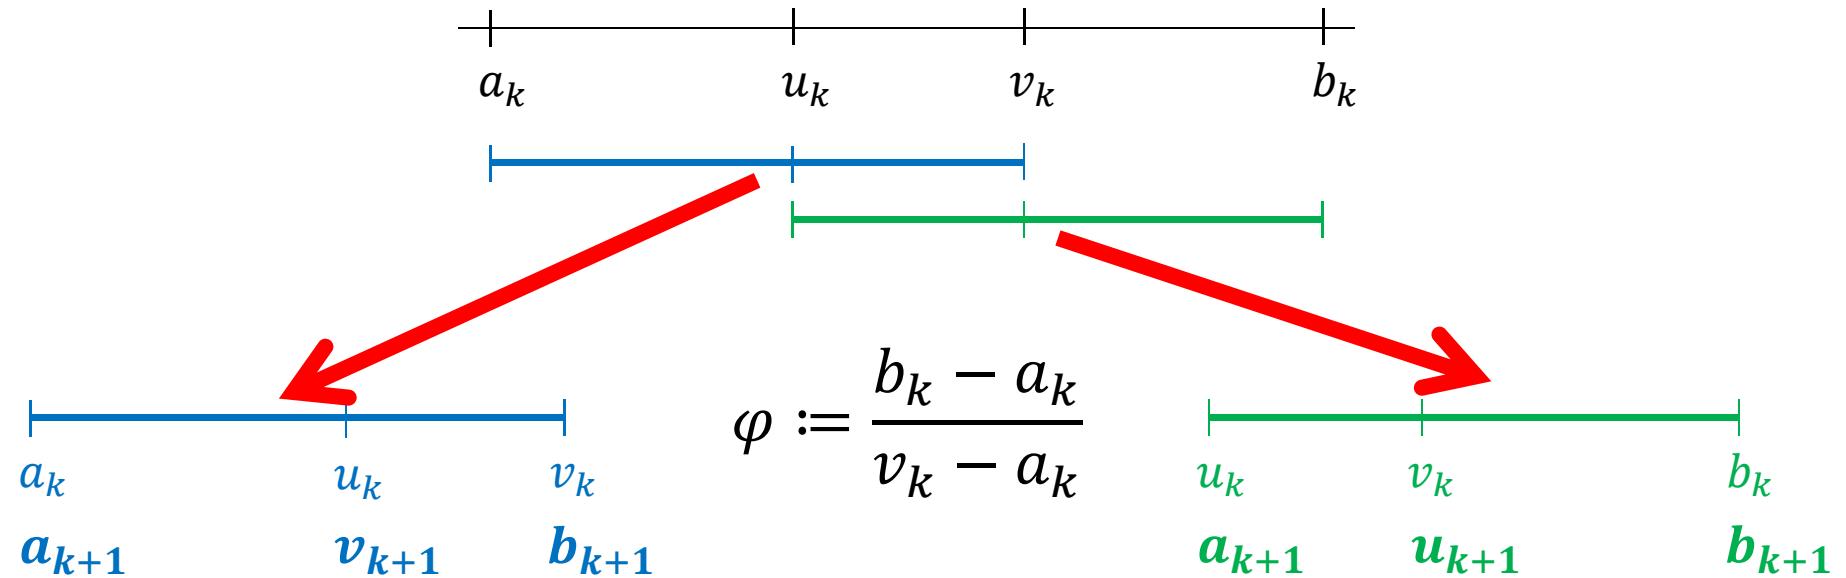


# Optimierung

---

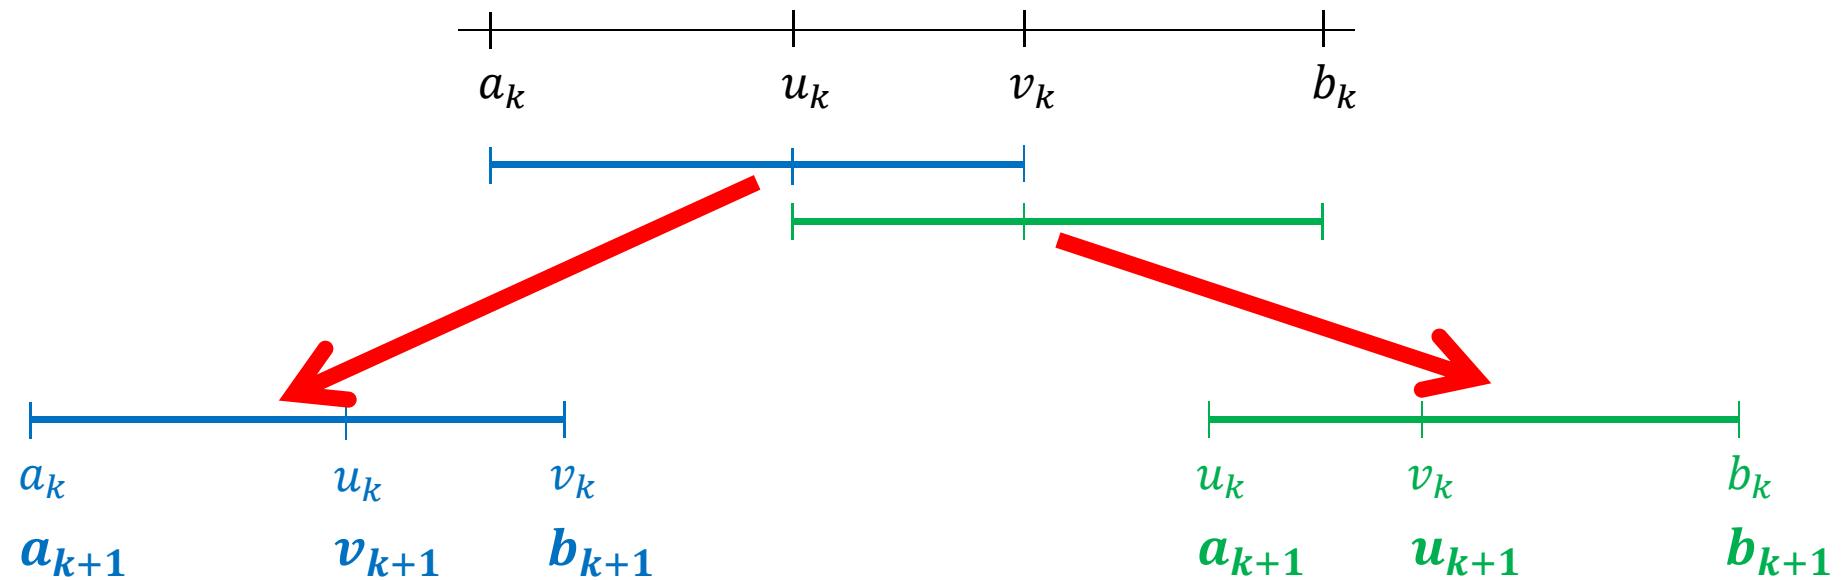
Vorlesung 3  
Optimierung ohne Nebenbedingungen  
Newton- und Quasi-Newton-Verfahren



$$\frac{v_k - a_k}{u_k - a_k} = \frac{b_{k+1} - a_{k+1}}{v_{k+1} - a_{k+1}} = \varphi \Rightarrow \frac{b_k - a_k}{u_k - a_k} = \varphi^2 \quad \frac{b_k - u_k}{v_k - u_k} = \frac{b_{k+1} - a_{k+1}}{u_{k+1} - a_{k+1}} = \varphi^2$$

$$b_k - u_k = (b_k - a_k) \left(1 - \frac{1}{\varphi^2}\right), \quad v_k - u_k = (b_k - a_k) \left(\frac{1}{\varphi} - \frac{1}{\varphi^2}\right)$$

$$\varphi^2 = \frac{b_k - u_k}{v_k - u_k} = \frac{1 - 1/\varphi^2}{1/\varphi - 1/\varphi^2} = \frac{(1 + 1/\varphi)(1 - 1/\varphi)}{1/\varphi(1 - 1/\varphi)} = \varphi + 1$$



$$\frac{b_k - a_k}{v_k - a_k} = \varphi \quad \Rightarrow \quad \frac{b_k - a_k}{u_k - a_k} = \varphi^2 \quad \Rightarrow \quad \varphi + 1 = \varphi^2$$

$$\varphi + 1 = \varphi^2 \quad (\varphi > 1) \quad \Rightarrow \quad \varphi = \frac{1 + \sqrt{5}}{2} \approx 1.618$$

