

# Lineare Abbildungen, Matrizen & Determinante

Irene Winkler & Nico Görnitz

Arbeitsgruppe Maschinelles Lernen

- 1 Bsp: Lineare Regression
- 2 Lineare Abbildungen
  - Allgemeine Abbildungen
  - Konvexe Funktionen
  - Lineare Abbildungen
  - Basis & Lineare Abbildung
  - Bild, Fasern & Kern
  - Existenz & Eindeutigkeit
- 3 Matrizen
  - Matrizen & Lineare Abbildungen
  - Beispiele
  - Rechenregeln
  - Komposition & Transformation
  - Rang
  - Inverse
  - Spezielle Matrizen
- 4 Determinante
  - Einleitung
  - Definition
  - Rechenregeln

# Bsp: Lineare Regression


- Gegeben sind  $n$  Datenpunkte  $X = (\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n)$  und dazugehörige Labels  $\mathbf{y} = (y_1, y_2, \dots, y_n)$
- Lineares Model:  $y = f_{\mathbf{w}}(\mathbf{x}) = \langle \mathbf{w}, \mathbf{x} \rangle$
- Einstellen des Parameters  $\mathbf{w}$  dr. Methode der kleinsten Quadrate:

$$\min_{\mathbf{w}} \frac{1}{2} \sum_i \text{dist}(y_i, \langle \mathbf{w}, \mathbf{x}_i \rangle) = \min_{\mathbf{x}} \frac{1}{2} \sum_i \|y_i - \mathbf{w}^T \mathbf{x}_i\|_2^2 = \frac{1}{2} (\mathbf{y}^T \mathbf{y} - 2\mathbf{w} X \mathbf{y} + \mathbf{w}^T X X^T \mathbf{w})$$

- Auflösen nach  $\mathbf{w}$  (Ableitung auf 0 setzen=Minima suchen):

$$0 = \frac{\partial}{\partial \mathbf{w}} \left\{ \frac{1}{2} (\mathbf{y}^T \mathbf{y} - 2\mathbf{w}^T X \mathbf{y} + \mathbf{w}^T X X^T \mathbf{w}) \right\} = -X \mathbf{y} + X X^T \mathbf{w}$$

$$X \mathbf{y} = X X^T \mathbf{w} \quad \Rightarrow \quad (X X^T)^{-1} X \mathbf{y} = \mathbf{w}$$



# Allgemeine Abbildungen

Eine Funktion  $f : X \rightarrow Y$ ,  $x \mapsto f(x)$  heisst

- **injektiv**

- wenn fuer alle  $x, y \in X$  mit  $f(x) = f(y)$  folgt, dass  $x = y$  ist.
- Zu jedem  $x$  gibt es genau 1  $f(x)$ .

- **surjektiv**


- wenn  $f(X) = Y$  ist.
- Also wenn alle Elemente in  $Y$  von  $X$  aus “angesprochen” werden koennen.

- **bijektiv\***

- wenn  $f$  injektiv und surjektiv ist.
- D.h. alle Elemente von  $x \in X$  zeigen auf genau 1  $y \in Y$  und es gibt keine “unbenutzten” Elemente in  $Y$ .

# Konvexe Funktionen

Eine reellwertige Funktion  $f : C \rightarrow \mathbb{R}$ , die auf einer konvexen Teilmenge  $C$  eines reellen Vektorraums definiert ist, heißt *konvex*, wenn für alle  $\mathbf{x}, \mathbf{y}$  aus  $C$  und für alle  $0 \leq t \leq 1$  gilt, dass  $f(t\mathbf{x} + (1-t)\mathbf{y}) \leq tf(\mathbf{x}) + (1-t)f(\mathbf{y})$ .



# Lineare Abbildungen

**Definition.** Seien  $V$  und  $W$  reelle Vektorräume. Eine Abbildung  $f : V \mapsto W$  heisst *linear* wenn

- ①  $f(\mathbf{v} + \mathbf{w}) = f(\mathbf{v}) + f(\mathbf{w})$  und
- ②  $f(\lambda \mathbf{v}) = \lambda f(\mathbf{v})$

für alle  $\mathbf{v}, \mathbf{w} \in V$  und  $\lambda \in \mathbb{R}$

# Arten von Linearen Abbildungen

Eine Funktion  $f : V \rightarrow W$ ,  $x \mapsto f(x)$  heisst

- **Homomorphismus**

- wenn es eine lineare Abbildung zwischen zwei Vektorräumen  $V$  und  $W$  ist.

- **Isomorphismus**

- Wenn die lineare Abbildung *bijektiv* ist.
- D.h. wenn es eine Umkehrabbildung geben kann.

- **Endomorphismus**

- wenn  $W = V$  ist.

# Basis & Lineare Abbildung

Seien  $V$  und  $W$  reelle Vektorräume,  $\mathbf{v}_1, \dots, \mathbf{v}_n$  eine Basis von  $V$  und  $f : V \mapsto W$  eine lineare Abbildung.

