

# Vektoren und Matrizen

Vollstaendige Vorlesung

BSc Analysis

- 1 Der Vektorbegriff
- 2 Vektoroperationen
- 3 Skalarprodukt und Norm
- 4 Kreuzprodukt
- 5 Matrizen
- 6 Matrixmultiplikation
- 7 Determinante
- 8 Inverse Matrix
- 9 Gauss-Elimination
- 10 Rang einer Matrix
- 11 Eigenwerte und Eigenvektoren
- 12 Lineare Transformationen
- 13 Anwendungen
- 14 Python-Vertiefung
- 15 Beweise und Herleitungen
- 16 Numerische Aspekte
- 17 Historischer Kontext
- 18 Übungsaufgaben
- 19 Zusammenfassung und Ausblick

# Was ist ein Vektor?

## Definition

Ein **Vektor**  $\mathbf{v} \in \mathbb{R}^n$  ist ein geordnetes  $n$ -Tupel reeller Zahlen:

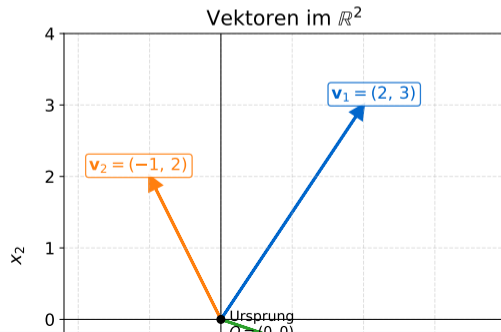
$$\mathbf{v} = \begin{pmatrix} v_1 \\ v_2 \\ \vdots \\ v_n \end{pmatrix}.$$

## Interpretationen:

- **Geometrisch:** Pfeil mit Richtung und Länge
- **Physikalisch:** Kraft, Geschwindigkeit, Beschleunigung
- **Algebraisch:** Element eines Vektorraums
- **Informatik:** Array von Zahlen

## Spezielle Vektoren:

- Nullvektor:  $\mathbf{0} = (0, \dots, 0)^T$
- Einheitsvektoren:  $\mathbf{e}_1, \mathbf{e}_2, \dots, \mathbf{e}_n$



Im  $\mathbb{R}^2$ :

$$\mathbf{v} = \begin{pmatrix} v_1 \\ v_2 \end{pmatrix}, \quad \mathbf{e}_1 = \begin{pmatrix} 1 \\ 0 \end{pmatrix}, \quad \mathbf{e}_2 = \begin{pmatrix} 0 \\ 1 \end{pmatrix}$$

Jeder Vektor ist Linearkombination:  $\mathbf{v} = v_1\mathbf{e}_1 + v_2\mathbf{e}_2$ .

Im  $\mathbb{R}^3$ :

$$\mathbf{w} = \begin{pmatrix} w_1 \\ w_2 \\ w_3 \end{pmatrix}, \quad \mathbf{e}_1 = \begin{pmatrix} 1 \\ 0 \\ 0 \end{pmatrix}, \quad \mathbf{e}_2 = \begin{pmatrix} 0 \\ 1 \\ 0 \end{pmatrix}, \quad \mathbf{e}_3 = \begin{pmatrix} 0 \\ 0 \\ 1 \end{pmatrix}$$

**Beispiel (Oekonomie):** Portfolio-Vektor  $\mathbf{w} = (0,4; 0,35; 0,25)^T$  beschreibt die Gewichtung von drei Anlageklassen.

**Beispiel (Physik):** Geschwindigkeitsvektor  $\mathbf{v} = (3; -2; 5)^T$  in m/s.

---

Die Standardbasis  $\{\mathbf{e}_1, \dots, \mathbf{e}_n\}$  erzeugt den gesamten  $\mathbb{R}^n$ .

