

Gleichungssysteme: Globale Newtonverfahren

Dirk Schröder

Residuum basierter Abstieg

Gedämpfte Newton Iteration:

$$F'(x^k)\Delta x^k = -F(x^k), \quad x^{k+1} = x^k + \lambda_k \Delta x^k \quad (\lambda_k \in (0, 1])$$

Kontrahierendes Residuum:

$$\|F(x^{k+1})\| < \|F(x^k)\|$$

Programm des Vortrags

- Theorie
 - optimale Dämpfungsfaktoren
 - Globale Konvergenz in einem Bereich dieser Faktoren

Programm des Vortrags

- Theorie
 - optimale Dämpfungsfaktoren
 - Globale Konvergenz in einem Bereich dieser Faktoren
- Praxis

Ziel: Residuum basierte Strategien für die Wahl der Dämpfungsfaktoren

 - exakte Newton Korrektur
 - inexakte Variante mit dem iterativen Löser von GMRES

Affine Contravarianz: Konvergenzanalyse

Ziel: Finde Schrittweite entlang der Newtonrichtung, so dass die Residuumreduktion in gewisser Weise optimal ist.

Lokaler Abstieg

Sei $F \in C^1(D)$ mit $D \subset \mathbb{R}^n$ offen konvex und $F'(x)$ nicht-singulär für alle $x \in D$. Es gelte weiterhin die spezielle affin, contravariante Lipschitzbedingung:

$$\|(F'(y) - F'(x))(y - x)\| \leq \omega \|F'(x)(y - x)\|^2 \text{ für } x, y \in D.$$

Lokaler Abstieg

Sei $F \in C^1(D)$ mit $D \subset \mathbb{R}^n$ offen konvex und $F'(x)$ nicht-singulär für alle $x \in D$. Es gelte weiterhin die spezielle affin, contravariante Lipschitzbedingung:

$$\|(F'(y) - F'(x))(y - x)\| \leq \omega \|F'(x)(y - x)\|^2 \text{ für } x, y \in D.$$

Dann gilt mit $h_k := \omega \|F'(x^k)\|$ und $\lambda \in [0, \min(1, 2/h_k)]$:

$$\|F(x^k + \lambda \Delta x^k)\|_2 \leq t_k(\lambda) \|F(x^k)\|_2,$$

mit $t_k(\lambda) := 1 - \lambda + \frac{1}{2} \lambda^2 h_k$.

Lokaler Abstieg

Sei $F \in C^1(D)$ mit $D \subset \mathbb{R}^n$ offen konvex und $F'(x)$ nicht-singulär für alle $x \in D$. Es gelte weiterhin die spezielle affin, contravariante Lipschitzbedingung:

$$\|(F'(y) - F'(x))(y - x)\| \leq \omega \|F'(x)(y - x)\|^2 \text{ für } x, y \in D.$$

Dann gilt mit $h_k := \omega \|F(x^k)\|$ und $\lambda \in [0, \min(1, 2/h_k)]$:

$$\|F(x^k + \lambda \Delta x^k)\|_2 \leq t_k(\lambda) \|F(x^k)\|_2,$$

mit $t_k(\lambda) := 1 - \lambda + \frac{1}{2} \lambda^2 h_k$. Die optimale Wahl des Dämpfungsfaktor im Sinne dieser lokaler Abschätzung ist

$$\bar{\lambda}_k := \min(1, 1/h_k).$$

Globale Konvergenz

Zusätzlich zu den vorherigen Voraussetzungen sei D_0 die wegzusammenhängende Komponente von $G(x^0) := \{y \in D \mid T(y) \leq T(x^0)\}$ in x^0 und sei $D_0 \subseteq D$ kompakt. Weiter sei die Jacobimatrix $F'(x)$ nicht-singulär für alle $x \in D_0$.

Globale Konvergenz

Zusätzlich zu den vorherigen Voraussetzungen sei D_0 die wegzusammenhängende Komponente von $G(x^0) := \{y \in D \mid T(y) \leq T(x^0)\}$ in x^0 und sei $D_0 \subseteq D$ kompakt. Weiter sei die Jacobimatrix $F'(x)$ nicht-singulär für alle $x \in D_0$.

Dann konvergiert die gedämpfte Newtoniteration ($k = 0, 1, \dots$) mit Dämpfungsfaktoren im Bereich von

$$\lambda_k \in [\epsilon, 2\bar{\lambda}_k - \epsilon]$$

und von D_0 abhängenden genügend kleinen $\epsilon > 0$ gegen eine Lösung x^* .

Adaptive trust region strategy

Die h_k sind wegen der Lipschitzkonstante ω nicht verfügbar.

Adaptive trust region strategy

Die h_k sind wegen der Lipschitzkonstante ω nicht verfügbar.