## Minimierungsproblem $\min_{x \in \mathbb{R}^n} f(x)$

- Finde stationären Punkt  $x^*$ :  $\nabla f(x^*) = 0$

## Iteratives Verfahren

- Berechne Sequenz  $x_0, x_1, x_2, \dots,$
- Für  $i \rightarrow \infty, x_i$  sollte zu stationärem Punkt konvergieren

## Taylor-Approximation 1. Ordnung von $\nabla f$

$$\nabla f(x_k + d_k) \approx \nabla f(x_k) + H(x_k) \cdot d_k$$

– Hesse'sche Matrix  $H(x_k) = \begin{pmatrix} \frac{\partial^2}{\partial x_1^2} f(x_k) & \cdots & \frac{\partial^2}{\partial x_1 \partial x_n} f(x_k) \\ \vdots & \ddots & \vdots \\ \frac{\partial^2}{\partial x_n \partial x_1} f(x_k) & \cdots & \frac{\partial^2}{\partial x_n^2} f(x_k) \end{pmatrix}$

– Taylor (1. Ordn.):  $\nabla f(x_k + d_k) = \begin{pmatrix} \vdots \\ \frac{\partial}{\partial x_i} f(x_k + d_k) \\ \vdots \end{pmatrix} \approx \begin{pmatrix} \vdots \\ \frac{\partial}{\partial x_i} f(x_k) \\ \vdots \end{pmatrix} + \left( d_k^\top \cdot \nabla \left( \begin{pmatrix} \vdots \\ \frac{\partial}{\partial x_i} f(x_k) \\ \vdots \end{pmatrix} \right) \right)$

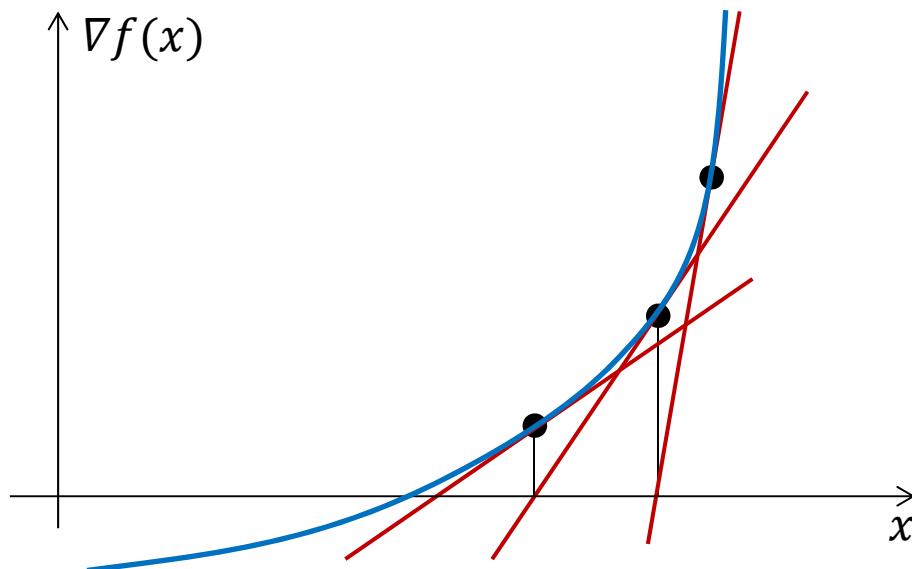
## Taylor-Approximation 1. Ordnung von $\nabla f$

$$\nabla f(x_k + d_k) \approx \nabla f(x_k) + H(x_k) \cdot d_k$$

## Newton-Verfahren

$$0 \stackrel{!}{=} \nabla f(x_k + d_k) \approx \nabla f(x_k) + H(x_k) \cdot d_k$$

- Setze  $\nabla f(x_k) + H(x_k)d_k = 0$  und berechne  $x_{k+1} = x_k + d_k$
- Löse lineares Gleichungssystem für  $d_k$ :  $d_k = -H(x_k)^{-1} \cdot \nabla f(x_k)$