## Definition (Vektorraum)

Ein **Vektorraum**  $(V, +, \cdot)$  ueber  $\mathbb{R}$  ist eine Menge  $V$  mit zwei Operationen (Addition, Skalarmultiplikation), die folgende Axiome erfuellen:

### Addition (+):

1.  $\mathbf{u} + \mathbf{v} = \mathbf{v} + \mathbf{u}$  (Kommutativ)
2.  $(\mathbf{u} + \mathbf{v}) + \mathbf{w} = \mathbf{u} + (\mathbf{v} + \mathbf{w})$  (Assoziativ)
3.  $\exists \mathbf{0} : \mathbf{v} + \mathbf{0} = \mathbf{v}$  (Neutrales El.)
4.  $\exists -\mathbf{v} : \mathbf{v} + (-\mathbf{v}) = \mathbf{0}$  (Inverses)

### Skalarmultiplikation ( $\cdot$ ):

5.  $\alpha(\beta\mathbf{v}) = (\alpha\beta)\mathbf{v}$  (Assoziativ)
6.  $1 \cdot \mathbf{v} = \mathbf{v}$  (Neutrales El.)
7.  $\alpha(\mathbf{u} + \mathbf{v}) = \alpha\mathbf{u} + \alpha\mathbf{v}$  (Distributiv I)
8.  $(\alpha + \beta)\mathbf{v} = \alpha\mathbf{v} + \beta\mathbf{v}$  (Distributiv II)

**Standardbeispiel:**  $\mathbb{R}^n$  mit komponentenweiser Addition und Skalarmultiplikation.

**Weitere Beispiele:** Raum der Polynome vom Grad  $\leq n$ ; Raum der stetigen Funktionen  $C[a, b]$ .

---

Diese 8 Axiome bilden das Fundament der gesamten linearen Algebra.

## Definition

Fuer  $\mathbf{u}, \mathbf{v} \in \mathbb{R}^n$ :

$$\mathbf{u} + \mathbf{v} = \begin{pmatrix} u_1 + v_1 \\ u_2 + v_2 \\ \vdots \\ u_n + v_n \end{pmatrix}, \quad \mathbf{u} - \mathbf{v} = \begin{pmatrix} u_1 - v_1 \\ u_2 - v_2 \\ \vdots \\ u_n - v_n \end{pmatrix}$$

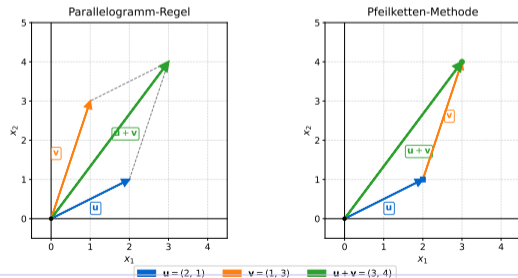
Zahlenbeispiel:

$$\begin{pmatrix} 3 \\ -1 \\ 2 \end{pmatrix} + \begin{pmatrix} 1 \\ 4 \\ -3 \end{pmatrix} = \begin{pmatrix} 4 \\ 3 \\ -1 \end{pmatrix}$$

Geometrisch:

- Addition: Parallelogrammregel
- Subtraktion: Verbindungsvektor

## Vektoraddition



Vektoraddition ist kommutativ und assoziativ – wie die Addition reeller Zahlen.

## Definition

Fuer  $\alpha \in \mathbb{R}$  und  $\mathbf{v} \in \mathbb{R}^n$ :


$$\alpha \cdot \mathbf{v} = \begin{pmatrix} \alpha v_1 \\ \alpha v_2 \\ \vdots \\ \alpha v_n \end{pmatrix}$$

## Wirkung:

- $|\alpha| > 1$ : Streckung
- $0 < |\alpha| < 1$ : Stauchung
- $\alpha < 0$ : Richtungsumkehr
- $\alpha = 0$ : Nullvektor

## Beispiel:

$$3 \begin{pmatrix} 2 \\ -1 \end{pmatrix} = \begin{pmatrix} 6 \\ -3 \end{pmatrix}, \quad -\frac{1}{2} \begin{pmatrix} 4 \\ 6 \end{pmatrix} = \begin{pmatrix} -2 \\ -3 \end{pmatrix}$$



Skalarmultiplikation aendert Laenge und ggf. Richtung, aber nicht die "Gerade" des Vektors.

