrisch und hat nur reelle Eigenwerte, A positiv definit $\Rightarrow a_{ii} > 0 \Rightarrow D^{\frac{1}{2}} := \text{diag}(\sqrt{a_{ii}})$ existiert.

$$M_J = -D^{-1}(L + R)$$

ist *ähnlich* zur Matrix (d.h. hat die gleichen Eigenwerte wie)

$$S := -D^{\frac{1}{2}}M_JD^{-\frac{1}{2}} = -D^{-\frac{1}{2}}(L + R)D^{-\frac{1}{2}},$$

welche *symmetrisch* ist und daher nur reelle Eigenwerte hat. S hat Spur = 0, die Spur ist die Summe aller Eigenwerte $\Rightarrow S$ (also auch M_J) hat kleinsten Eigenwert $\mu_{\min} \leq 0$. Wegen der vorausgesetzten Konvergenz des Jacobi-Verfahrens hat M_J Eigenwerte $-1 < \mu_i < 1$. $M_{\text{JOR}}(\omega)$ hat (nach (4.17)) Eigenwerte $\nu_j = 1 - \omega + \omega \mu_j$. Notwendige und hinreichende Bedingung für die Konvergenz des JOR-Verfahrens ist also

$$\begin{array}{lll}
 -1 < 1 - \omega + \omega \mu_j < 1 & | - 1 \\
 -2 < -\omega + \omega \mu_j < 0 & | \cdot (-1) \\
 2 > \omega(1 - \mu_j) > 0 & | \cdot \frac{1}{1 - \mu_j}
 \end{array}$$

Da nach Voraussetzung das Jacobi-Verfahren konvergent ist, ist $1 - \mu_j > 0 \quad \forall j$, also

$$\underbrace{\frac{2}{1 - \mu_j}}_{\text{wird minimal für } \mu_j = \mu_{\min}} > \omega > 0 \quad \forall \text{ Eigenwerte } \mu_j \text{ von } M_J$$

Dies ist äquivalent zu

$$\frac{2}{1 - \mu_{\min}} > \omega > 0.$$

□

Lemma 4.7 (optimale Wahl des Relaxationsparameters für JOR)

Sei A symmetrisch (M_J ist dann ähnlich zu einer symmetrischen Matrix, s. Beweis Lemma 4.6) und die (dann reellen) Eigenwerte von M_J erfüllen

$$\mu_1 \leq \mu_2 \leq \dots \leq \mu_n < 1$$

(ist z.B. erfüllt, wenn das Jacobi-Verfahren konvergent ist; z.B. wenn A diagonal dominant ist). Dann ist die optimale Wahl von ω , d.h. ω_{opt} so, dass

$$\varrho(M_{JOR}(\omega_{opt})) = \min_{\omega \in \mathbb{R}} \varrho(M_{JOR}(\omega)),$$

gegeben durch

$$\omega_{opt} = \frac{2}{2 - \mu_n - \mu_1}.$$

Es ist dann $\varrho(M_{JOR}(\omega_{opt})) = \frac{\mu_n - \mu_1}{2 - \mu_n - \mu_1}$.

Bemerkung: Leider kennt man im Allgemeinen die Eigenwerte von M_J nicht (noch nicht einmal die von A), d.h. man bestimmt ein "gutes" ω durch Ausprobieren.

Beweis : Es ist $\mu_1 \leq 0, \mu_n \geq 0$ (wie im Beweis von Lemma 4.7). Es ist

$$M_{JOR}(\omega) = (1 - \omega)Id + \omega M_J,$$

d.h. M_{JOR} hat die Eigenwerte $\nu_i = (1 - \omega) + \omega \mu_i$. Offensichtlich (siehe grafische Darstellung, Abbildung 17) kommen nur $\omega > 0$ in Frage. Für $\omega > 0$ hängen die ν_i monoton von den μ_i ab:

$$\begin{aligned} \nu_1 &\leq \dots \leq \nu_n < 1 \\ \Rightarrow \varrho(M_{JOR}(\omega)) &= \max\{|\nu_1|, \dots, |\nu_n|\} = \max\{|\nu_1|, |\nu_n|\}. \end{aligned}$$

Dieser Wert wird *minimal*, wenn

$$\begin{aligned} -\nu_1 &= \nu_n \\ \text{d.h. } -1 + \omega - \omega \mu_1 &= 1 - \omega + \omega \mu_n \\ \Leftrightarrow 2 - 2\omega + \omega(\mu_1 + \mu_n) &= 0 \\ \Leftrightarrow 2 &= \omega(2 - \mu_1 - \mu_n) \\ \Leftrightarrow \omega &= \frac{2}{2 - \mu_1 - \mu_n}. \end{aligned}$$




Abbildung 17: Eigenwerte von M_J und M_{JOR} für verschiedene ω

Für dieses ω ist

$$\rho(M_{\text{JOR}}(\omega)) = -\nu_1 = +\nu_n = 1 + \omega \cdot (\mu_n - 1) = 1 + \frac{2}{2 - \mu_1 - \mu_n} \cdot (\mu_n - 1) = \frac{\mu_n - \mu_1}{2 - \mu_1 - \mu_n}.$$

□

Bemerkung:

Falls $\mu_1 = -\mu_n$, was bei der Diskretisierung der LAPLACE-Gleichung zum Beispiel der Fall ist, so ist $\omega_{\text{opt}} = 1$, d.h. die Relaxation bringt keine Verbesserung.

