

# Numerisches Programmieren (IN0019)

Frank R. Schmidt

Winter Semester 2016/2017

## 10. Minimieren von Funktionen

### Gradienten-Abstieg

### Differenzierbare Funktionen

Im Weiteren gehen wir sogar davon aus, dass  $f \in C^1(\mathbb{R})$  ist, d.h. dass  $f$  mindestens einmal **stetig differenzierbar** ist.

Wir wissen dann, dass das Minimum  $x^*$  von  $E$  die Bedingung  $f'(x^*) = 0$  erfüllt, d.h.  $x^*$  ist ein **kritischer Punkt** von  $f$ . Im Folgenden sind wir daran interessiert einen kritischen Punkte zu finden. Es handelt sich hierbei nicht notwendigerweise um ein globales Minimum.

Ist nun  $f'(x_0) < 0$ , so gibt es ein  $\varepsilon > 0$ , so dass

$$0 > \frac{f(x_0 + h) - f(x_0)}{h} \quad \forall h, |h| < \varepsilon$$
$$f(x_0) > f(x_0 + h) \quad \forall h, 0 < h < \varepsilon$$

Analog gilt für  $f'(x_0) > 0$ , dass  $f(x_0) > f(x_0 - h)$ , d.h. wenn man  $f$  in **Richtung der negativen Ableitung variiert**, sinkt der Wert von  $f$ .

### Schrittweite

Bei der Iterationsfolge

$$x_{k+1} = x_k - t_k \cdot f'(x_k)$$

nennen wir  $t_k$  die **Schrittweite**. Eine optimale Schrittweite zu finden, d.h. eine Schrittweite, so dass  $f$  möglichst stark sinkt ist nicht einfach.

Ein bewährtes Verfahren besteht darin, mit einer festen Schrittweite, z.B.  $t = 1$  zu starten und diese iterativ zu verbessern:

```
1 // f: function - x: position - d: derivative
2 while (f(x-t*d)>=f(x)) t /= 2.0;
3 x = x - t*d;
```

Hierbei wird benutzt, dass das komplette Intervall  $(0; \varepsilon)$  Schrittweiten liefert, die alle die Funktion  $f$  reduzieren.

### Minimierungsproblem

Viele Probleme lassen sich als Minimierungsproblem darstellen.

Hierzu definiert man eine Funktion, die zu jeder gültigen Lösung  $x$  eines Problems einen Wert  $f(x)$  zuordnet. Das Problem ist gelöst, wenn man das  $x^*$  findet, das die **Auswertungsfunktion**  $f$  minimiert.

Im Folgenden wollen wir also das Minimum einer Funktion  $f: \mathbb{R} \rightarrow \mathbb{R}$  finden, ohne alle Stellen  $x \in \mathbb{R}$  auszuwerten.

Daher fordern wir eine gewisse **Regularität** von  $f$ . Wir benötigen mindestens **Stetigkeit**, da wir andernfalls das Minimum der Funktion

$$f: \mathbb{R} \rightarrow \mathbb{R}$$
$$x \mapsto \begin{cases} 1 & x \neq 0 \\ 0 & x = 0 \end{cases}$$

nur Finden können, wenn  $f$  an allen Stellen ausgewertet wird.

### Iterationsfolge

Benutzen wir die Taylorapproximation von  $f$ , so erhalten wir

$$f(x_0 + h) \approx f(x_0) + f'(x_0) \cdot h$$
$$f(x_0 - t f'(x_0)) \approx f(x_0) - \underbrace{t f'(x_0)^2}_{\text{erwartete Reduktion}},$$

d.h. wir können eine größere Reduktion von  $f$  erwarten, wenn  $t$  größer ist.

Allerdings gilt die obige Approximation nur für  $t |f'(x_0)| < \varepsilon$ . Somit muss  $t$  groß gewählt sein, aber nicht zu groß.

Insgesamt erhalten wir also eine Iterationsfolge zum Finden eines lokalen Minimums von  $f$ :

$$x_{k+1} = x_k - t_k \cdot f'(x_k)$$

**Aber:** Wie ist  $t_k$  zu wählen?

### Konvergenz

Die Iterationsfolge  $x_k$  ist derart, dass  $f(x_k)$  eine **monoton fallende Folge** ist, die durch das Minimum von  $f$  **nach unten beschränkt** ist.

