

# Kapitel 2. Anwendungen der Differentialrechnung mehrerer Variablen

## 2.4 Das Newton–Verfahren

**Ziel:** Wir suchen die Nullstellen einer Funktion  $\mathbf{f} : D \rightarrow \mathbb{R}^n, D \subset \mathbb{R}^n:$

$$\mathbf{f}(\mathbf{x}) = \mathbf{0}$$

- Wir kennen bereits die **Fixpunktiteration**

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

mit Startwert  $\mathbf{x}^0$  und Iterationsvorschrift  $\Phi : \mathbb{R}^n \rightarrow \mathbb{R}^n$ .

- Konvergenzaussagen liefert der **Banachsche Fixpunktsatz**.

**Vorteil:** Dieses Verfahren ist **ableitungsfrei**.

**Nachteile:**

- das numerische Verfahren konvergiert zu langsam (nur linear),
- es gibt keine eindeutige Iterationsvorschrift.

Banachscher Fixpunktsatz (BFS)

$$f(x) = 0 \quad \boxed{x = x + f(x) = \phi_1(x)}$$

Wähle  $x^0$

$$x^1 = \phi_1(x^0)$$

$$x^2 = \phi_1(x^1)$$

⋮

Hoffnung:

$$x^n \xrightarrow{n \rightarrow \infty} x^*$$

$$x^* = \phi_1(x^*)$$

BFS

$$\|\phi_1(x) - \phi_1(y)\| \leq L \|x - y\|$$


$\forall x, y \in D$

Lipschitzbeziehung




$\phi_1 \in C^1$  Funktion

$$L < 1 \text{ (Kontraktion)} \implies x^n \xrightarrow{n \rightarrow \infty} x^*$$



$$|\phi_1'(x^*)| < 1$$



$$|\phi_1'(x^*)| > 1$$

→ Konvergenz langsam

+ )  $x^{k+1} = \phi_1(x^k)$  keine Ableitung

+ )  $x = x + f(x) = \phi_1(x)$   
 - )  $x = x - f(x) = \phi_2(x)$

$x = \frac{x}{1+f(x)} = \phi_3(x)$

# Zur Konstruktion des Newton–Verfahrens.

**Ausgangspunkt:** Gegeben sei eine  $C^1$ -Funktion  $\mathbf{f} : D \rightarrow \mathbb{R}^n$ ,  $D \subset \mathbb{R}^n$  offen.

Wir suchen eine Nullstelle von  $\mathbf{f}$ , d.h ein  $\mathbf{x}^* \in D$  mit

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

**Konstruktion des Newton–Verfahrens:**

Die Taylor–Entwicklung von  $\mathbf{f}(\mathbf{x})$  um einen Startwert  $\mathbf{x}^0$  lautet

$$\mathbf{f}(\mathbf{x}) = \mathbf{f}(\mathbf{x}^0) + \mathbf{Jf}(\mathbf{x}^0)(\mathbf{x} - \mathbf{x}^0) + \mathbf{o}(\|\mathbf{x} - \mathbf{x}^0\|)$$

Setzen wir  $\mathbf{x} = \mathbf{x}^*$ , so folgt

$$\mathbf{Jf}(\mathbf{x}^0)(\mathbf{x}^* - \mathbf{x}^0) \approx -\mathbf{f}(\mathbf{x}^0)$$

Eine Näherungslösung für  $\mathbf{x}^*$  ist dann  $\mathbf{x}^1$ ,  $\mathbf{x}^1 \approx \mathbf{x}^*$ , die Lösung des linearen Gleichungssystems

$$\mathbf{Jf}(\mathbf{x}^0)(\mathbf{x}^1 - \mathbf{x}^0) = -\mathbf{f}(\mathbf{x}^0)$$

Newton

$h=1$


$$f(x^*) = 0$$

$$f(x) = f(x_0) + f'(x_0)(x-x_0) + \dots$$

$$y = f(x_0) + f'(x_0)(x-x_0) \quad y'(x_0) = f'(x_0)$$

$$y=0 \Leftrightarrow x = x_0 - \frac{f(x_0)}{f'(x_0)}$$

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



$h>1$

$$f(x) = f(x_0) + Jf(x_0)(x-x_0) + \dots$$

$$y = f(x_0) + Jf(x_0)(x-x_0)$$

$$y=0 \Leftrightarrow \text{i) } x = x_0 - (Jf(x_0))^{-1} f(x_0)$$

$$\text{ii) } Jf(x_0)(x-x_0) = -f(x_0)$$

invertieren einer Matrix ↘

lineares Gleichungssystem für  $x-x_0$  ✓

# Das Newton–Verfahrens als Algorithmus.

Das **Newton–Verfahren** kann man somit wie folgt als Algorithmus formulieren.

