



# Beispiel-Problem: Geschwindigkeit vs. Fahrstrecke



# Beispiel-Problem: Geschwindigkeit vs. Bremsweg



# Problemstellung Least Squares

- ▶ **Gegeben:** Datenreihe mit  $m$  Datenpunkten

$$(x_1, y_1), (x_2, y_2), \dots, (x_m, y_m)$$

mit  $x_j, y_j \in \mathbb{R}$  für  $j = 1, \dots, m$

- ▶ **Erwartung:**  $y_j$  enthalten Messfehler ( $j = 1, \dots, m$ )
- ▶ **Gesucht:** Funktion  $F : \mathbb{R} \rightarrow \mathbb{R}$  so dass **Approximationsfehler**

$$\eta_j = F(x_j) - y_j$$

für alle  $j = 1, \dots, m$  möglichst gering

- ▶ **Annahme:**  $F$  lässt sich darstellen als Summe von Basisfunktionen  $f_i$ ,

$$F(x) = \sum_{i=1}^n c_i f_i(x)$$

# Wahl der Basisfunktionen

## Wahl der Basisfunktionen $f_i$ für $F$ :

- ▶ typische Wahl:  $f_i(x) = x^{i-1}$ , dann

$$F(x) = c_1 + c_2x + c_3x^2 + \dots + c_nx^{n-1}$$

(Polynom in  $x$  vom Grad  $n - 1$ )

- ▶ auch oft mit  $n = 2$ , dann

$$F(x) = c_1 + c_2x$$

(Gerade) auch genannt **lineare Regression**

- ▶ im Fall von Tomographie: Pixel- oder Voxel-Basisfunktionen

# Matrix-Notation

- ▶ für die verschiedenen Datenpunkte  $x_j, j = 1, \dots, m$ , kann  $F$  geschrieben werden als:

$$\begin{pmatrix} F(x_1) \\ \vdots \\ F(x_m) \end{pmatrix} = \underbrace{\begin{pmatrix} f_1(x_1) & \cdots & f_n(x_1) \\ \vdots & & \vdots \\ f_1(x_m) & \cdots & f_n(x_m) \end{pmatrix}}_{=:A} \underbrace{\begin{pmatrix} c_1 \\ \vdots \\ c_n \end{pmatrix}}_{=:c}$$

mit  $A \in \mathbb{R}^{m \times n}$ ,  $c \in \mathbb{R}^n$ .

- ▶ untersucht wird dann der **Approximationsfehler**  $\eta$

$$\eta = Ac - y$$

mit  $\eta = (\eta_1, \dots, \eta_m) \in \mathbb{R}^m$ ,  $y = (y_1, \dots, y_m) \in \mathbb{R}^m$ .

# Daten mit Meßfehler

ist  $m = n$  und  $A$  invertierbar, so kann direkt

$$Ac - y = 0$$

gelöst werden.

## Problem:

- ▶ selbst wenn  $A$  invertierbar ist,  $y$  enthält Meßfehler
- ▶ Lösung  $F$  ist dann meist **nicht** die **gewünschte** Lösung
- ▶ passt sich zu sehr an "Ausreißer" an

**besser:** mehr Datenpunkte,  $m \gg n$

# Minimierung des Approximationsfehlers

- ▶ zur **Minimierung des Approximationsfehlers** kann z.B. die Norm  $\|\eta\|$  betrachtet werden

$$\|\eta\| = \left( \sum_{j=1}^m \eta_j^2 \right)^{\frac{1}{2}} = \sqrt{\sum_{j=1}^m \eta_j^2}$$

- ▶ zur Vereinfachung betrachtet man üblicherweise

$$\|\eta\|^2 = \|Ac - \mathcal{Y}\|^2 = \sum_{j=1}^m \left( \sum_{i=1}^n a_{ji}c_i - \mathcal{Y}_j \right)^2$$

- ▶ daher der Name: **Methode der kleinsten Quadrate** oder **Least squares**

# Least-squares Lösung

## Least-squares Lösung

Sei  $A \in \mathbb{R}^{m \times n}$ ,  $y \in \mathbb{R}^m$  mit  $m \geq n$ . Eine Lösung  $c \in \mathbb{R}^n$  des Minimierungs-Problems

$$\min_c \|Ac - y\| \quad \text{or} \quad \min_c \|Ac - y\|^2$$

heißt **Least-squares Lösung**.