Linearität  $\Rightarrow$  für jedes  $\mathbf{v} \in V$  gilt:

$$f(\mathbf{v}) = f(\lambda_1 \mathbf{v}_1 + \dots + \lambda_n \mathbf{v}_n) = \lambda_1 f(\mathbf{v}_1) + \dots + \lambda_n f(\mathbf{v}_n)$$

$\Rightarrow$  Es genügt die Bilder der Basisvektoren zu kennen, um die ganze Funktion zu charakterisieren!

$\Rightarrow$  repräsentierbar als Matrix, in der die Koordinaten von  $\mathbf{v}$  auf Koordinaten von  $f(\mathbf{v})$  abgebildet werden.



# Bild, Faser & Kern

Ist Funktion  $F : V \rightarrow W$  eine lineare Abbildung, dann ist

- $\text{Im}F := F(V)$  das Bild von  $F$
- $F^{-1}(\mathbf{w}) := \{\mathbf{v} \in V \mid F(\mathbf{v}) = \mathbf{w}\}$  die Faser über  $W$
- $\text{Ker}F := F^{-1}(0)$  der Kern von  $F$

# Existenz & Eindeutigkeit

**Satz.** Seien  $V$  und  $W$  reelle Vektorräume und  $(v_1, \dots, v_n)$  eine Basis von  $V$ . Dann gibt es zu *jedem*  $n$ -Tupel  $(w_1, \dots, w_n)$  von Vektoren in  $W$  genau eine lineare Abbildung  $f : V \mapsto W$  mit  $f(v_i) = w_i, i = 1, \dots, n$ .

## Beweis.

- ① Existenz: Für  $x = \lambda_1 v_1 + \dots + \lambda_n v_n$  definiere  $f(x) := \lambda_1 w_1 + \dots + \lambda_n w_n$
- ② Eindeutigkeit: Seien  $f, f' : V \mapsto W$  lineare Abbildungen mit  $f(v_i) = f'(v_i) = w_i, i = 1, \dots, n$ . Dann  $f(x) = f(\lambda_1 v_1 + \dots + \lambda_n v_n) = \lambda_1 w_1 + \dots + \lambda_n w_n = f'(\lambda_1 v_1 + \dots + \lambda_n v_n) = f'(x)$

# Matrizen

Sei  $g : \mathbb{R}^n \mapsto \mathbb{R}^m$  eine lineare Abbildung. Wir wollen sie charakterisieren durch  $g(\mathbf{x}) = A \cdot \mathbf{x}$  für  $\mathbf{x} \in \mathbb{R}^n$  und  $A$  eine  $m \times n$  Matrix.

$$g(\mathbf{x}) = \begin{pmatrix} a_{11} & \dots & a_{1n} \\ \vdots & & \vdots \\ a_{m1} & \dots & a_{mn} \end{pmatrix} \cdot \begin{pmatrix} x_1 \\ \vdots \\ x_n \end{pmatrix} = \begin{pmatrix} a_{11}x_1 + \dots + a_{1n}x_n \\ \vdots \\ a_{m1}x_1 + \dots + a_{mn}x_n \end{pmatrix}$$

Wie muss  $A$  aussehen?

Es genügt, die Bilder der Basisvektoren  $(\mathbf{e}_1, \dots, \mathbf{e}_n)$  zu kennen.  
Die Spalten der Matrix  $A$  sind die Bilder der Einheitsvektoren!

# Beispiele

Lineare Abbildungen lassen sich also als Lineares Gleichungssystem  $\mathbf{y} = g(\mathbf{x}) = A\mathbf{x}$  darstellen:

- Identitätsmatrix  $I$
- $g : \mathbb{R}^2 \mapsto \mathbb{R}^2$  Drehung um  $90^\circ$
- $g : \mathbb{R}^2 \mapsto \mathbb{R}^2$  Spiegelung an der x-Achse
- $g : \mathbb{R}^2 \mapsto \mathbb{R}^2$  Projektion auf die Gerade durch  $(0, 0)$  und  $(1, 1)$

Ps: Praktische Lösung von  $A\mathbf{x} = \mathbf{y}$  (wenn  $\mathbf{x}$  gesucht ist) durch z.B. QR-Zerlegung, Cholesky-Zerlegung, Conjugate Gradient oder dem allseits bekannten Gauss-Verfahren.

# Matrixrechnung

- Addition
- Skalarmultiplikation
- Multiplikation

$$AB=C$$

$$\begin{pmatrix} a_{1,i} \\ \vdots \\ \vdots \end{pmatrix} \begin{pmatrix} b_{i,1} \\ \vdots \\ \vdots \end{pmatrix} = \begin{pmatrix} c_{1,1} \\ \vdots \\ \vdots \end{pmatrix}$$

$$c_{1,1} = \sum_i a_{1,i} b_{i,1}$$

## Weiteres

- Spur einer quadratischen Matrix = Summe der Hauptdiagonalelemente.