**Algorithmus (Newton–Verfahren):**

**(1) FOR**  $k = 0, 1, 2, \dots$

**(2a) Löse**  $\mathbf{J}f(\mathbf{x}^k) \cdot \Delta\mathbf{x}^k = -f(\mathbf{x}^k);$

**(2b) Setze**  $\mathbf{x}^{k+1} = \mathbf{x}^k + \Delta\mathbf{x}^k;$

- Man löst in *jedem* Newton–Schritt ein lineares Gleichungssystem.
- Die Lösung  $\Delta\mathbf{x}^k$  heißt **Newton–Korrektur**.
- Das Newton–Verfahren ist **skalierungsinvariant**.

# Skalierungsinvarianz des Newton–Verfahrens.

**Satz:** Das Newton–Verfahren ist invariant unter linearen Transformationen der Form

$$\mathbf{f}(\mathbf{x}) \rightarrow \mathbf{g}(\mathbf{x}) = \mathbf{A}\mathbf{f}(\mathbf{x}) \quad \text{für } \mathbf{A} \in \mathbb{R}^{n \times n} \text{ regulär,}$$

d.h. die Iterierten für  $\mathbf{f}$  und  $\mathbf{g}$  sind in diesem Fall identisch.

**Beweis:** Bildet man das Newton–Verfahren für  $\mathbf{g}(\mathbf{x})$ , so lautet die

Newton–Korrektur  $\Delta \mathbf{x}^k = (\mathbf{Jg}(\mathbf{x}^k))^{-1} (\mathbf{x}^{k+1} - \mathbf{x}^k) = -\mathbf{g}(\mathbf{x}^k) = -\mathbf{A}\mathbf{f}(\mathbf{x}^k)$

$$\Delta \mathbf{x}^k = -(\mathbf{Jg}(\mathbf{x}^k))^{-1} \cdot \mathbf{g}(\mathbf{x}^k)$$

$$\mathbf{A} \mathbf{Jf}(\mathbf{x}^k) (\mathbf{x}^{k+1} - \mathbf{x}^k) = \mathbf{g}(\mathbf{x}^k)$$

$$= -(\mathbf{A}\mathbf{Jf}(\mathbf{x}^k))^{-1} \cdot \mathbf{A}\mathbf{f}(\mathbf{x}^k)$$

$$\mathbf{A}^{-1} / \mathbf{Jf}(\mathbf{x}^k)^{-1} (\mathbf{x}^{k+1} - \mathbf{x}^k) = -\mathbf{f}(\mathbf{x}^k)$$

$$= -(\mathbf{Jf}(\mathbf{x}^k))^{-1} \cdot \mathbf{A}^{-1}\mathbf{A} \cdot \mathbf{f}(\mathbf{x}^k)$$

$$= -(\mathbf{Jf}(\mathbf{x}^k))^{-1} \cdot \mathbf{f}(\mathbf{x}^k)$$

womit die Newton–Korrektur von  $\mathbf{f}$  und  $\mathbf{g}$  übereinstimmen.

Bei gleichem Startwert  $\mathbf{x}^0$  stimmen somit auch alle Iterierten  $\mathbf{x}^k$  überein.

# Zur lokalen Konvergenz des Newton–Verfahrens.

**Satz:** Sei  $\mathbf{f} : D \rightarrow \mathbb{R}^n$  eine  $\mathcal{C}^1$ –Funktion,  $D \subset \mathbb{R}^n$  offen und konvex. Sei  $\mathbf{x}^* \in D$  eine Nullstelle von  $\mathbf{f}$ , d.h.  $\mathbf{f}(\mathbf{x}^*) = 0$ .

