

# 07 Newtonartige Verfahren, Quasi-Newton-Verfahren, nichtlineare CG-Verfahren

Nichtlineare Optimierung  
WS 2020/21

# Prüfung

- ▶ Die Prüfungen werden mündlich per BBB-Videokonferenz stattfinden.
- ▶ Prüfungszeitraum 05.02.2021 bis einschließlich 23.03.2021 *Du vormittag  
Fr vormittag*
- ▶ Prüfungsinhalte: Skript, Konsultation, Übungen
- ▶ siehe auch Ordner „Prüfung“ im OPAL  
*30 Minuten, keine Vorbereitungszeit*

# Newtonartige Verfahren

Newton-Verfahren:

$$\nabla^2 f(x_k) d_k = -\nabla f(x_k)$$

Newtonartige Verfahren:

$$H_k d_k = -\nabla f(x_k) + \zeta$$

inexaktes Newton-Verfahren:

$$\nabla^2 f(x_k) d_k = -\nabla f(x_k) + \zeta$$

Quasi-Newton-Verfahren:

$$H_k d_k = -\nabla f(x_k)$$

# Quizfrage

Unter welcher Bedingung können wir die q-superlineare Konvergenz von Quasi-Newton-Verfahren erwarten?

→ Umfrage

- A  $H_k \rightarrow 0$  (Nullmatrix)
- C  $H_k d_k \rightarrow 0$

B  $\Rightarrow$  D

- B  $\|H_{k+1} - H_k\| \rightarrow 0$
- D  $\|(H_{k+1} - H_k) d_k\| = o(\|d_k\|)$

Satz 5.34

$$m_k(x) = f(x_k) + \nabla f(x_k)^T (x - x_k) + \dots + H_k$$

# Quizfrage

$$m_{k+1}(x) = f(x_{k+1}) + \nabla f(x_{k+1})^T (x - x_{k+1}) + \dots + H_{k+1}$$

$$\nabla m_{k+1}(x_k) = \nabla f(x_k) = \nabla m_k(x_k)$$

Was ist die Sekantenbedingung?

Hinweis:  $s_k = x_{k+1} - x_k$  und

$$y_k = \nabla f(x_{k+1}) - \nabla f(x_k)$$

→ Umfrage

3  A  $H_{k+1} s_k = y_k$

1  C  $H_{k+1} y_k = s_k$

0  B  $\nabla f(x+d) - \nabla f(x) = \nabla^2 f(x) d + \int_0^1 [\nabla^2 f(x+td) - \nabla^2 f(x)] d dt$

4  D  $H_{k+1} \underbrace{(x_{k+1} - x_k)}_{s_k} = \underbrace{\nabla f(x_{k+1}) - \nabla f(x_k)}_{y_k}$

# Konstruktionsideen

Welche Dinge spielen eine Rolle?

- ▶ Sekantenbedingung

$$H_{k+1} (x_{k+1} - x_k) = \nabla f(x_{k+1}) - \nabla f(x_k)$$

- ▶  $H_{k+1}$  „in der Nähe“ von  $H_k$

damit  $\|(H_{k+1} - H_k) d_k\| = o(\|d_k\|)$

- ▶  $H_{k+1}$  spd *im Kontext von Linschnittverfahren  
(benötigen Abstiegsrichtungen)*

# Quizfrage

Es sei  $d_k$  eine Abstiegsrichtung für  $f$  an der Stelle  $x_k$ .

Welche Rolle spielt die Krümmungsbedingung

$$f'(x_{k+1}) d_k \geq \tau f'(x_k) d_k$$

(Wolfe-Liniensuche)

Quasi-Newton-Verfahren?