## Anwendungs-Beispiele:

- ▶ Tracking von Objekten mit Kameras
- ▶ Kalibrierung von Kameras, Robotern, etc.
- ▶ Iterative Rekonstruktion für Tomographie



# Normalengleichung

- ▶ Berechnung der **Least-squares Lösung** mit Standard-Technik  
“Ableitung gleich null setzen”
- ▶ hier: partielle Ableitungen für  $k = 1, \dots, n$

$$\frac{\partial \|\eta\|^2}{\partial c_k} = \sum_{j=1}^m 2 \left( \sum_{i=1}^n a_{ji} c_i - y_j \right) a_{jk} = 0$$

- ▶ daraus folgt

$$\nabla \|\eta\|^2 = A^T (Ac - \mathbf{y}) = 0$$

- ▶ umgeformt ergibt sich

$$A^T Ac = A^T \mathbf{y}$$

auch genannt die **Normalengleichung**.

# Normalengleichung

## Normalengleichung

Sei  $A \in \mathbb{R}^{m \times n}$ ,  $y \in \mathbb{R}^m$  mit  $m \geq n$ .  $c \in \mathbb{R}^n$  ist eine Least-squares Lösung von  $\min_c \|Ac - y\|$  genau dann, wenn die **Normalengleichung** gilt:

$$A^T A c = A^T y$$

Insbesondere ist die Normalengleichung lösbar, falls  $\text{rank}(A) = n$ .

- ▶ Die Matrix  $A^T A$  ist immer **symmetrisch**.
- ▶ Falls  $\text{rank}(A) = n$  ist  $A^T A$  auch **positiv definit** und damit invertierbar
- ▶ Die Lösung der Normalengleichung ist dann

$$c = ((A^T A)^{-1} A^T) y.$$

# Pseudoinverse

## Pseudoinverse

Sei  $A \in \mathbb{R}^{m \times n}$  mit  $m \geq n$  und  $\text{rank}(A) = n$ . Die Matrix

$$A^+ := (A^T A)^{-1} A^T$$

heißt **Pseudoinverse** von  $A$  (auch **Moore-Penrose Inverse** genannt).

- ▶ Die Pseudoinverse verallgemeinert das Konzept der Inversen für nicht-quadratische Matrizen.
- ▶ Ist  $A$  invertierbar, dann gilt  $A^+ = A^{-1}$ .

# Pseudoinverse

Für  $A \in \mathbb{R}^{m \times n}$ ,  $c \in \mathbb{R}^n$ ,  $y \in \mathbb{R}^m$  löse

$$A^T A c = A^T y$$

Umbenennung der Variablen:

$$M x = b$$

- ▶  $x = c$
- ▶  $M = A^T A$ ; Berechnung in Zeit  $\mathcal{O}(n^2 m)$ ; (trivialer Algorithmus)
- ▶  $b = A^T y$ ; Berechnung in Zeit  $\mathcal{O}(m n)$ ; (trivialer Algorithmus)

# Lösen von linearen Systemen

## Inverse Matrix

Sei  $M \in \mathbb{R}^{n \times n}$  quadratische Matrix. Falls ein  $M' \in \mathbb{R}^{n \times n}$  existiert mit

$$MM' = M'M = I_n$$

(wobei  $I_n$  die  $n \times n$  Einheitsmatrix ist), dann heißt  $M$  **invertierbar** und wir nennen  $M' =: M^{-1}$  das **Inverse** von  $M$ .

- ▶ Ist  $Mx = b$  lineares System mit  $M \in \mathbb{R}^{n \times n}$  invertierbar, dann ist

$$x = M^{-1}b$$

die **Lösung** des linearen Systems. Diese Lösung ist **eindeutig**.

# Invertierbarkeit von Matrizen

**Problem 1:** wann ist eine Matrix  $M \in \mathbb{R}^{n \times n}$  invertierbar?

- ▶  $Mx = 0$  hat nur die triviale Lösung  $x = 0$

**Problem 2:** falls  $M$  invertierbar, wie findet man das Inverse  $M^{-1}$ ?

- ▶ Berechnung mit Gauss-Jordan Elimination
- ▶ Umweg über Zerlegungen von  $M$  (z.B. LU-Zerlegung)
- ▶ **generell:** Berechnung der Inversen meist numerisch nicht stabil

## Günstige Matrix-Formen

- ▶  $M$  **diagonal**: Lösung kann abgelesen werden

$$\begin{pmatrix} M_{11} & & 0 \\ & \ddots & \\ 0 & & M_{nn} \end{pmatrix} x = b$$

- ▶  $M$  **obere Dreiecksmatrix**: Rückwärtssubstitution

$$\begin{pmatrix} M_{11} & \cdots & M_{1n} \\ & \ddots & \vdots \\ 0 & & M_{nn} \end{pmatrix} x = b$$

- ▶  $M$  **untere Dreiecksmatrix**: Vorwärtssubstitution

$$\begin{pmatrix} M_{11} & & 0 \\ \vdots & \ddots & \\ M_{n1} & \cdots & M_{nn} \end{pmatrix} x = b$$