Weiterhin sei die Jacobi–Matrix  $\mathbf{Jf}(\mathbf{x})$  regulär für  $\mathbf{x} \in D$ , und es gelte eine Lipschitz–Bedingung für  $\phi(\mathbf{z}) = (\mathbf{Jf}(\mathbf{x}))^{-1} \mathbf{Jf}(\mathbf{z})$

$$\|(\mathbf{Jf}(\mathbf{x}))^{-1}(\mathbf{Jf}(\mathbf{y}) - \mathbf{Jf}(\mathbf{x}))\| \leq L \|\mathbf{y} - \mathbf{x}\| \quad \text{für alle } \mathbf{x}, \mathbf{y} \in D,$$

mit einem  $L > 0$ . Dann ist das Newton–Verfahren für alle Startwerte  $\mathbf{x}^0 \in D$  mit

$$\|\mathbf{x}^0 - \mathbf{x}^*\| < \frac{2}{L} =: r \quad \text{und} \quad K_r(\mathbf{x}^*) \subset D$$

wohldefiniert mit  $\mathbf{x}^k \in K_r(\mathbf{x}^*)$ ,  $k = 0, 1, 2, \dots$ , und die Newton–Iterierten  $\mathbf{x}^k$  konvergieren quadratisch gegen  $\mathbf{x}^*$ , d.h.

$$\|\mathbf{x}^{k+1} - \mathbf{x}^*\| \leq \frac{L}{2} \|\mathbf{x}^k - \mathbf{x}^*\|^2$$

Weiterhin ist  $\mathbf{x}^*$  die eindeutige Nullstelle von  $\mathbf{f}(\mathbf{x})$  innerhalb der Kugel  $K_r(\mathbf{x}^*)$ .

$$f(x^*) = 0$$

$$f(x) = (x-1)^2 - 1$$

$$Jf(x) = 2(x-1)$$


$$(Jf(x))^{-1} = \frac{1}{2(x-1)}$$


$$|(Jf(x))^{-1}(Jf(x_1) - Jf(x_0))| = \left| \frac{1}{2(x-1)} (2x_1 - 2 - 2x_0 + 2) \right|$$

$$= \left| \frac{1}{x-1} \right| |y-x| \leq L |x-1|$$

$$x^0 = 0 \left\{ \begin{array}{ll} \left| \frac{1}{x-1} \right| < 2 \text{ für } x \in (-\infty, \frac{1}{2}) & L=2 \quad |x^0 - x^*| = |x^0| < \frac{2}{L} = 1 \\ \left| \frac{1}{x-1} \right| < 10 \text{ für } x \in (-\infty, \frac{9}{10}) & L=10 \quad |x^0| < \frac{2}{10} = \frac{1}{5} \end{array} \right.$$

$$x^0 = 1 \left\{ \begin{array}{ll} \left| \frac{1}{x-1} \right| < 2 & x \in \left( \frac{3}{2}, +\infty \right) \quad |x^0 - 2| < 1 \\ \left| \frac{1}{x-1} \right| < 10 & x \in \left( \frac{11}{10}, \infty \right) \quad |x^0 - 2| < \frac{1}{5} \end{array} \right.$$





Beweis:  $g(t) = (Jf(x))^{-1} f(x + t(y-x))$

$$f: \mathbb{R}^1 \rightarrow \mathbb{R}^n$$

$$g(0) = (Jf(x))^{-1} f(x)$$

$$g(1) = (Jf(x))^{-1} f(y)$$

Kettengregel

$$g'(t) = (Jf(x))^{-1} Jf(x + t(y-x)) \cdot (y-x)$$

$$\|g'(t) - g'(0)\| = \|(Jf(x))^{-1} Jf(x + t(y-x)) (y-x) - (Jf(x))^{-1} Jf(x) (y-x)\|$$

$$= \|(Jf(x))^{-1} [Jf(x + t(y-x)) - Jf(x)] (y-x)\|$$

$$\leq \|(Jf(x))^{-1} [Jf(x + t(y-x)) - Jf(x)]\| \|y-x\|$$

$$\leq L \|x + t(y-x) - x\| \|y-x\| = L \|t(y-x)\| \|y-x\| \stackrel{\oplus}{=} L \|y-x\|^2$$

$$\begin{aligned} \|(Jf(x))^{-1} (f(y) - f(x) - Jf(x)(y-x))\| &= \|g(1) - g(0) - g'(0)\| = \left\| \int_0^1 g'(t) dt - g'(0) \right\| = \left\| \int_0^1 (g'(t) - g'(0)) dt \right\| \\ &\leq \int_0^1 \|g'(t) - g'(0)\| dt \stackrel{\oplus}{\leq} \int_0^1 L \|y-x\|^2 dt = L \|y-x\|^2 \int_0^1 t dt = \frac{L}{2} \|y-x\|^2 \end{aligned}$$