## Definition (Linearkombination)

Ein Vektor  $\mathbf{w}$  heisst **Linearkombination** von  $\mathbf{v}_1, \dots, \mathbf{v}_k$ , falls

$$\mathbf{w} = \alpha_1 \mathbf{v}_1 + \alpha_2 \mathbf{v}_2 + \dots + \alpha_k \mathbf{v}_k \quad \text{mit } \alpha_i \in \mathbb{R}.$$

## Definition (Lineare Unabhaengigkeit)

Vektoren  $\mathbf{v}_1, \dots, \mathbf{v}_k$  sind **linear unabhaengig**, falls

$$\alpha_1 \mathbf{v}_1 + \dots + \alpha_k \mathbf{v}_k = \mathbf{0} \quad \implies \quad \alpha_1 = \dots = \alpha_k = 0.$$

Andernfalls heissen sie **linear abhaengig**.

**Beispiel:**  $\mathbf{v}_1 = \begin{pmatrix} 1 \\ 0 \end{pmatrix}$ ,  $\mathbf{v}_2 = \begin{pmatrix} 0 \\ 1 \end{pmatrix}$  sind linear unabhaengig (Standardbasis).

$\mathbf{v}_1 = \begin{pmatrix} 1 \\ 2 \end{pmatrix}$ ,  $\mathbf{v}_2 = \begin{pmatrix} 2 \\ 4 \end{pmatrix}$  sind linear abhaengig:  $\mathbf{v}_2 = 2\mathbf{v}_1$ .

**Kriterium:** In  $\mathbb{R}^n$  sind maximal  $n$  Vektoren linear unabhaengig.

Lineare Unabhaengigkeit bedeutet: Kein Vektor ist "ueberfluessig" – keiner folgt aus den anderen.

## Definition (Basis)

Eine Menge  $\{\mathbf{b}_1, \dots, \mathbf{b}_n\}$  heisst **Basis** von  $V$ , falls:

1. Die Vektoren sind **linear unabhaengig**.
2. Jeder Vektor in  $V$  ist Linearkombination von  $\mathbf{b}_1, \dots, \mathbf{b}_n$  (Erzeugendensystem).

## Definition (Dimension)

Die **Dimension** von  $V$  ist die Anzahl der Basisvektoren:  $\dim(V) = n$ .

### Beispiele:

- $\mathbb{R}^n$ : Standardbasis  $\{\mathbf{e}_1, \dots, \mathbf{e}_n\}$ ,  $\dim(\mathbb{R}^n) = n$
- Polynome  $\leq$  Grad 2: Basis  $\{1, x, x^2\}$ , Dimension 3
- $\{(1, 1)^T, (1, -1)^T\}$  ist eine Basis von  $\mathbb{R}^2$  (nicht die Standard-Basis!)

### Wichtige Fakten:

- Jede Basis von  $V$  hat *gleich viele* Elemente (Basisaustauschsatz).
- Die Darstellung eines Vektors bzgl. einer Basis ist *eindeutig*.

---

Die Wahl der Basis ist frei – verschiedene Basen geben verschiedene Koordinaten fuer denselben Vektor.

# Skalarprodukt (Dot Product)

## Definition

Das **Skalarprodukt** zweier Vektoren  $\mathbf{u}, \mathbf{v} \in \mathbb{R}^n$  ist

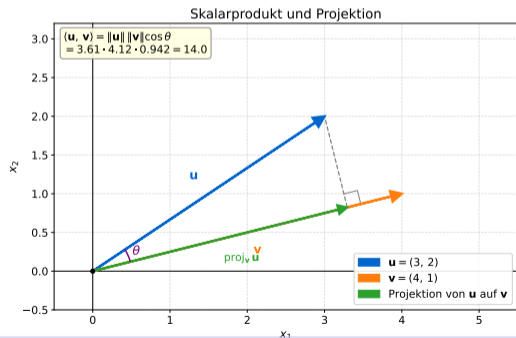
$$\langle \mathbf{u}, \mathbf{v} \rangle = \mathbf{u}^T \mathbf{v} = \sum_{i=1}^n u_i v_i = u_1 v_1 + u_2 v_2 + \cdots + u_n v_n \in \mathbb{R}.$$