Daher konvergiert  $f(x_k)$ . Allerdings konvergiert  $f(x_k)$  nicht notwendigerweise zu einem lokalen Minimum.


Um ein lokale Minimum zu gewährleisten, muss man zusätzliche Eigenschaften von der Schrittweite fordern.

Ein Beispiel hierfür ist die **Armijo-Bedingung** ( $0 < \alpha < 1$ )

$$f(x_{k+1}) \leq f(x_k) - \alpha \cdot t_k \cdot f'(x_k)^2$$

Diese Bedingung garantiert ein lokales Minimum.

Oft wählt man ein kleines  $\alpha$  (z.B.  $\alpha = 10^{-4}$ ).



$f(x_k)$  konvergiert nicht notwendigerweise zum Minimum.

Dies liegt daran, dass die Menge gültiger Schrittweiten zu groß ist.

Die Armijo-Bedingung schränkt die Schrittweiten so ein, dass Konvergenz zu einem lokalen Minimum garantiert wird.

Dies wird erreicht indem man nur solche Schrittweiten zulässt, die zumindest einen Anteil  $\alpha < 1$  der erwarteten Reduktion garantiert.

In den meisten Anwendungen ist man an der Minimierung einer Funktion  $f: \mathbb{R}^n \rightarrow \mathbb{R}$  interessiert.

Anstatt die Stelle  $x_n$  in die Richtung der negativen Ableitung zu verschieben, verschiebt man sie in die Richtung des negativen Gradienten. Man nennt dieses Verfahren das **Gradienten-Abstiegs-Verfahren** (eng. **Gradient Descent**).

Die Iterationsfolge ist

$$x_{n+1} = x_n - t_n \cdot \nabla f(x_n)$$

Die Armijo-Bedingung wird dann zu

$$f(x_{n+1}) \leq f(x_n) - \alpha \cdot t_n \cdot \|\nabla f(x_n)\|^2$$

## Newton-Verfahren

## Newton-Verfahren im $\mathbb{R}^n$

Zur **Nullstellen-Berechnung** einer Funktion  $g: \mathbb{R}^n \rightarrow \mathbb{R}^n$  können wir das Newton-Verfahren benutzen.

Für  $n = 1$  erhalten wir die klassische Newton-Iteration

$$x_{k+1} = x_k - \frac{g(x_k)}{g'(x_k)}$$

Für allgemeines  $n$  gilt dann

$$x_{k+1} = x_k - J[g](x)^{-1}g(x) \quad J[g](x) = \begin{pmatrix} \frac{\partial g_1}{\partial x_1} & \dots & \frac{\partial g_1}{\partial x_n} \\ \vdots & \ddots & \vdots \\ \frac{\partial g_n}{\partial x_1} & \dots & \frac{\partial g_n}{\partial x_n} \end{pmatrix} \in \mathbb{R}^{n \times n}$$

wobei  $J[g](x)$  die **Jacobi-Matrix** von  $g$  an der Stelle  $x$  ist.

## Minimieren mittels Newton-Verfahren

Wenn wir an einem **lokalen Minimum** von  $f: \mathbb{R}^n \rightarrow \mathbb{R}$  interessiert sind, reicht es die Nullstellen von  $\nabla f: \mathbb{R}^n \rightarrow \mathbb{R}^n$  zu finden.

Hierzu können wir das Newton-Verfahren benutzen:


$$x_{k+1} = x_k - H(x)^{-1} \nabla f(x),$$

wobei  $H(x)$  die (symmetrische) **Hesse-Matrix** von  $f$  ist:

$$H(x) = J[\nabla f](x) = \begin{pmatrix} \frac{\partial^2 f}{\partial x_1 \partial x_1} & \dots & \frac{\partial^2 f}{\partial x_1 \partial x_n} \\ \vdots & \ddots & \vdots \\ \frac{\partial^2 f}{\partial x_n \partial x_1} & \dots & \frac{\partial^2 f}{\partial x_n \partial x_n} \end{pmatrix} \in \mathbb{R}^{n \times n}$$

In jedem Schritt muss ein lineares Gleichungssystem gelöst werden.