Für  $A \in \mathbb{R}^{n \times m}$  und  $B \in \mathbb{R}^{m \times n}$  gilt

$$\text{Spur}(AB) = \text{Spur}(BA)$$

.

- Sind  $A^T, B^T \in \mathbb{R}^{n \times m}$  die transponierten Matrizen zu  $A, B \in \mathbb{R}^{m \times n}$  und  $\lambda \in \mathbb{R}$  dann

$$(A + B)^T = A^T + B^T$$

$$(\lambda \cdot A)^T = \lambda \cdot A^T,$$

$$(A \cdot B)^T = B^T \cdot A^T$$

## Komposition & Transformation

Seien  $F : V \mapsto W$  und  $G : U \mapsto V$  lineare Abbildungen, dann ist die Komposition (Hintereinanderausführung)  $F \circ G$  wieder linear. Dies entspricht der Multiplikation der zu  $F$  und  $G$  gehörenden Matrix.

Sei  $F : V \mapsto W$  eine lineare Abbildung, und seien  $\mathcal{A}$  und  $\mathcal{B}$  Basen von  $V$  und  $W$ . Dann hat man ein Diagramm linearer Abbildungen und es gilt:

$$\begin{array}{ccc}
 V & \xrightarrow{F} & W \\
 \uparrow T_A & & \uparrow T_B \\
 K^n & \xrightarrow{M} & K^m
 \end{array}$$

$$M = T_B^{-1} \circ F \circ T_A$$

# Rang

**Definition:** Der Rang einer Matrix ist die Maximalzahl linear unabhängiger Spalten (äquivalent: Zeilen).

Der Rang ist die Dimensionalität des Bildes von der durch  $A$  beschriebenen Abbildung.



# Inverse Matrix

**Definition:** Eine quadratische Matrix  $A \in \mathbb{R}^{n \times n}$  ist *invertierbar* (*regulär*, *nichtsingulär*), wenn eine weitere Matrix  $A^{-1}$  existiert, sodass

$$AA^{-1} = A^{-1}A = I_n.$$

Es gilt:

- A ist genau dann invertierbar, wenn  $\text{rang}(A) = n$
- $(A \cdot B)^{-1} = B^{-1} \cdot A^{-1}$
- $(A^T)^{-1} = (A^{-1})^T$
- $\begin{pmatrix} a & b \\ c & d \end{pmatrix}^{-1} = \frac{1}{ad-bc} \begin{pmatrix} d & -b \\ -c & a \end{pmatrix}$

# Inverse Matrix Berechnung

Will man die Inverse von  $A \in \mathbb{R}^{n \times n}$  ausrechnen, dann kann man folgendermassen vorgehen:

- Schreiben  $(I_n | A)$  nebeneinander
- Führe synchron in beiden Matrizen die ueblichen Umformungen aus, bis auf der rechten Seite  $I_n$  erscheint
- Dann steht die Inverse von  $A$ ,  $A^{-1}$  auf der linken Seite

# Spezielle Matrizen

Sei  $A \in \mathbb{R}^{n \times n}$  eine quadratische, reelle Matrix.

- A ist *orthogonal* wenn  $AA^T = A^T A = I_n$ .  
Orthogonale Matrizen stellen Spiegelungen und Drehungen im Raum dar.
- A ist *symmetrisch* wenn  $A = A^T$
- A ist *antisymmetrisch* wenn  $A = -A^T$
- A ist *diagonal* wenn alle Elemente außerhalb der Hauptdiagonale 0 sind

# Determinante

Die Determinante einer quadratischen Matrix ist eine Zahl. Was bedeutet sie anschaulich?

- Absolutbetrag: das Volumen des Parallelotops das durch die Zeilen- oder Spaltenvektoren aufgespannt wird
- Vorzeichen: Orientierung des Parallelotops

# Determinante

**Satz und Definition:** Es gibt genau eine Abbildung  $\det : \mathbb{R}^{n \times n} \ni A \mapsto \det A \in \mathbb{R}$  mit

- ①  $\det$  ist linear in jeder Zeile
- ② Ist der (Zeilen-) rang kleiner als  $n$ , so ist  $\det A = 0$
- ③  $\det I_n = 1$

Diese Abbildung heisst *Determinante*.

# Determinante - Regeln

Seien  $A, B \in \mathbb{R}^{n \times n}$  zwei quadratische Matrizen und  $\lambda \in \mathbb{R}$

- Ist  $A$  eine Dreiecksmatrix, dann ist die Determinante das Produkt der Hauptdiagonalelemente von  $A$
- $A$  ist genau dann invertierbar, wenn  $\det A \neq 0$
- $\det AB = \det A \det B$
- $\det A^{-1} = (\det A)^{-1}$
- $\det A = \det A^T$
- $\det \lambda A = \lambda^n \det A$
- $\det \begin{pmatrix} a & b \\ c & d \end{pmatrix} = ad - bc$