## Taylor-Approximation 2. Ordnung von $f$

$$f(x_k + d_k) \approx f(x_k) + d_k^\top \cdot \nabla f(x_k) + \frac{1}{2} d_k^\top \cdot H(x_k) \cdot d_k$$

- $H(x_k)$ : Hesse'sche Matrix an der Stelle  $x_k$

## Newton-Verfahren

- Neuer Wert  $x_{k+1}$ : minimiere 2. Ordnung Taylor-Approximation

$$d_k = \arg \min_{d \in \mathbb{R}^n} \left\{ f(x_k) + d^\top \nabla f(x_k) + \frac{1}{2} d^\top H(x_k) d \right\}$$

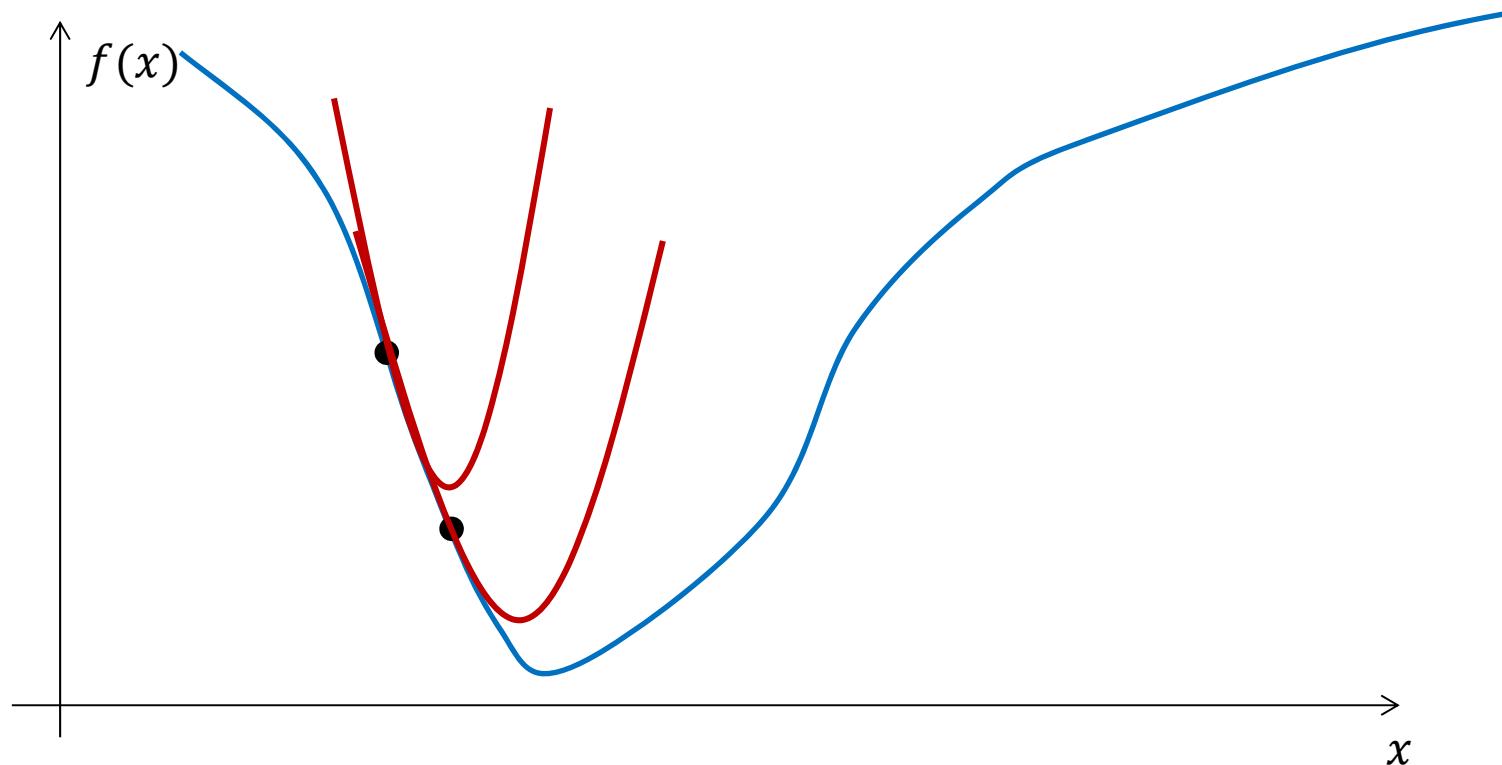
$$x_{k+1} = x_k + d_k$$

## Taylor-Approximation 2. Ordnung von $f$

$$f(x_k + d_k) \approx f(x_k) + d_k^\top \cdot \nabla f(x_k) + \frac{1}{2} d_k^\top \cdot H(x_k) \cdot d_k$$

## Newton-Verfahren

- Neuer Wert  $x_{k+1}$ : minimiere 2. Ordnung Taylor-Approximation



$$f(x) = 5x - \ln x$$

- Gradient:  $\nabla f(x) = f'(x) = 5 - \frac{1}{x}$ ,  $f'(x^*) = 0 \Rightarrow x^* = \frac{1}{5}$
- Hesse'sche Matrix:  $H(x) = f''(x) = \frac{1}{x^2}$
- Newton-Richtung:  $d_k = -H(x_k)^{-1} \nabla f(x_k) = -\frac{f'(x_k)}{f''(x_k)} = x_k - 5x_k^2$   
 $x_{k+1} = x_k + d_k = 2x_k - 5x_k^2$

$k$	$x_k$	$x_k$
1	0.05	0.3
2	0.0875000000000000	0.15
3	0.1367187500000000	0.1875
4	0.179977416992188	0.19921875
5	0.197995480848476	0.199996948242188
6	0.199979909514856	0.199999999953434
7	0.199999997981862	0.2000000000000000

$$f(x, y) = \ln(1 + x + y) + \ln 2x + \ln 5y$$