## Newton-Verfahren (Bsp.)



In jedem Schritt des **Gradienten-Abstiegs-Verfahrens** reduziert man die Funktion entlang einer Richtung (Gradienten-Richtung).

Das kann das zu vielen Iterationen führen.

Das Newton-Verfahren erreicht das Minimum in wesentlich weniger Iterationen.

Allerdings muss in jedem Newton-Schritt ein neues lineares Gleichungssystem (LGS) gelöst werden.

## Gauß-Seidel

## Iterative Lösung von LGS

Im Folgenden wollen wir uns mit der Lösung linearer Gleichungen  $Ax = b$  beschäftigen, die beim Newton-Verfahren auftreten.

Weil Hesse-Matrizen symmetrisch sind, fordern wir, dass  $A$  **symmetrisch** ist.

Oft treten in der Praxis Matrizen auf, die nur  $\mathcal{O}(n)$  Einträge besitzen, die  $a_{ij} \neq 0$  erfüllen. Solche Matrizen heißen **dünn besetzt** (eng. **sparse**).

Ist eine Matrix  $A$  dünn besetzt, so lässt sich die Matrix-Vektor-Multiplikation in  $\mathcal{O}(n)$  Schritten durchführen.

**Ziel:** Finde ein iteratives Verfahren, das schnell konvergiert. Dann werden statt  $\mathcal{O}(n^3)$  nur  $\mathcal{O}(n) \cdot \#$  Iterationen Schritte benötigt.

**Vorteil:** Der Speicherbedarf ist weiterhin  $\mathcal{O}(n)$  und nicht  $\mathcal{O}(n^2)$  wie bei der LU- oder der QR-Zerlegung. (Oft ist  $n > 10^6$ )

# Richardson-Iteration

Gradienten-Abstieg    Newton-Verfahren    Gauß-Seidel    Bild-Entrauschen

Ziel bei iterativen Verfahren ist es, ein Fixpunktproblem zu formulieren:

$$b = Ax = (A - I)x + x \quad \Leftrightarrow \quad x = x + (b - Ax)$$

Daraus ergibt sich die **Richardson-Iteration**

$$x_{k+1} = x_k + (b - Ax_k) =: \Phi(x_k)$$

Damit  $x^* = A^{-1}b$  ein anziehender Fixpunkt ist, muss Folgendes gelten:

$$1 > \limsup_{h \rightarrow 0} \frac{\|\Phi(x^* + h) - \Phi(x^*)\|}{\|h\|} = \limsup_{h \rightarrow 0} \frac{\|(I - A)h\|}{\|h\|} = \|A - I\|_2$$

$x^*$  ist ein anziehender Fixpunkt genau dann, wenn für alle **Eigenwerte**  $\lambda_i$  von  $A$  gerade  $0 < \lambda_i < 2$  gilt.

Das Richardson-Verfahren ist also nur sinnvoll, wenn  $A \approx I$  gilt.

# Richardson-Iteration (Bsp.)

Gradienten-Abstieg    Newton-Verfahren    Gauß-Seidel    Bild-Entrauschen

Betrachten wir beispielhaft folgende LGS

$$\underbrace{\begin{pmatrix} 0.5 & 0 \\ 0 & 1 \end{pmatrix}}_{A_0} \cdot x = \underbrace{\begin{pmatrix} 0.5 \\ 1 \end{pmatrix}}_{b_0} \quad \text{und} \quad \underbrace{\begin{pmatrix} 1 & 0 \\ 0 & 3 \end{pmatrix}}_{A_1} \cdot x = \underbrace{\begin{pmatrix} 1 \\ 3 \end{pmatrix}}_{b_1}$$

die beide die eindeutige Lösung  $x = \begin{pmatrix} 1 \\ 1 \end{pmatrix}$  haben.