Idee: Ersetze ω durch Schätzung $[\omega]$ und h_k durch

$$[h_k] = [\omega] \|F(x^k)\|.$$

Adaptive trust region strategy

Die h_k sind wegen der Lipschitzkonstante ω nicht verfügbar.

Idee: Ersetze ω durch Schätzung $[\omega]$ und h_k durch

$$[h_k] = [\omega] \|F(x^k)\|.$$

$$\Rightarrow [\omega] \leq \omega, [h_k] \leq h_k$$

Adaptive trust region strategy

Die h_k sind wegen der Lipschitzkonstante ω nicht verfügbar.

Idee: Ersetze ω durch Schätzung $[\omega]$ und h_k durch

$$[h_k] = [\omega] \|F(x^k)\|.$$

$$\Rightarrow [\omega] \leq \omega, [h_k] \leq h_k$$

Optimale Dämpfungsfaktoren:

$$[\bar{\lambda}_k] := \min(1, 1/[h_k])$$

Bit Counting Lemma

Angenommen das gedämpfte Newtonverfahren wurde mit Dämpfungsfaktoren $[\bar{\lambda}_k] := \min(1, 1/[h_k])$ durchgeführt. Weiterhin gelte für die Schätzungen:

$$0 \leq h_k - [h_k] < \sigma \max(1, [h_k]) \text{ für ein } \sigma < 1.$$

Bit Counting Lemma

Angenommen das gedämpfte Newtonverfahren wurde mit Dämpfungsfaktoren $[\bar{\lambda}_k] := \min(1, 1/[h_k])$ durchgeführt. Weiterhin gelte für die Schätzungen:

$$0 \leq h_k - [h_k] < \sigma \max(1, [h_k]) \text{ für ein } \sigma < 1.$$

Dann ergibt der Residuum-Monotonietest:

$$\|F(x^{k+1})\| \leq \left(1 - \frac{1}{2}(1 - \sigma)\lambda\right) \|F(x^k)\|.$$

Bit Counting Lemma

Angenommen das gedämpfte Newtonverfahren wurde mit Dämpfungsfaktoren $[\bar{\lambda}_k] := \min(1, 1/[h_k])$ durchgeführt. Weiterhin gelte für die Schätzungen:

$$0 \leq h_k - [h_k] < \sigma \max(1, [h_k]) \text{ für ein } \sigma < 1.$$

Dann ergibt der Residuum-Monotonietest:

$$\|F(x^{k+1})\| \leq (1 - \frac{1}{2}(1 - \sigma)\lambda) \|F(x^k)\|.$$

Es reicht also das führende Bit von λ_k mit $[\lambda_k]$ zu treffen, damit das Residuum monoton fällt.

Das gedämpfte Newtonverfahren kann als Abstieg des dazugehörigen Newtonpfades interpretiert werden.

geeignete Schätzer

Das gedämpfte Newtonverfahren kann als Abstieg des dazugehörigen Newtonpfades interpretiert werden.

$$\Rightarrow \|F(x^{k+1}) - (1 - \lambda)F(x^k)\| \leq \frac{1}{2}\lambda^2\omega\|F(x^k)\|^2.$$

geeignete Schätzer

Das gedämpfte Newtonverfahren kann als Abstieg des dazugehörigen Newtonpfades interpretiert werden.

$$\Rightarrow \|F(x^{k+1}) - (1 - \lambda)F(x^k)\| \leq \frac{1}{2}\lambda^2\omega\|F(x^k)\|^2.$$

$$\Rightarrow [h_k] := \frac{2\|F(x^{k+1}) - (1 - \lambda)F(x^k)\|}{\lambda^2\|F(x^k)\|} \leq h_k.$$

Prädiktor- und Korrektorstrategie

Wir brauchen mindestens einen Versuchswert

$$x^{k+1} = x^k + \lambda_k^0 \Delta x^k.$$

Prädiktor- und Korrektorstrategie

Wir brauchen mindestens einen Versuchswert

$$x^{k+1} = x^k + \lambda_k^0 \Delta x^k.$$

Korrektorstrategie: $\lambda_k^{i+1} := \min(\frac{1}{2} \lambda_k^i, 1/[h_k^{i+1}])$.

Prädiktor- und Korrektorstrategie

Wir brauchen mindestens einen Versuchswert

$$x^{k+1} = x^k + \lambda_k^0 \Delta x^k.$$

Korrektorstrategie: $\lambda_k^{i+1} := \min(\frac{1}{2} \lambda_k^i, 1/[h_k^{i+1}])$.