## Eigenschaften:

- Symmetrisch:  $\langle \mathbf{u}, \mathbf{v} \rangle = \langle \mathbf{v}, \mathbf{u} \rangle$
- Bilinear:  $\langle \alpha \mathbf{u} + \mathbf{w}, \mathbf{v} \rangle = \alpha \langle \mathbf{u}, \mathbf{v} \rangle + \langle \mathbf{w}, \mathbf{v} \rangle$
- Positiv definit:  $\langle \mathbf{v}, \mathbf{v} \rangle \geq 0, = 0 \Leftrightarrow \mathbf{v} = \mathbf{0}$

## Beispiel:

$$\left\langle \begin{pmatrix} 2 \\ 3 \\ -1 \end{pmatrix}, \begin{pmatrix} 4 \\ -1 \\ 5 \end{pmatrix} \right\rangle = 8 - 3 - 5 = 0$$



Skalarprodukt = 0 bedeutet Orthogonalität – eines der wichtigsten Konzepte der linearen Algebra.

## Winkelformel

Der Winkel  $\theta$  zwischen  $\mathbf{u}$  und  $\mathbf{v}$  ( $\neq \mathbf{0}$ ) ist

$$\cos \theta = \frac{\langle \mathbf{u}, \mathbf{v} \rangle}{\|\mathbf{u}\| \cdot \|\mathbf{v}\|}.$$

Spezialfaelle:

Skalarprodukt	Winkel	Bedeutung
$\langle \mathbf{u}, \mathbf{v} \rangle > 0$	$0 < \theta < 90$	spitzer Winkel
$\langle \mathbf{u}, \mathbf{v} \rangle = 0$	$\theta = 90$	<b>orthogonal</b> ( $\mathbf{u} \perp \mathbf{v}$ )
$\langle \mathbf{u}, \mathbf{v} \rangle < 0$	$90 < \theta < 180$	stumpfer Winkel

Beispiel:  $\mathbf{u} = (1, 1)^T$ ,  $\mathbf{v} = (1, -1)^T$ :

$$\langle \mathbf{u}, \mathbf{v} \rangle = 1 \cdot 1 + 1 \cdot (-1) = 0 \quad \implies \quad \mathbf{u} \perp \mathbf{v}.$$

**Cauchy-Schwarz-Ungleichung:**  $|\langle \mathbf{u}, \mathbf{v} \rangle| \leq \|\mathbf{u}\| \cdot \|\mathbf{v}\|$  (sichert  $|\cos \theta| \leq 1$ ).

Orthogonale Zerlegungen sind zentral in Statistik (Regression), Signalverarbeitung und Quantenmechanik.

## Definition (Euklidische Norm)

Die **Norm** (Laenge, Betrag) von  $\mathbf{v} \in \mathbb{R}^n$  ist

$$\|\mathbf{v}\| = \sqrt{\langle \mathbf{v}, \mathbf{v} \rangle} = \sqrt{v_1^2 + v_2^2 + \dots + v_n^2}.$$

### Eigenschaften:

1.  $\|\mathbf{v}\| \geq 0$ ,  $\|\mathbf{v}\| = 0 \Leftrightarrow \mathbf{v} = \mathbf{0}$
2.  $\|\alpha\mathbf{v}\| = |\alpha| \cdot \|\mathbf{v}\|$
3.  $\|\mathbf{u} + \mathbf{v}\| \leq \|\mathbf{u}\| + \|\mathbf{v}\|$

(Definitheit)  
(Homogenitaet)  
(Dreiecksungleichung)

**Einheitsvektor:**  $\hat{\mathbf{v}} = \frac{\mathbf{v}}{\|\mathbf{v}\|}$  hat Laenge 1 (Normierung).

**Beispiel:**  $\mathbf{v} = (3, 4)^T$ :  $\|\mathbf{v}\| = \sqrt{9 + 16} = 5$ ,  $\hat{\mathbf{v}} = \frac{1}{5}(3, 4)^T$ .