Initialisieren wir die Richardson-Iteration ( $x + (b - Ax)$ ) mit dem Nullvektor, erhalten wir folgende Iterationsfolgen:

$$A_0: \begin{pmatrix} 0 & 0 \\ 0 & 0 \end{pmatrix} \quad \begin{pmatrix} 0.5 \\ 1 \end{pmatrix} \quad \begin{pmatrix} 0.75 \\ 1 \end{pmatrix} \quad \begin{pmatrix} 0.875 \\ 1 \end{pmatrix} \quad \begin{pmatrix} 0.9375 \\ 1 \end{pmatrix} \quad \dots \quad \begin{pmatrix} 1 \\ 1 \end{pmatrix}$$
$$A_1: \begin{pmatrix} 0 & 0 \\ 0 & 0 \end{pmatrix} \quad \begin{pmatrix} 1 \\ 3 \end{pmatrix} \quad \begin{pmatrix} 1 \\ -3 \end{pmatrix} \quad \begin{pmatrix} 1 \\ 9 \end{pmatrix} \quad \begin{pmatrix} 1 \\ -15 \end{pmatrix} \quad \dots$$

# Diagonaldominanz

Gradienten-Abstieg    Newton-Verfahren    Gauß-Seidel    Bild-Entrauschen

Wir wollen das Richardson-Verfahren auch auf eine größere Klasse von Matrizen anwenden. Dies sind die Matrizen, die im Wesentlichen durch ihre Diagonaleinträge bestimmt sind, d.h. es gilt:

$$|d_i| = |a_{ii}| > \sum_{\substack{j=1 \\ i \neq j}}^n |a_{ij}|$$

Diese Matrizen heißen **diagonaldominant**.

Im Weiteren bezeichnen wir mit  $D$  die **Diagonalmatrix** von  $A$ , d.h. die Matrix, die die Diagonaleinträge von  $A$  besitzt und sonst aus Nullen besteht.

Bezeichnet man mit  $B := D^{-1}A$ , so gilt für die Eigenwerte  $\lambda$  von  $B$  gerade

$$|\lambda - 1| \leq \sum_{\substack{j=1 \\ i \neq j}}^n \frac{|a_{ij}|}{|d_i|} < 1 \quad (\text{Gerschgorin})$$

# Jacobi-Verfahren

Gradienten-Abstieg    Newton-Verfahren    Gauß-Seidel    Bild-Entrauschen

Wir haben gesehen, dass wir bei einer diagonaldominanten Matrix  $A$ , die Richardson-Iteration auf  $D^{-1}A$  anwenden können.

Die Gleichung  $Ax = b$  wird zu  $D^{-1}Ax = D^{-1}b$  und wir erhalten:

$$x_{k+1} = x_k + (D^{-1}b - D^{-1}Ax_k) = D^{-1}[b - (A - D)x_k]$$

Dieses Verfahren heißt **Jacobi-Verfahren**.

Zerlegt man  $A$  in seine drei Komponenten:

$$A = L + D + U,$$

wobei  $L$  (bzw.  $U$ ) die Einträge unterhalb (bzw. oberhalb) der Diagonalen von  $A$  besitzt, so lässt sich das Jacobi-Verfahren wie folgt umschreiben:

$$x_{k+1} = D^{-1}[b - (L + U)x_k]$$

# Implementierung (Jacobi)

Gradienten-Abstieg    Newton-Verfahren    Gauß-Seidel    Bild-Entrauschen

Eine Jacobi-Iteration

$$x_{k+1} = D^{-1}[b - (L + U)x_k]$$

kann man wie folgt implementieren:

```
1 // A: matrix - x_old: current vector - x_new: new vector
2 for (unsigned i=0; i<n; i++) {
3   x_new[i] = b[i];
4   for (unsigned j=0; j<i; j++) {
5     x_new[i] -= A[i][j]*x_old[j];
6   }
7   for (unsigned j=i+1; j<n; j++) {
8     x_new[i] -= A[i][j]*x_old[j];
9   }
10  x_new[i] /= A[i][i];
11 }
```

Es wird also in jedem Schritt die  $i$ -te Zeile nach  $x_i$  aufgelöst.