Auch für das *SOR*-Verfahren lassen sich Konvergenzsätze sowie eine Formel für die optimale Wahl von ω angeben. Die Analyse des *SOR*-Verfahrens ist allerdings schwieriger als die des *JOR*-Verfahrens (Lemma 4.5 - 4.7), da bei *SOR* die Iterationsmatrix

$$M_{\text{SOR}}(\omega) = (D + \omega L)^{-1}[(1 - \omega)D - \omega R]$$

nichtlinear von ω abhängt und außerdem auch bei symmetrisch positiv definitem A im Allgemeinen nicht ähnlich zu einer spd-Matrix ist.

Hier einige Resultate:

Lemma 4.8

- a) *Es gilt $\rho(M_{\text{SOR}}(\omega)) \geq |1 - \omega|$,
d.h. für $\omega \leq 0$ und für $\omega \geq 2$ ist das *SOR*-Verfahren divergent.*
- b) *Für diagonaldominantes A (auch für schwach diagonaldominantes und irreduzibles A) ist das *SOR*-Verfahren für $0 < \omega \leq 1$ konvergent.*
- c) *Für A s.p.d. ist das *SOR*-Verfahren für $0 < \omega < 2$ konvergent.*

Beweis:

a)

$$\det M_{\text{SOR}}(\omega) \stackrel{\text{Det. Prod. Satz}}{=} \frac{\det[(1 - \omega)D - \omega R]}{\det(D + \omega L)} \stackrel{\text{det von } \Delta\text{-Matrizen}}{=} \frac{(1 - \omega)^n \det D}{\det D} = (1 - \omega)^n$$

Da Determinante = Produkt der Eigenwerte $\in \mathbb{C}$:

$$\prod_{i=1}^n \lambda_i = (1 - \omega)^n$$

Ferner

$$\rho(M_{\text{SOR}}(\omega))^n = \max_{i=1..n} |\lambda_i|^n \geq \prod_{i=1}^n |\lambda_i| = |1 - \omega|^n$$

⇒ Behauptung

b) und c) : siehe Schwarz & Köckler Satz 11.13, 11.15

□

Definition 4.9 Eine Matrix $A \in \mathbb{R}^{n \times n}$ heißt T - Matrix, falls sie die blockweise Tridiagonalgestalt

$$A = \begin{pmatrix} D_1 & R_1 & & & & \\ U_1 & \ddots & \ddots & & & 0 \\ & \ddots & \ddots & \ddots & & \\ & & \ddots & \ddots & \ddots & \\ & & & \ddots & \ddots & R_{s-1} \\ & 0 & & & U_{s-1} & D_s \end{pmatrix}$$

hat, wobei die D_i quadratische Diagonalmatrizen sind (die R_i, U_i sind im Allgemeinen rechteckig).

Bemerkung: Matrizen, die bei der Diskretisierung von partiellen Differentialgleichungen mittels sogenannter finiter Differenzen entstehen, sind, bei geeigneter Nummerierung der Gleichungen/Unbekannten, oft T-Matrizen⁶. T-Matrizen haben die Eigenschaft, dass $\det(\alpha L + \beta D + \frac{1}{\alpha} R)$ unabhängig von α ist. Diese Eigenschaft kann genutzt werden, um die Eigenwerte der komplizierten Matrix $M_{\text{SOR}}(\omega)$ mit denen der einfach aufgebauten Matrix M_J in Beziehung setzen. So lässt sich beweisen (s. Schwarz & Köckler, Kapitel 11.2.3):

Lemma 4.10 (Varga '62, Young '71)

Ist A eine T-Matrix mit $a_{ii} \neq 0$, und besitzt $M_J = -D^{-1}(L + R)$ nur reelle Eigenwerte μ_j , und gilt $\varrho(M_J) < 1$, dann ist der optimale Relaxationsparameter ω_{opt} des SOR-Verfahrens gegeben durch

$$\omega_{\text{opt}} = \frac{2}{1 + \sqrt{1 - \varrho(M_J)^2}} \in [1, 2)$$

und der zugehörige optimale Spektralradius ist

$$\varrho(M_{\text{SOR}}(\omega_{\text{opt}})) = \omega_{\text{opt}} - 1 \in [0, 1).$$

$\varrho(M_J)$	ω_{opt}	$\varrho(M_{\text{SOR}}(\omega_{\text{opt}}))$
0.9	1.393	0.393
0.99	1.753	0.753
0.999	1.914	0.914

Bemerkung: Die Abbildung $\omega \rightarrow \varrho(M_{\text{SOR}}(\omega))$ hat die Form

d.h. es ist besser ein etwas zu großes als ein etwas zu kleines ω zu wählen. In der Praxis: ω durch Ausprobieren bestimmen.

Allgemeine Bemerkung zu Fixpunktverfahren:

⁶Die Gitterpunkte werden schachbrettartig schwarz oder weiß "eingefärbt", so dass jeder Gitterpunkt von vier Gitterpunkten der jeweils anderen Farbe umgeben ist; dann startet man mit den "weißen" Gleichungen/Unbekannten und endet mit den "schwarzen". Es ergibt sich die obige Struktur mit $s = 2$.




Abbildung 18: Wahl des optimalen Relaxationsparameters.

- Ein prinzipieller Vorteil von Fixpunktverfahren zum Lösen von linearen Gleichungssystemen gegenüber direkten Verfahren ist, dass sich Rundungsfehler nicht akkumulieren können!
- In der Praxis kennt man die Eigenwerte von M_J nicht (nicht einmal die von A)
 → gutes ω für SOR und JOR durch *Ausprobieren* finden!