**Abstand:**  $d(\mathbf{u}, \mathbf{v}) = \|\mathbf{u} - \mathbf{v}\|$  (euklidische Metrik).

---

Die Dreiecksungleichung verallgemeinert: "Der direkte Weg ist nie laenger als ein Umweg."

## Definition

Das **Kreuzprodukt**  $\mathbf{u} \times \mathbf{v}$  fuer  $\mathbf{u}, \mathbf{v} \in \mathbb{R}^3$  ist

$$\mathbf{u} \times \mathbf{v} = \begin{pmatrix} u_2 v_3 - u_3 v_2 \\ u_3 v_1 - u_1 v_3 \\ u_1 v_2 - u_2 v_1 \end{pmatrix}.$$

## Eigenschaften:


- $\mathbf{u} \times \mathbf{v} \perp \mathbf{u}$  und  $\mathbf{u} \times \mathbf{v} \perp \mathbf{v}$
- Antikommutativ:  $\mathbf{u} \times \mathbf{v} = -(\mathbf{v} \times \mathbf{u})$
- $\|\mathbf{u} \times \mathbf{v}\| = \|\mathbf{u}\| \cdot \|\mathbf{v}\| \cdot \sin \theta$
- $\mathbf{u} \times \mathbf{v} = \mathbf{0} \Leftrightarrow \mathbf{u} \parallel \mathbf{v}$

## Beispiel:

$$\begin{pmatrix} 1 \\ 0 \\ 0 \end{pmatrix} \times \begin{pmatrix} 0 \\ 1 \\ 0 \end{pmatrix} = \begin{pmatrix} 0 \\ 0 \\ 1 \end{pmatrix}$$

## Kreuzprodukt $\mathbf{a} \times \mathbf{b}$

—	$\mathbf{a} = (1, 0, 0)$
—	$\mathbf{b} = (0, 1, 0)$
—	$\mathbf{a} \times \mathbf{b} = (0, 0, 1)$



## 1. Flächenberechnung:

Fläche des Dreiecks mit Ecken  $A, B, C$ :

$$F = \frac{1}{2} \|\vec{AB} \times \vec{AC}\|$$

**Beispiel:**  $A = (1, 0, 0)$ ,  $B = (0, 1, 0)$ ,  $C = (0, 0, 1)$ :

$$\vec{AB} \times \vec{AC} = \begin{pmatrix} -1 \\ 1 \\ 0 \end{pmatrix} \times \begin{pmatrix} -1 \\ 0 \\ 1 \end{pmatrix} = \begin{pmatrix} 1 \\ 1 \\ 1 \end{pmatrix}, \quad F = \frac{1}{2}\sqrt{3}$$

## 2. Volumenberechnung (Spatprodukt):

$$V = |\langle \mathbf{a}, (\mathbf{b} \times \mathbf{c}) \rangle| = |\det((\mathbf{a} \ \mathbf{b} \ \mathbf{c}))|$$

## 3. Normalenvektor einer Ebene:

Ebene durch  $P$  mit Richtungsvektoren  $\mathbf{u}, \mathbf{v}$ : Normalenvektor  $\mathbf{n} = \mathbf{u} \times \mathbf{v}$ .

---

Das Kreuzprodukt existiert nur in  $\mathbb{R}^3$  (und  $\mathbb{R}^7$ ) – in anderen Dimensionen gibt es kein Analogon.

## Definition







Eine **Matrix**  $\mathbf{A} \in \mathbb{R}^{m \times n}$  ist ein rechteckiges Zahlenschema mit  $m$  Zeilen und  $n$  Spalten:

$$\mathbf{A} = \begin{pmatrix} a_{11} & a_{12} & \cdots & a_{1n} \\ a_{21} & a_{22} & \cdots & a_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ a_{m1} & a_{m2} & \cdots & a_{mn} \end{pmatrix} = (a_{ij})_{\substack{1 \leq i \leq m \\ 1 \leq j \leq n}}$$