# Gauß-Seidel-Verfahren

Gradienten-Abstieg    Newton-Verfahren    Gauß-Seidel    Bild-Entrauschen

Ein anderes Verfahren, das auf der Richardson-Iteration beruht ist das **Gauß-Seidel-Verfahren**. Es benutzt die Matrix  $B = (D + L)^{-1}A$ .

Die Gleichung  $Ax = b$  wird zu  $(D + L)^{-1}Ax = (D + L)^{-1}b$  und wir erhalten:

$$x_{k+1} = x_k + (D + L)^{-1}(b - Ax_k)$$
$$= (D + L)^{-1}[b - (A - D - L)x_k]$$
$$= (D + L)^{-1}[b - Ux_k]$$

Im Unterschied zum Jacobi-Verfahren hängt die  $i$ -te Komponente von  $x_{k+1}$  nur von der  $j$ -ten Komponente von  $x_k$  ab, wobei  $j > i$  ist.

Das heißt, wir können die Gauß-Seidel-Iteration **in place**, d.h. ohne zusätzlichen Speicherplatz durchführen.

# Gauß-Seidel-Iteration

Gradienten-Abstieg    Newton-Verfahren    Gauß-Seidel    Bild-Entrauschen

In jedem Schritt wird folgende Gleichung (nach  $y$ ) gelöst:

$$(D + L) \cdot y = b - U \cdot x$$

Das heißt:

$$\sum_{j=1}^i a_{ij}y_j = b_i - \sum_{j=i+1}^n a_{ij}x_j$$
$$a_{ii}y_i = b_i - \sum_{j=i+1}^n a_{ij}x_j - \sum_{j=1}^{i-1} a_{ij}y_j$$

$y_i$  hängt also nur von  $A$  und  $x$  ab und kann unabhängig von den übrigen  $y_i$  berechnet werden. Analog hängt  $y_2$  nur von  $A$ ,  $x$  und  $y_1$  ab und kann unabhängig von den übrigen  $y_i$  als Nächstes berechnet werden etc.

Man kann also in jedem Schritt die  $i$ -te Zeile nach  $y_i$  auflösen, wenn man zuvor die  $x_j$  ( $j < i$ ) durch  $y_j$  ersetzt.

# Implementierung (Gauß-Seidel)

Gradienten-Abstieg    Newton-Verfahren    Gauß-Seidel    Bild-Entrauschen

Eine Gauß-Seidel-Iteration

$$x_{k+1} = (D + L)^{-1}[b - U \cdot x_k]$$

kann man also wie folgt implementieren:

```
1 // A: matrix - x: current vector
2 for (unsigned i=0; i<n; i++) {
3   x[i] = b[i];
4   for (unsigned j=0; j<i; j++) {
5     x[i] -= A[i][j]*x[j];
6   }
7   for (unsigned j=i+1; j<n; j++) {
8     x[i] -= A[i][j]*x[j];
9   }
10  x[i] /= A[i][i];
11 }
```

Die Implementierung benutzt also immer die aktuellsten Werte von  $x$ .

Wir haben zwei verschiedene iterative Verfahren zum Lösen von Gleichungssystemen gefunden, die auf der **Richardson-Iteration** beruhen.

Das **Jacobi-Verfahren** und das **Gauß-Seidel-Verfahren** lösen die  $i$ -te Zeile von  $A$  nach der  $i$ -ten Variablen auf.

Das Jacobi-Verfahren benutzt die Werte  $x_k$  der vorherigen Iteration und benötigt daher einen **zusätzlichen Speicherplatz** von  $\mathcal{O}(n)$ . Da die Reihenfolge der Einträge von  $x_{k+1}$  nicht vorgegeben ist, ist es einfacher, das Jacobi-Verfahren zu **parallelisieren**.

Das Gauß-Seidel-Verfahren arbeitet **in-place** und benötigt keinen zusätzlichen Speicherplatz. Da die Reihenfolge der Einträge von  $x_{k+1}$  vorgegeben ist, ist eine Parallelisierung üblicherweise komplizierter.

Beide Verfahren konvergieren für **diagonaldominante Matrizen**.