# Rückwärtssubstitution

Lineares System in **oberer Dreiecksform**:

$$\begin{aligned}M_{11}x_1 + M_{21}x_2 + \dots + M_{1,n-1}x_{n-1} + M_{1n}x_n &= b_1 \\M_{22}x_2 + \dots + M_{2,n-1}x_{n-1} + M_{2n}x_n &= b_2 \\&\vdots \\M_{n-1,n-1}x_{n-1} + M_{n-1,n}x_n &= b_{n-1} \\M_{n,n}x_n &= b_n\end{aligned}$$

**Rückwärts** nacheinander nach  $x_n, x_{n-1}, \dots, x_1$  auflösen:

$$x_i = \left( b_i - \sum_{j=i+1}^n M_{ij}x_j \right) / M_{ii}$$

**Aufwand:**  $\mathcal{O}(n^2)$  arithmetische Operationen (FLOPs)



# Vorwärtssubstitution

Lineares System in **unterer Dreiecksform**:

$$M_{11}x_1 = b_1$$

$$M_{21}x_1 + M_{22}x_2 = b_2$$

$$\vdots$$

$$M_{n-1,1}x_1 + M_{n-1,2}x_2 + \dots + M_{n-1,n-1}x_{n-1} = b_{n-1}$$

$$M_{n1}x_1 + M_{n2}x_2 + \dots + M_{n,n-1}x_{n-1} + M_{nn}x_n = b_n$$

**Vorwärts** nacheinander nach  $x_1, x_2, \dots, x_n$  auflösen:

$$x_i = \left( b_i - \sum_{j=1}^{i-1} M_{ij}x_j \right) / M_{ii}$$

**Aufwand:**  $\mathcal{O}(n^2)$  FLOPs

## Gauss Elimination

**Gauss-Elimination:** Überführung der Matrix  $A$  in **Dreiecksform** durch **elementare Zeilenumformungen**

- ▶ Komplexität:  $\Theta(n^3)$

**Gauss-Jordan-Elimination:** Überführung der Matrix  $A$  in **Diagonalform** durch **elementare Zeilenumformungen**

- ▶ Komplexität:  $\Theta(n^3)$

**Elementare Zeilenumformungen:**

- ▶ Vielfaches einer Zeile zu einer anderen Zeile addieren
- ▶ zwei Zeilen vertauschen
- ▶ Vielfaches einer Zeile berechnen

für lineare Systeme: Gauss-Elimination auf erweiterter Matrix

$$(A|b) = \left( \begin{array}{ccc|c} M_{11} & \cdots & M_{1n} & b_1 \\ \vdots & & \vdots & \vdots \\ M_{n1} & \cdots & M_{nn} & b_n \end{array} \right)$$

## Gauss Elimination: Beispiel

$$2x + y - z = 8 \quad (G_1)$$

$$-3x - y + 2z = -11 \quad (G_2)$$

$$-2x + y + 2z = -3 \quad (G_3)$$

$$\left( \begin{array}{ccc|c} 2 & 1 & -1 & 8 \\ -3 & -1 & 2 & -11 \\ -2 & 1 & 2 & -3 \end{array} \right) \xrightarrow{G_2 += \frac{3}{2}G_1} \left( \begin{array}{ccc|c} 2 & 1 & -1 & 8 \\ 0 & \frac{1}{2} & \frac{1}{2} & 1 \\ -2 & 1 & 2 & -3 \end{array} \right)$$

$$\xrightarrow{G_3 += G_1} \left( \begin{array}{ccc|c} 2 & 1 & -1 & 8 \\ 0 & \frac{1}{2} & \frac{1}{2} & 1 \\ 0 & 2 & 1 & 5 \end{array} \right) \xrightarrow{G_3 += -4G_2} \left( \begin{array}{ccc|c} -2 & 1 & -1 & 8 \\ 0 & \frac{1}{2} & \frac{1}{2} & 1 \\ 0 & 0 & -1 & 1 \end{array} \right)$$

$$\xrightarrow{G_1/2, G_2 \cdot 2, G_3 \cdot (-1)} \left( \begin{array}{ccc|c} 1 & \frac{1}{2} & -\frac{1}{2} & 4 \\ 0 & 1 & 1 & 2 \\ 0 & 0 & 1 & -1 \end{array} \right)$$

Lösung nun durch **Rücksubstitution**:  $z = -1$ ,  $y = 3$  und  $x = 2$

# Gauss Elimination: Algorithmus

```
1 Gauss(M)
2   for (j=0; j<n-1; j++)
3     foundNonZero = false;
4     for (i=j; i<n-1; i++)
5       if (Mij != 0)
6         swap(i, j);
7         foundNonZero = true;
8         break;
9     if (!foundNonZero)
10      printf("Matrix not invertible");
11      return;
12     for (i=j+1; i<n-1; i++)
13       Mi += -(Mij/Mjj)*Mj;
```

- ▶ Laufzeit: Die äußere Schleife wird  $n$  mal durchlaufen; die inneren Schleifen  $\leq n$  mal. D.h. jede Operation wird höchstens  $n^2$  mal ausgeführt.
- ▶ Die swap-Operation in Zeile 5 und die Operation in Zeile 11 sind aber nicht elementar und benötigen Laufzeit  $\mathcal{O}(n)$ .