Wir brauchen noch ein λ_k^0 :

$$h_{k+1} = \frac{\|F(x^{k+1})\|}{\|F(x^k)\|} h_k \Rightarrow [h_{k+1}^0] = \frac{\|F(x^{k+1})\|}{\|F(x^k)\|} [h_k^{i_*}] < [h_k^{i_*}].$$

Prädiktor- und Korrektorstrategie

Wir brauchen mindestens einen Versuchswert

$$x^{k+1} = x^k + \lambda_k^0 \Delta x^k.$$

Korrektorstrategie: $\lambda_k^{i+1} := \min(\frac{1}{2} \lambda_k^i, 1/[h_k^{i+1}])$.

Wir brauchen noch ein λ_k^0 :

$$h_{k+1} = \frac{\|F(x^{k+1})\|}{\|F(x^k)\|} h_k \Rightarrow [h_{k+1}^0] = \frac{\|F(x^{k+1})\|}{\|F(x^k)\|} [h_k^{i_*}] < [h_k^{i_*}].$$

Prädiktorstrategie: $\lambda_{k+1}^0 := \min(1, 1/[h_{k+1}^0])$.

Quasi-Newton-Zwischenschritte

Falls $\lambda_k = 1$ und der Residuum Monotonietest ergibt:

$$\Theta = \frac{\|F(x^{k+1})\|}{\|F(x^k)\|} \leq \Theta_{\max} < 1$$

Dann ist das Residuumbasierte Quasi-Newtonverfahren anwendbar. Das heisst, Die Jacobimatrixauswertung ist durch ein Residuum rank-1 update ersetzt.

Inexaktes Newton-RES-Verfahren

Inexaktes globales Newton-Verfahren:

$$x^{k+1} = x^k + \lambda_k \delta x^k, \quad 0 < \lambda_k \leq 1$$

mit GMRES als iterativen linearen Gleichungslöser:

$$F'(x^k) \delta x^k = -F(x^k) + r^k.$$

Konvergenzanalyse

Vorraussetzungen sind wie bei der exakten Variante.

Konvergenzanalyse

Vorraussetzungen sind wie bei der exakten Variante.
Die inexakte Newton-GMRES Iteration erfüllt:

$$\Theta_k := \frac{\|F(x^{k+1})\|}{\|F(x^k)\|} \leq t_k(\lambda_k, \mu_k)$$

mit

$$t_k(\lambda, \mu) = 1 - (1 - \mu)\lambda + \frac{1}{2}\lambda^2(1 - \mu^2)h_k, \mu_k = \frac{\|r^k\|_2}{\|F(x^k)\|_2} < 1.$$

Die optimale Wahl des Dämpfungsfaktor ist:

$$\bar{\lambda}_k := \min\left(1, \frac{1}{(1 + \mu_k)h_k}\right).$$

Dämpfungs-faktoren:

$$[\bar{\lambda}_k] := \min\left(1, \frac{1}{(1 + \mu_k)[h_k]}\right)$$

Monotonietest

Dämpfungs-faktoren:

$$[\bar{\lambda}_k] := \min\left(1, \frac{1}{(1 + \mu_k)[h_k]}\right)$$

Beschränkter Residuum Monotonietest:

$$\|F(x^{k+1})\|_2 \leq \left(1 - \frac{1 - \mu_k}{4} \lambda_k\right) \|F(x^k)\|_2$$

Adaptive trust region Methode

A-posteriori Schätzer:

$$[h_k](\lambda) := \frac{2\|F(x^{k+1}(\lambda)) - (1-\lambda)F(x^k) - \lambda r^k\|_2}{\lambda^2(1-\mu_k^2)\|F(x^k)\|_2} \leq h_k$$

Adaptive trust region Methode

A-posteriori Schätzer:

$$[h_k](\lambda) := \frac{2\|F(x^{k+1}(\lambda)) - (1 - \lambda)F(x^k) - \lambda r^k\|_2}{\lambda^2(1 - \mu_k^2)\|F(x^k)\|_2} \leq h_k$$

Korrekturstrategie ($i=0, 1, \dots, i_k^*$):

$$\lambda_k^{i+1} = \min\left(\frac{1}{2}\lambda_k^i, \frac{1}{(1 + \mu_k)[h_k^i]}\right)$$

Adaptive trust region Methode

A-priori Schätzer:

$$[h_{k+1}^0] := \Theta_k[h_k^{i*}] \leq h_{k+1}$$

Adaptive trust region Methode

A-priori Schätzer:

$$[h_{k+1}^0] := \Theta_k [h_k^{i*}] \leq h_{k+1}$$

Prädiktorstrategie:

$$\lambda_{k+1}^0 := \min\left(1, \frac{1}{(1 + \mu_{k+1})[h_{k+1}^0]}\right)$$

Vielen Dank für Ihre Aufmerksamkeit.