Darüber hinaus konvergiert das Gauß-Seidel-Verfahren ebenfalls für **symmetrische positiv-definite** Matrizen. (ohne Beweis)

Um zu sehen, dass das Gauß-Seidel-Verfahren eine größere Problemklasse als das Jacobi-Verfahren lösen betrachten wir folgendes LGS


$$\begin{pmatrix} 4 & 3 & 3 \\ 3 & 4 & 3 \\ 3 & 3 & 4 \end{pmatrix} \cdot x = \begin{pmatrix} 10 \\ 10 \\ 10 \end{pmatrix},$$

welches die eindeutige Lösung  $x = (1 \ 1 \ 1)^T$  besitzt.


Initialisieren wir Jacobi (J) und Gauß-Seidel (GS) mit dem Nullvektor, erhalten wir folgende Iterationsfolgen (gerundet auf 2 Nachkommastellen):

$$\begin{aligned} \text{(GS)} : & \quad (2.5 \ 0.625 \ 0.156)^T & \quad (1.91 \ 0.947 \ 0.354)^T & \quad (1.52 \ 1.09 \ 0.538)^T \\ \text{(J)} : & \quad (2.5 \ 2.5 \ 2.5)^T & \quad (-1.25 \ -1.25 \ -1.25)^T & \quad (4.38 \ 4.38 \ 4.38)^T \end{aligned}$$

## Bild-Entrauschen



Original



Verrauscht

Sensoren sind oft ungenau und liefern meist **verrauschte Daten**.

Die Entfernung der Verrauschung nennt man **Entrauschen** (eng. Denoising).

Traditionelle Verfahren benutzen hierfür **Bildglättung** (siehe FFT-Vorlesung).

Moderne Verfahren beschreiben dies als **Minimierung einer Funktion**.

## Entrauschung durch Minimierung

Sei  $u \in \mathbb{R}^n$  eine Diskretisierung des Eingabebildes. Wir sind auf der Suche des entrauschten Bildes  $v \in \mathbb{R}^n$ , so dass

- $v$  sich nicht stark von  $u$  unterscheidet und
- $v$  kleinere Ableitungen als  $u$  besitzt.

Bezeichnen wir mit  $D_1, D_2 \in \mathbb{R}^{n \times n}$  die diskretisierten Ableitungen  $\frac{\partial}{\partial x_1}$  bzw.  $\frac{\partial}{\partial x_2}$ , so kann man folgende Funktion beschreiben:

$$f(v) = \|v - u\|^2 + \lambda \cdot [\|D_1 v\|^2 + \|D_2 v\|^2]$$

Der **Parameter**  $\lambda$  beschreibt wie wichtig die Glattheit von  $u$  ist. Für  $\lambda = 0$  ist  $v = u$  das Minimum von  $f$ . Für wachsendes  $\lambda$  wird das minimierende  $v$  immer glatter. Für  $\lambda \rightarrow \infty$  wird  $v$  schließlich konstant.

## Verbesserte Entrauschung

Da die quadratische Bestrafung der Ableitungen zu Überglättungen führen kann, benutzt man üblicherweise die folgende Funktion

$$f(v) = \|v - u\|^2 + \lambda \cdot [\|D_1 v\|^2 + \|D_2 v\|^2]^{\frac{p}{2}}$$

Für  $p = 2$  erhält man die gleiche Funktion wie zuvor.

Für  $p < 2$  werden die Ableitungen schwächer bestraft und man erhält üblicherweise bessere Ergebnisse.

Die so erhaltene Funktion ist für  $p > 1$  zweimal differenzierbar und kann mit Hilfe von Gradienten-Abstieg oder mit Hilfe des Newton-Verfahrens minimiert werden. Außerdem kann gezeigt werden, dass jedes lokale Minimum das globale Minimum ist.

Für  $p = 2$  muss nur ein einziger Newton-Schritt berechnet werden, da  $f$  dann quadratisch in  $v$  ist.

## Ergebnisse






Bild-Glättung (Faltung)




Entrauschung (p = 2)

## Ergebnisse für verschiedene p



Entrauschung (p = 2)



Entrauschung (p = 1)