## Erklärung

- ▶  $j$  geht über die Spalten; und  $i$  über die Zeilen;
- ▶ Zu Beginn der von Iteration  $j$ , haben alle Zeilen  $i \geq j$  Nullen in Spalten  $\ell$  mit  $\ell < j$ .
- ▶ In Iteration  $j$  bekommen die Zeilen  $i > j$  Nullen in Spalte  $\ell$ ;
- ▶ Die Zeile  $j$  soll aber in Spalte  $j$  einen Wert  $M_{jj} \neq 0$  haben; dazu wird erst nach einer geeigneten Zeile gesucht (in den Zeilen mit  $i \geq j$ ) und ggfs. eine Vertauschung vorgenommen. Falls dies fehlschlägt haben **alle** Zeilen  $i \geq j$  Nullen in Spalte  $\ell$  mit  $1 \leq \ell \leq j$ . D.h., diese insgesamt  $n - j$  Zeilen haben höchstens  $n - j - 1$  Spalten, die nicht Null sind. Damit sind diese Zeilen linear abhängig und die Matrix ist nicht invertierbar.
- ▶ In einer Iteration der for-Schleife in Zeile 11 wird die  $j$ -te Zeile mit einem geeigneten Vielfachen multipliziert und zu der  $i$ -ten Zeile addiert, so daß letztere einen Nulleintrag in Spalte  $j$  bekommt.

# Inverse via Gauss-Jordan Elimination

Sei  $A \in \mathbb{R}^{n \times n}$ .

- ▶ Bilde erweiterte Matrix

$$(A|I_n) = \left( \begin{array}{ccc|ccc} a_{11} & \cdots & a_{n1} & 1 & \cdots & 0 \\ \vdots & \ddots & \vdots & \vdots & \ddots & \vdots \\ a_{n1} & \cdots & a_{nn} & 0 & \cdots & 1 \end{array} \right)$$

wobei  $I_n$  die  $n \times n$  Identitätsmatrix ist.

- ▶ Führe Gauss-Jordan Elimination für  $A$  aus (linker Teil) bis auf  $I_n$  reduziert, repliziere elementare Zeilenumformungen für  $I_n$  (rechter Teil).
- ▶ Am Ende entspricht rechter Teil  $A^{-1}$ .

# Pseudoinverse

Falls  $A^T A$  nicht invertierbar ist die Pseudoinverse gegeben durch die Matrix  $A^+$ , die folgende Bedingungen erfüllt:


- ▶  $AA^+A = A$
- ▶  $A^+AA^+ = A^+$
- ▶  $(AA^+)^T = AA^+$
- ▶  $(A^+A)^T = A^+A$

## Theorem

Diese Matrix existiert immer.

# Anwendung

gegeben: ungerichteter Graph  $G = (V, E)$




weise Kanten beliebige Richtungen zu (Zählpfeile)

**Definition:** Die **Knoten-Kanten Inzidenzmatrix**  $B$  ist wie folgt definiert:

- ▶ eine Zeile für jede Kante; eine Spalte für jeden Knoten
- ▶ die Zeile für Kante  $e = (u, v)$  enthält ein  $1$  in Spalte  $u$  und eine  $-1$  in Spalte  $v$



# Anwendung



$$\underbrace{\begin{pmatrix} 1 & -1 & 0 & 0 & 0 \\ 0 & 1 & -1 & 0 & 0 \\ 0 & 1 & 0 & 0 & -1 \\ 0 & 0 & -1 & 0 & 1 \\ 0 & 0 & 0 & 1 & -1 \\ 1 & 0 & 0 & -1 & 0 \\ 0 & 0 & 1 & -1 & 0 \end{pmatrix}}_B$$

Angenommen Vektor  $x$  ordnet jedem Knoten ein Potential zu und die Kanten des Graphen haben Widerstand 1.

$Bx$  = Vektor von Strömen entlang der Kanten

# Anwendung

$Bx$  = Vektor von Strömen entlang der Kanten

$\underbrace{B^T B}_L x$  = Vektor von Strömen aus Knoten

Gegeben: Vektor  $b \in \mathbb{R}^n$  der Ein- und Ausgangsströme für alle Knoten angibt (z.B. einfach +1 an Knoten  $v$  und -1 an Knoten  $u$  bei einer Stromquelle zwischen diesen Knoten).

Löse

$$Lx = b$$

$L^+b$  ist die Lösung der Gleichung die  $\|x\|_2$  minimiert.