→ Umfrage

$$\left. \begin{aligned} s_k &= (x_{k+1} - x_k) \\ s_k &= \alpha_k d_k \end{aligned} \right\} x_{k+1} = x_k + \alpha_k d_k$$

5  A sichert  $s_k^T H_{k+1} s_k > 0$

1  B bringt guten Abstieg bei der Liniensuche

2  C sichert  $H_{k+1}^{\text{BFGS}}$  spd ← Lemma 5-36

0  D keine besondere Rolle, man kann auch eine

$$s_k^T H_{k+1} s_k = s_k^T y_k = (\nabla f(x_{k+1}) - \nabla f(x_k))^T s_k$$

$\underbrace{f'(x_{k+1}) d_k}_{> \tau} \geq \tau \underbrace{f'(x_k) d_k}_{> 0} > \underbrace{f'(x_k) d_k}_{> 0}$

Armijo-Liniensuche verwenden

$\text{Rang}(AB) \leq \min\{\text{Rang}(A), \text{Rang}(B)\}$

# Quizfrage

Wie wird die Sherman-Morrison-Woodbury-Formel

$$\boxed{\phantom{A}} + \boxed{U} \boxed{C} \boxed{V} \boxed{\phantom{A}}^{-1} = \boxed{A}^{-1} \boxed{-A^{-1}U(C^{-1} + VA^{-1}U)^{-1}VA^{-1}} \boxed{\phantom{A}}$$

mit  $A \in \mathbb{R}^{n \times n}$ ,  $C \in \mathbb{R}^{\ell \times \ell}$ ,  $U \in \mathbb{R}^{n \times \ell}$  und  $V \in \mathbb{R}^{\ell \times n}$   
typischerweise verwendet?

Aufgabenangabe  $\rightarrow$  Rang  $\ell$

$\uparrow$   
Rang  $\leq \ell \leq n$

$\rightarrow$  Umfrage

A  $n = \ell$  und  $A^{-1}$  bekannt

B  $n < \ell$  und  $A^{-1}$  bekannt

C  $n = \ell$  und  $A^{-1}$  gesucht

D  $\ell < n$  und  $A^{-1}$  bekannt

# Quizfrage

Wozu wird die SMW-Formel im Kontext von Quasi-Newton-Verfahren verwendet?

→ Umfrage

1 A zur Lösung von  $H_k d_k = -\nabla f(x_k)$

2 C Herleiten einer Update-Formel für  $H_k^{-1} \rightsquigarrow H_{k+1}^{-1}$

$A = H_k$   
 $A + UCV = H_{k+1}$  } low-rank Update (oft  $l=2$ )  
 $\Rightarrow H_{k+1}^{-1} = H_k^{-1} - \dots$

0 B für den Konvergenzbeweis  $x_k \rightarrow x^*$

0 D für den Beweis der q-superlinearen Konvergenz

mit inverser Formel:  $B_k = H_k^{-1}$

$H_k d_k = -\nabla f(x_k)$  LGS!

(=)  $d_k = -B_k \nabla f(x_k)$  kann LGS!

# Quizfrage

$$\mathbb{1} = \in \mathbb{R}^{n \times n}$$

Was ist ein Nachteil der Verwendung von Quasi-Newton-Matrizen  $H_k$  bzw. der Inversen  $B_k$ ?

→ Umfrage *typisch:  $H_0$  voll dünnbesetzt  
 $H_1 = \text{Rang-2-Update von } H_0$   
nicht mehr dünnbesetzt*

A Berechnungsaufwand für  $H_k$   
bzw.  $B_k$  (*Aufdehnung*)

B Speicherbedarf

C exakte Lösung der linearen  
Gleichungssysteme

D fehlende Symmetrie

$$H_k d_k = -\nabla f(x_k)$$

*(man kann das auch iterativ  
und exakt machen oder gleich  
mit  $d_k = -B_k \nabla f(x_k)$  arbeiten)*

# Quizfrage

Wie kann man den Speicherbedarf von Quasi-Newton-Matrizen sinnvoll reduzieren?

→ Umfrage

keine Superlineare K.