- $\nabla f(x, y) = \begin{pmatrix} \frac{1}{1+x+y} + \frac{1}{x} \\ \frac{1}{1+x+y} + \frac{1}{y} \end{pmatrix}, \quad \nabla f(x^*, y^*) = 0 \Rightarrow x^* = -\frac{1}{3}, y^* = -\frac{1}{3}$

- $H(x, y) = - \begin{pmatrix} \left(\frac{1}{1+x+y}\right)^2 + \frac{1}{x^2} & \left(\frac{1}{1+x+y}\right)^2 \\ \left(\frac{1}{1+x+y}\right)^2 & \left(\frac{1}{1+x+y}\right)^2 + \frac{1}{y^2} \end{pmatrix}$

- Newton-Richtung:  $-H(x, y)d_k = \nabla f(x, y)$
- Startwerte:  $x_1 = -0.05, x_2 = -0.75$

$$\begin{pmatrix} 425 & 25 \\ 25 & 25 + 16/9 \end{pmatrix} \cdot \begin{pmatrix} d_{k,x} \\ d_{k,y} \end{pmatrix} = \begin{pmatrix} -15 \\ 5 - 4/3 \end{pmatrix} \Rightarrow d_k = \begin{pmatrix} -0.0458677686 \\ 0.1797520661 \end{pmatrix}$$

## Abstiegsrichtung

- Eine Richtung  $d$  ist eine Abstiegsrichtung für einen Wert  $x_k$ , falls

$$d^\top \nabla f(x_k) < 0$$

- Beispiel: Neg. Gradient  $d = -\nabla f(x_k)$
- Taylor-Approximation:  $f(x_k + \varepsilon \cdot d) \approx f(x_k) + \varepsilon \cdot d^\top \nabla f(x_k)$

**Newton-Richtung**  $d_k = -H(x_k)^{-1} \nabla f(x_k)$

- Falls  $H(x_k)$  positiv definit ist, ist  $d_k$  eine Abstiegsrichtung

**Konvexe Funktionen  $f(x)$ :**

- Newton-Richtung ist eine Abstiegsrichtung
- Newton-Verfahren konvergiert zu lokalem Minimum

**Konvexe, quadratische Funktionen  $f(x)$ :**

- Newton-Schritt geht zu Minimum der quadratischen Approx. von  $f(x)$
- Verfahren erreicht lokales Minimum in einem Schritt!