$$x^{k+1} - x^* = x^k - (Jf(x^k))^{-1} f(x^k) - x^*$$

Mark

$$= (Jf(x^k))^{-1} (f(x^*) - f(x^k)) + (Jf(x^k))^{-1} (Jf(x^k)) (x^k - x^*)$$

$$= (Jf(x^k))^{-1} [f(x^*) - f(x^k) - Jf(x^k)(x^* - x^k)]$$

$$x^* = y \quad x^k = x$$

$$\|x^{k+1} - x^*\| = \|(Jf(x^k))^{-1} [f(x^*) - f(x^k) - Jf(x^k)(x^* - x^k)]\|$$

$$\leq \frac{L}{2} \|x^k - x^*\|^2$$

# Das gedämpfte Newton–Verfahren.

## Weitere Beobachtungen:

- Das Newton–Verfahren konvergiert zwar quadratisch, aber nur **lokal**.
- **Globale** Konvergenz kann ggf. durch einen Dämpfungsterm erreicht werden:

**Algorithmus (Gedämpftes Newton–Verfahren):**

**(1) FOR**  $k = 0, 1, 2, \dots$

**(2a) Löse**  $\mathbf{J}f(\mathbf{x}^k) \cdot \Delta \mathbf{x}^k = -f(\mathbf{x}^k);$

**(2b) Setze**  $\mathbf{x}^{k+1} = \mathbf{x}^k + \lambda_k \Delta \mathbf{x}^k;$


**Frage:** Wie wählt man die **Dämpfungsfaktoren**  $\lambda_k$ ?

$$x_1 = x_0 - \frac{f(x_0)}{f'(x_0)} \quad \text{Newton-Horner}$$

$$x_1 = x_0 + \Delta x_0$$

$$x_2 = x_0 + \lambda \Delta x_0 \quad \lambda \in (0, 1)$$

$$\lambda = 1, \frac{1}{2}, \frac{1}{3}$$



# Wahl des Dämpfungsparameters.

**Strategie:** Verwende eine **Testfunktion**  $T(\mathbf{x}) = \|\mathbf{f}(\mathbf{x})\|$ , womit gilt

$$T(\mathbf{x}) \geq 0, \quad \forall \mathbf{x} \in D$$

$$T(\mathbf{x}) = 0 \Leftrightarrow \mathbf{f}(\mathbf{x}) = \mathbf{0}$$

Wähle nun  $\lambda_k \in (0, 1)$  so, dass die Folge  $T(\mathbf{x}^k)$  streng monoton fällt, d.h.

$$\|\mathbf{f}(\mathbf{x}^{k+1})\| < \|\mathbf{f}(\mathbf{x}^k)\| \quad \text{für } k \geq 0.$$

In der Nähe der gesuchten Lösung  $\mathbf{x}^*$  sollte  $\lambda_k = 1$  gewählt werden, um (lokale) quadratische Konvergenz zu sichern.

Der folgende Satz garantiert die Existenz eines Dämpfungsparameters.

**Satz:** Sei  $\mathbf{f}$  eine  $\mathcal{C}^1$ -Funktion auf der offenen und konvexen Menge  $D \subset \mathbb{R}^n$ . Für  $\mathbf{x}^k \in D$  mit  $\mathbf{f}(\mathbf{x}^k) \neq \mathbf{0}$  gibt es dann ein  $\mu_k > 0$ , sodass

$$\|\mathbf{f}(\mathbf{x}^k + \lambda \Delta \mathbf{x}^k)\|_2^2 < \|\mathbf{f}(\mathbf{x}^k)\|_2^2 \quad \text{für alle } \lambda \in (0, \mu_k).$$

*gestärkt Newton*      *klassisch Newton*

# Dämpfungsstrategie.

Für die **Startiteration**  $k = 0$ : Wähle  $\lambda_0 \in \{1, \frac{1}{2}, \frac{1}{4}, \dots, \lambda_{min}\}$  **möglichst groß**, sodass gilt

$$\|\mathbf{f}(\mathbf{x}^0)\|_2 > \|\mathbf{f}(\mathbf{x}^0 + \lambda_0 \Delta \mathbf{x}^0)\|_2$$

Für **nachfolgende Iterationen**  $k > 0$ : Setze  $\lambda_k = \lambda_{k-1}$ .