0 A Zurücksetzen von  $H_k$  auf  $H_0$  alle  $m_{\max}$  Iterationen

1 C durch Speichern aller Vektorpaare jeweils zu  $(y_0, s_0), (y_1, s_1), \dots$

z.B. inverses BFGS:  $B_0 g$ ,  
 $d_k = -B_k \nabla f(x_k)$

keine superlin. K. (Gradientenverfahren)

0 B durch Verwenden einer festen Matrix  $H_k \equiv M$

7 D durch Speichern nur einiger Paare von Vektoren  $\{(y_i, s_i)\}_{i=k-m, \dots, k-1}$

$$B_1 g = V_0^T B_0 V_0 g + \gamma_0 s_0 s_0^T g \\ = I - \gamma_0 y_0 s_0, \quad \gamma_0 = y_0^T s_0$$

# Auswertung von $B_k^{\text{LM-BFGS}}$ $g$

limited-memory

- 1: Setze  $r := g$
- 2: **for**  $i := k - 1, k - 2, \dots, k - m$  **do**
- 3:     Setze  $\alpha_i := \gamma_i s_i^T r$
- 4:     Setze  $r := r - \alpha_i y_i$
- 5: **end for**     *seed matrix*     //  $r = V_{k-m} V_{k-m+1} \dots V_{k-1} g$
- 6: Setze  $d := B_0^{\text{BFGS}} r$
- 7: **for**  $i := k - m, \dots, k - 2, k - 1$  **do**
- 8:     Setze  $\beta := \gamma_i y_i^T d$
- 9:     Setze  $d := d + (\alpha_i - \beta) s_i$
- 10: **end for**
- 11: **return**  $d$      //  $d = B_k^{\text{LM-BFGS}} g$

$B_0^{\text{BFGS}}$  Vektors  $\hat{=} H^{-1}$  Vektors

$H_0^{\text{BFGS}}$   $\hat{=} H$  (Basismethode im Raum der Optimierungsvorgängen)

# Nichtlineare CG-Verfahren

*mit Aspd*

Minimiere  $\frac{1}{2}x^T A x - b^T x$

▶  $r_k = Ax_k - b$

▶  $d_0 = -M^{-1}r_0$

▶  $d_k = -M^{-1}r_k + \beta_k d_{k-1}$

▶  $d_k^T A d_{k+1} = 0$

▶ exakte Liniensuche

Minimiere  $f(x)$

↔ ▶  $r_k = \nabla f(x_k)$

▶  $d_0 = -M^{-1}r_0$

▶  $d_k = -M^{-1}r_k + \beta_k d_{k-1}$

▶ verschiedene Möglichkeiten,  $\beta_k$  zu wählen

▶ inexakte Liniensuche  
(Wolfe oder starke Wolfe)

↑ Dieselben Zertarten wie Gradientenverfahren!

# Nichtlineares CG-Verfahren

- 1: Setze  $k := 0$
- 2: Setze  $r_0 := \nabla f(x_0)$
- 3: Setze  $d_0 := -M^{-1} r_0$
- 4: Setze  $\delta_0 := -r_0^T d_0$  //  $\delta_0 = \|\nabla_M f(x_0)\|_M^2$
- 5: **while** Abbruchkriterium nicht erfüllt **do**
- 6:     Bestimme  $\alpha_k$  über eine Liniensuche
- 7:     Setze  $x_{k+1} := x_k + \alpha_k d_k$
- 8:     Setze  $r_{k+1} := \nabla f(x_{k+1})$
- 9:     Setze  $d_{k+1} := -M^{-1} r_{k+1}$
- 10:     Setze  $\delta_{k+1} := -r_{k+1}^T d_{k+1}$  //  $\delta_{k+1} = \|\nabla_M f(x_{k+1})\|_M^2$
- 11:     Wähle  $\beta_{k+1}$
- 12:     Setze  $d_{k+1} := d_{k+1} + \beta_{k+1} d_k$
- 13:     Setze  $k := k + 1$
- 14: **end while**
- 15: **return**  $x_k$

# Nächste Woche

- ▶ **keine** Konsultation am 16.12.2020
- ▶ Behandlung des Materials der Wochen 8 und 9 (Trust-Region-Verfahren) in der nächsten Konsultation am 06.01.2021



Credits: Downloaded in hoher Auflösung ohne Wasserzeichen von AGNES KARIKATUREN  
Free high resolution file without watermark available at: [www.Live-Karikaturen.de](http://www.Live-Karikaturen.de)

CC-BY-SA Agnes Karikaturen

# Zeit für Ihre Fragen

Was sind Ihre Fragen zu den Themen der Woche?

→ Benutzen Sie den **Chat**.

# Fragen und Antworten 1

# Fragen und Antworten 2