

Optimierung

Vorlesung 4 Newton- und Quasi-Newton-Verfahren (Teil II)

Taylor-Approximation 1. Ordnung von ∇f

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

Newton-Verfahren


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

Newton-R.

- 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

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

Newton-Verfahren

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



Abstiegsrichtung

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

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

– 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:

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:

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

Superlineare Konvergenz:

$$\limsup_{k \rightarrow \infty} \frac{|s_{k+1} - \bar{s}|}{|s_k - \bar{s}|} = 0 \quad s_i = 1/i!$$

Quadratische Konvergenz:

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

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

Ziel: Die Sequenz $\underline{x_1}, \underline{x_2}, \dots$ konvergiert quadratisch gegen $\underline{x^*}$ ← stat. Punkt
 $\nabla f(x^*) = 0$

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

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

$$\|x\| = \sqrt{\sum x_i^2}$$

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

$$|f'(x) - f'(y)| \leq L \cdot |x - y|$$

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 $L, C \geq 0$

Lemma:

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

Lemma:

$$\phi(1) - \phi(0)$$

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

Beweis:

- Definiere $\phi(t) := \nabla f(x + t(z-x))$ $\phi(0) = \nabla f(x)$, $\phi(1) = \nabla f(z)$
- Ableitung $\phi'(t) = [H(x + t(z-x))] (z-x)$

$$\begin{aligned} \nabla f(z) - \nabla f(x) &= \phi(1) - \phi(0) \\ &= \int_0^1 \phi'(t) dt \\ &= \int_0^1 [H(x + t(z-x))] (z-x) dt \end{aligned}$$

Ziel: Die Sequenz x_1, x_2, \dots konvergiert quadratisch gegen x^* $\nabla f(x^*) = 0$

$$x_i: x$$

$$x_i - x^*$$

$$x_{i+1} - x^*$$

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

Lemma:

$$x_{i+1}: x'$$

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

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

■

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

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

$$= x - x^* + H(x)^{-1} \int_0^1 [H(x + t(x^* - x))] (x^* - x) dt$$

$$= H(x)^{-1} \int_0^1 [H(x + t(x^* - x)) - H(x)] (x^* - x) dt$$

$$x - x^* = H(x)^{-1} H(x) (x - x^*)$$

$$= H(x)^{-1} \cdot \int_0^1 \underline{H(x) (x - x^*)} dt$$

$$\int_0^1 c dt = c$$

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 $L, C \geq 0$

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

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

$$\|x' - x^*\| \leq \|H(x)^{-1}\| \int_0^1 \| \dots \| dt$$



$$\left\| \int_0^1 [H(x + t(x^* - x)) - H(x)](x^* - x) dt \right\| \leq \int_0^1 \| [H(x + t(x^* - x)) - H(x)](x^* - x) \| dt$$

$$\|a + b\| \leq \|a\| + \|b\|$$

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

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

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 $L, C \geq 0$

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

$$\leq \|x^* - x\| \|H(x)^{-1}\| \int_0^1 \|H(x + t(x^* - x)) - H(x)\| dt$$

$$\leq L \cdot \|x^* - x\|$$

$$\leq \|x^* - x\| \|H(x)^{-1}\| \int_0^1 L \cdot t \cdot \|x^* - x\| dt = \|x^* - x\|^2 \cdot \underbrace{\|H(x)^{-1}\|}_{\leq C} \cdot L \cdot \int_0^1 t dt$$

$$\|x' - x^*\| \leq \frac{L \cdot C}{2} \cdot \|x - x^*\|^2$$

$$\lim_{i \rightarrow \infty} \frac{\|x^{i+1} - x^*\|}{\|x^i - x^*\|^2} \leq \frac{LC}{2}$$

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: $-H^{-1}\nabla f$
 - Evaluation Gradient + Hesse'sche Matrix
 - n -dim. lineares Gl.-system
- “Teure” Schritte, “gute” Konvergenz
- Einfachere Iterationen:

Quasi-Newton-Verfahren

- Newton-Verfahren + Line Search:

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

- **Idee:** Ersetze $H(x_k)^{-1}$ durch eine Matrix D_k , welche einfacher berechnet werden kann

$$D_k \approx H(x_k)^{-1}$$

- Taylor-Approximation $\nabla f(x_{k+1}) - \nabla f(x_k) \approx H(x_{k+1})(x_{k+1} - x_k)$

$$\underline{\nabla f(x+s) \approx \nabla f(x) + H(x) \cdot s} \quad f'(x+s) \approx f'(x) + s \cdot f''(x)$$

- Idee: D_{k+1}^{-1} sollte dies auch erfüllen...

- Quasi-Newton Bedingung:

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

$$\underbrace{\nabla f(x_{k+1}) - \nabla f(x_k)}_{q_k} = D_{k+1}^{-1} \underbrace{(x_{k+1} - x_k)}_{p_k} \quad q_k = D_{k+1}^{-1} p_k$$

Quasi-Newton-Verfahren:

$$\underline{x_{k+1} = x_k + \tau_k \cdot d_k}, \quad \text{wobei } d_k = \underbrace{-D_k^{-1} \nabla f(x_k)}_{\substack{\text{Hesse-Matrix} \\ \text{von } f(x_k)}}$$

- τ_k wird typischerweise durch line search ermittelt

Quasi-Newton Bedingung:

$$\underline{D_1, D_2, \dots}$$

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

Berechnung von D_{k+1} :

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

$$\underline{(D_k + C_k)q_k = p_k} \quad \Rightarrow \quad \underline{C_k q_k = p_k - D_k q_k}$$

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

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

Quasi-Newton-Verfahren:

$$\begin{aligned}
 x_{k+1} &= x_k - \tau_k \cdot D_k \nabla f(x_k) \\
 D_{k+1} &= D_k + C_k, \quad C_k q_k = p_k - D_k q_k
 \end{aligned}$$

$D_{k+1} q_k = p_k$

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

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

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

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

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