**Allgemein:**

- Konvergiert sobald man *nahe genug* bei einem lokalen Minimum ist
- Kann mit *line search* (wie beim Gradientenverfahren) kombiniert werden:

$$\text{Newton-Richtung: } d_k = -H(x_k)^{-1} \cdot \nabla f(x_k)$$

Bestimme  $x_{k+1} = x_k + \tau_k \cdot d_k$ , so dass  $f(x_k + \tau_k d_k)$  minimal ist

- Wie schnell kommt man zum lokalen Minimum?

**Konvergenz von Folgen**  $s_1, s_2, \dots, \lim_{k \rightarrow \infty} s_k = \bar{s}$

**Lineare Konvergenz:**

$$\limsup_{k \rightarrow \infty} \frac{|s_{k+1} - \bar{s}|}{|s_k - \bar{s}|} = C$$

**Superlineare Konvergenz:**

$$\limsup_{k \rightarrow \infty} \frac{|s_{k+1} - \bar{s}|}{|s_k - \bar{s}|} = 0$$

**Quadratische Konvergenz:**

$$\limsup_{k \rightarrow \infty} \frac{|s_{k+1} - \bar{s}|}{|s_k - \bar{s}|^2} = C$$

## Gradientenverfahren (steilster Abstieg)

- lineare Konvergenz

## Newtonverfahren

- quadratische Konvergenz
- minimiert quadratische Funktionen in 1 Schritt

## Konjugierte Gradienten

- minimiert  $n$ -dimensionale quadratische Funktionen in  $n$  Schritten
- quadratische Konvergenz alle  $n$  Schritte (superlinear)

## Quasi-Newtonverfahren

- superlineare Konvergenz
- einfacher als Newton-Verfahren

**Annahme: streng konvexe, quadratische Fkt.**  $f(x) = \frac{1}{2}x^\top Ax - b^\top x$

- $A$  symm. pos. definit ( $\forall x: x^\top Ax > 0$ , alle Eigenwerte reell und positiv)
- Eindeutiges Minimum bei  $x^*$ , so dass  $\nabla f(x^*) = 0$

$$0 = \nabla f(x^*) = Ax^* - b \implies x^* = A^{-1}b$$

- Funktionswert bei  $x^*$ :

## 1 Iterationsschritt an Stelle $x$

- Abstiegsrichtung  $d = -\nabla f(x) = b - Ax$
- Neuer Iterationswert  $x' = x + \tau \cdot d$ , wobei  $\tau = \arg \min_{\alpha} f(x + \alpha \cdot d)$

## Quadratische konvexe Funktion

$$f(x) = \frac{1}{2}x^\top Ax - b^\top x, \quad x^* = A^{-1}b, \quad f(x^*) = -\frac{1}{2}b^\top A^{-1}b$$

### 1 Iterationsschritt an Stelle $x$ (neuer Wert $x'$ )

$$d = -\nabla f(x) = b - Ax, \quad x' = x + \tau \cdot d, \quad \tau = \frac{d^\top d}{d^\top Ad}$$

## Konvergenzrate $C$

$$C = \max_{x \text{ nahe genug bei } x^*} \frac{f(x') - f(x^*)}{f(x) - f(x^*)}$$

## Quadratische konvexe Funktion

$$f(x) = \frac{1}{2}x^\top Ax - b^\top x, \quad x^* = A^{-1}b, \quad f(x^*) = -\frac{1}{2}b^\top A^{-1}b$$

$$d = b - Ax, \quad x' = x + \tau d, \quad \tau = \frac{d^\top d}{d^\top Ad}, \quad f(x') = f(x) - \frac{1}{2} \frac{(d^\top d)^2}{d^\top Ad}$$