**IF**  $\|\mathbf{f}(\mathbf{x}^k)\|_2 > \|\mathbf{f}(\mathbf{x}^k + \lambda_k \Delta \mathbf{x}^k)\|_2$  **THEN**

- $\mathbf{x}^{k+1} := \mathbf{x}^k + \lambda_k \Delta \mathbf{x}^k$
- $\lambda_k := 2\lambda_k$ , falls  $\lambda_k < 1$ .

**ELSE**

- Bestimme  $\mu = \max\{\lambda_k/2, \lambda_k/4, \dots, \lambda_{min}\}$  mit

$$\|\mathbf{f}(\mathbf{x}^k)\|_2 > \|\mathbf{f}(\mathbf{x}^k + \lambda_k \Delta \mathbf{x}^k)\|_2$$

- $\lambda_k := \mu$

**END**

# Ausfallsproblem:

$(y_i, x_i)$   $i = 1, \dots, m$

modell  $\phi(x_1, \dots, x_n; \alpha_1, \dots, \alpha_n)$

z.B.  $\phi = A(x)\alpha$

gerade

$$y_i = \alpha_1 + \alpha_2 x_i$$

$$A = \begin{pmatrix} 1 & x_1 \\ \vdots & \vdots \\ 1 & x_n \end{pmatrix}_{m \times 2}$$

$$\alpha = \begin{pmatrix} \alpha_1 \\ \alpha_2 \end{pmatrix}_{2 \times 1}$$

$2 \times 2$   
 $2 \times m$   $m \times 2$

$$\|y - A\alpha\|_2^2 \longrightarrow \min(\alpha)$$

$$f(\alpha) = \|y - A\alpha\|_2^2 = (y - A\alpha)^T (y - A\alpha) = y^T y - y^T A \alpha - \alpha^T A^T y + \alpha^T A^T A \alpha$$

notwendige Bed.


$$\text{grad}_{\alpha} f(\alpha) = 0$$

$$\text{grad}_{\alpha} f(\alpha) = -y^T A \begin{pmatrix} 1 \\ \vdots \\ 1 \end{pmatrix}$$

$$- \underbrace{(1 \dots 1)^T}_{y^T A} y + \alpha^T \left( A^T A + \underbrace{(A^T A)^T}_{A^T A} \right) = +2\alpha^T A^T A - 2y^T A = 0$$

$$A^T A \alpha = A y^T$$

$$\alpha = (A^T A)^{-1} (A^T y)$$



$$A = \begin{pmatrix} 1 & x_1 \\ \vdots & \vdots \\ 1 & x_n \end{pmatrix}$$

$$A^T y = \begin{pmatrix} 1 & \dots & 1 \\ x_1 & & x_n \end{pmatrix} \begin{pmatrix} y_1 \\ \vdots \\ y_n \end{pmatrix} = \begin{pmatrix} \sum y_i \\ \sum x_i y_i \end{pmatrix} = n \begin{pmatrix} \bar{y} \\ \overline{xy} \end{pmatrix}$$

$$A^T A = \begin{pmatrix} 1 & \dots & 1 \\ x_1 & \dots & x_n \end{pmatrix} \begin{pmatrix} 1 & x_1 \\ \vdots & \vdots \\ 1 & x_n \end{pmatrix} = n \begin{pmatrix} 1 & \bar{x} \\ \bar{x} & \overline{x^2} \end{pmatrix}$$

$$\bar{x} = \frac{1}{n} \sum x_i$$

$$\bar{y} = \frac{1}{n} \sum y_i$$

$$\overline{xy} = \frac{1}{n} \sum x_i y_i$$

$$\overline{x^2} = \frac{1}{n} \sum x_i^2$$

$$(A^T A)^{-1} = \frac{1}{n(\overline{x^2} - \bar{x}^2)} \begin{pmatrix} \overline{x^2} & -\bar{x} \\ -\bar{x} & 1 \end{pmatrix}$$

$$\alpha = \frac{1}{n(\overline{x^2} - \bar{x}^2)} \begin{pmatrix} \overline{x^2} & -\bar{x} \\ -\bar{x} & 1 \end{pmatrix} \begin{pmatrix} n \bar{y} \\ n \overline{xy} \end{pmatrix} = \frac{1}{\overline{x^2} - \bar{x}^2} \begin{pmatrix} \overline{x^2} \bar{y} - \bar{x} \overline{xy} \\ -\bar{x} \bar{y} + \overline{xy} \end{pmatrix} = \begin{pmatrix} \alpha_1 \\ \alpha_2 \end{pmatrix}$$