## Konvergenzrate $C$

$$C = \frac{f(x') - f(x^*)}{f(x) - f(x^*)} = \frac{f(x) - \frac{1}{2} \frac{(d^\top d)^2}{d^\top Ad} + \frac{1}{2} b^\top A^{-1}b}{f(x) + \frac{1}{2} b^\top A^{-1}b}$$

$$= 1 - \frac{\frac{1}{2} \frac{(d^\top d)^2}{d^\top Ad}}{f(x) + \frac{1}{2} b^\top A^{-1}b} = 1 - \frac{\frac{1}{2} \frac{(d^\top d)^2}{d^\top Ad}}{\frac{1}{2} x^\top Ax - b^\top x + \frac{1}{2} b^\top A^{-1}b}$$

$\frac{1}{2} x^\top AA^{-1}Ax = \frac{1}{2} (Ax)^\top A^{-1}(Ax)$

## Konvergenzrate $C$

$$C = \frac{f(x') - f(x^*)}{f(x) - f(x)} = 1 - \frac{\frac{1}{2} (d^\top d)^2}{\frac{1}{2} d^\top A^{-1} d} = 1 - \frac{d^\top d}{d^\top A d} \cdot \frac{d^\top d}{d^\top A^{-1} d}$$

- Eigenwerte von  $A$  :  $0 < \lambda_1 \leq \lambda_2 \leq \dots \leq \lambda_n$  (positiv und reell)
- Eigenwerte von  $A^{-1}$ :  $0 < {}^1/\lambda_n \leq {}^1/\lambda_{n-1} \leq \dots \leq {}^1/\lambda_1$
- Grösster Eigenwert  $\mu_{\max}$  einer reellen, symm.  $n \times n$ -Matrix  $M$ :

$$\mu_{\max} = \max_{x \in \mathbb{R}^n} \frac{x^\top M x}{x^\top x}$$

- Deshalb:  $\frac{d^\top A d}{d^\top d} \leq \lambda_n, \quad \frac{d^\top A^{-1} d}{d^\top d} \leq {}^1/\lambda_1 \quad \Rightarrow \quad C \leq 1 - \lambda_1 / \lambda_n$
- Genauer:  $C \leq \left( \frac{\lambda_n - \lambda_1}{\lambda_n + \lambda_1} \right)^2$

**Ziel:** Die Sequenz  $x_1, x_2, \dots$  konvergiert quadratisch gegen  $x^*$

### Matrix-Norm $\|M\|$ einer Matrix $M$

$$\|M\| := \max_{x: \|x\|=1} \|Mx\|$$

- $\forall M, M', x: \|Mx\| \leq \|M\| \cdot \|x\|, \|M \cdot M'\| \leq \|M\| \cdot \|M'\|$

**Annahmen:** Für  $x, y$  nahe genug bei  $x^*$  gilt  $\|\mathbf{H}(x) - \mathbf{H}(y)\| \leq L \cdot \|x - y\|$ , sowie  $\|\mathbf{H}(x)^{-1}\| \leq C$  für Konstanten  $L, C \geq 0$

**Lemma:**

$$\nabla f(z) - \nabla f(x) = \int_0^1 [H(x + t(z - x))] (z - x) dt$$

**Lemma:**

$$\nabla f(z) - \nabla f(x) = \int_0^1 [H(x + t(z - x))](z - x) dt$$

**Beweis:**

- Definiere  $\phi(t) := \nabla f(x + t(z - x))$
- Ableitung  $\phi'(t) = [H(x + t(z - x))](z - x)$

**Ziel:** Die Sequenz  $x_1, x_2, \dots$  konvergiert quadratisch gegen  $x^*$

**Lemma:**

$$\nabla f(z) - \nabla f(x) = \int_0^1 [H(x + t(z - x))] (z - x) dt$$

■

$$x' - x^* = x - H(x)^{-1} \nabla f(x) - x^*$$

## Matrix-Norm $\|M\|$ einer Matrix $M$

- $\forall M, M', x: \|Mx\| \leq \|M\| \cdot \|x\|, \|M \cdot M'\| \leq \|M\| \cdot \|M'\|$

**Annahmen:** Für  $x, y$  nahe genug bei  $x^*$  gilt  $\|H(x) - H(y)\| \leq L \cdot \|x - y\|$ , sowie  $\|H(x)^{-1}\| \leq C$  für Konstanten  $L, C \geq 0$

$$x' - x^* = H(x)^{-1} \int_0^1 [H(x + t(x^* - x)) - H(x)](x^* - x) dt$$

$$\|x' - x^*\| \leq \|H(x)^{-1}\| \int_0^1 \|H(x + t(x^* - x)) - H(x)\| \cdot \|x^* - x\| dt$$

## Gradientenverfahren

- Lineare Konvergenz
  - Benötigt i.A. deutlich mehr Schritte (vor allem, wenn die Hesse'sche Matrix schlecht konditioniert ist)
- 1. Ableitung nötig
- 1 Iterationsschritt:
  - Evaluation Gradient + line search
- “Billige” Schritte, “schlechte” Konv.
- Bessere Konvergenz:  
Konjugierte Gradientenverfahren

## Newton-Verfahren

- Quadratische Konvergenz
  - konvergiert in wenigen Schritten (bei quadr. Problem in 1 Schritt)
- 1. & 2. Ableitung nötig
- 1 Iterationsschritt:
  - Evaluation Gradient + Hesse'sche Matrix
  - $n$ -dim. lineares Gl.-system
- “Teure” Schritte, “gute” Konvergenz
- Einfachere Iterationen:  
Quasi-Newton-Verfahren

- Newton-Verfahren + Line Search:

$$x_{k+1} = x_k + \tau_k d_k, \quad \text{wobei } d_k = -H(x_k)^{-1} \nabla f(x_k)$$

- **Idee:** Ersetze  $H(x_k)^{-1}$  durch eine Matrix  $D_k$ , welche einfacher berechnet werden kann
- Taylor-Approximation:  $\nabla f(x_{k+1}) - \nabla f(x_k) \approx H(x_{k+1})(x_{k+1} - x_k)$ 
  - Idee:  $D_k^{-1}$  sollte dies auch erfüllen...
- Quasi-Newton Bedingung:

$$D_{k+1} \cdot q_k = p_k, \quad \text{wobei } p_k = x_{k+1} - x_k, \quad q_k = \nabla f(x_{k+1}) - \nabla f(x_k)$$

**Quasi-Newton-Verfahren:**

$$\mathbf{x}_{k+1} = \mathbf{x}_k + \tau_k \cdot \mathbf{d}_k, \quad \text{wobei } \mathbf{d}_k = -D_k \nabla f(\mathbf{x}_k)$$

- $\tau_k$  wird typischerweise durch line search ermittelt

**Quasi-Newton Bedingung:**

$$D_{k+1} \cdot q_k = p_k, \quad \text{wobei } p_k = x_{k+1} - x_k, \quad q_k = \nabla f(x_{k+1}) - \nabla f(x_k)$$

**Berechnung von  $D_{k+1}$ :**

- Alte Matrix + Korrekturterm:  $D_{k+1} = D_k + C_k$

$$(D_k + C_k)q_k = p_k \implies C_k q_k = p_k - D_k q_k$$

- Zum Beispiel ( $\phi \in [0,1]$  ist ein Parameter)

$$C(\phi) = \frac{pp^\top}{p^\top q} - \frac{Dqq^\top D}{q^\top Dq} + \phi \eta v v^\top, \quad \text{wobei } v = \frac{p}{p^\top q} - \frac{Dq}{\eta}, \quad \eta = q^\top Dq$$

## Quasi-Newton-Verfahren:

$$x_{k+1} = x_k - \tau_k \cdot D_k \nabla f(x_k)$$

$$D_{k+1} = D_k + C_k, \quad C_k q_k = p_k - D_k q_k$$

- Parameter  $\phi = 0$  (Davidson-Fletcher-Powell, erstes Quasi-Newton-Verf.)

$$C(0) = \frac{pp^\top}{p^\top q} - \frac{Dqq^\top D}{q^\top Dq}$$

- Parameter  $\phi = 1$  (Broyden-Fletcher-Goldfarb-Shanno)

$$C(1) = \frac{pp^\top}{p^\top q} \left[ 1 + \frac{q^\top Dq}{p^\top q} \right] - \frac{Dqp^\top + pq^\top D}{p^\top q}$$

- Quasi-Newton-Verfahren konvergieren oft superlinear
- Für quadratische Funktionen in  $n$  Schritten
  - entspricht dann dem konjugierten Gradientenverfahren