## Wichtige Typen:

- **Quadratisch:**  $m = n$
- **Einheitsmatrix:**  $\mathbf{I}_n$  (1 auf Diagonale)
- **Nullmatrix:**  $\mathbf{0}$  (alle Einträge 0)
- **Diagonalmatrix:**  $a_{ij} = 0$  fuer  $i \neq j$

## Wichtige Matrixtypen



## Symmetrische Matrix:

$$\mathbf{A}^T = \mathbf{A}, \quad a_{ij} = a_{ji}$$

Beispiel:  $\begin{pmatrix} 2 & 3 \\ 3 & 5 \end{pmatrix}$

## Obere Dreiecksmatrix:

$$a_{ij} = 0 \text{ fuer } i > j$$

Beispiel:  $\begin{pmatrix} 1 & 4 & 7 \\ 0 & 2 & 5 \\ 0 & 0 & 3 \end{pmatrix}$

## Orthogonale Matrix:

$$\mathbf{Q}^T \mathbf{Q} = \mathbf{I}, \quad \mathbf{Q}^{-1} = \mathbf{Q}^T$$

## Schiefsymmetrische Matrix:

$$\mathbf{A}^T = -\mathbf{A}, \quad a_{ij} = 0$$

## Untere Dreiecksmatrix:

$$a_{ij} = 0 \text{ fuer } i < j$$

## Duennbesetzte Matrix (Sparse):

Die meisten Eintraege sind 0. Wichtig in Anwendungen (Netzwerke, FEM).

## Stochastische Matrix:

Alle Eintraege  $\geq 0$ , Spaltensummen = 1.

---

Symmetrische Matrizen haben stets reelle Eigenwerte – ein fundamentales Resultat.

## Transponierte

Die **Transponierte**  $\mathbf{A}^T$  entsteht durch Vertauschen von Zeilen und Spalten:  $(\mathbf{A}^T)_{ij} = a_{ji}$ .

**Rechenregeln:**

- $(\mathbf{A}^T)^T = \mathbf{A}$
- $(\mathbf{A} + \mathbf{B})^T = \mathbf{A}^T + \mathbf{B}^T$
- $(\alpha\mathbf{A})^T = \alpha\mathbf{A}^T$
- $(\mathbf{AB})^T = \mathbf{B}^T\mathbf{A}^T$  (Reihenfolge umkehren!)

**Matrixaddition und Skalarmultiplikation** (komponentenweise, wie bei Vektoren):

$$\mathbf{A} + \mathbf{B} = (a_{ij} + b_{ij}), \quad \alpha\mathbf{A} = (\alpha \cdot a_{ij})$$

**Beispiel:**

$$\begin{pmatrix} 1 & 2 \\ 3 & 4 \end{pmatrix}^T = \begin{pmatrix} 1 & 3 \\ 2 & 4 \end{pmatrix}, \quad 2 \begin{pmatrix} 1 & 0 \\ -1 & 3 \end{pmatrix} = \begin{pmatrix} 2 & 0 \\ -2 & 6 \end{pmatrix}$$

Merke: Transponieren eines Produkts kehrt die Reihenfolge um – wie beim Invertieren.

## Definition

Fuer  $\mathbf{A} \in \mathbb{R}^{m \times p}$  und  $\mathbf{B} \in \mathbb{R}^{p \times n}$  ist das Produkt  $\mathbf{C} = \mathbf{AB} \in \mathbb{R}^{m \times n}$ :

$$c_{ij} = \sum_{k=1}^p a_{ik} b_{kj} = \text{“Zeile } i \text{ von } \mathbf{A} \text{”} \cdot \text{“Spalte } j \text{ von } \mathbf{B} \text{”}$$


**Voraussetzung:** Spaltenanzahl von  $\mathbf{A}$  = Zeilenanzahl von  $\mathbf{B}$ .

**Beispiel** ( $2 \times 2$ ):

$$\begin{pmatrix} 1 & 2 \\ 3 & 4 \end{pmatrix} \begin{pmatrix} 5 & 6 \\ 7 & 8 \end{pmatrix} = \begin{pmatrix} 19 & 22 \\ 43 & 50 \end{pmatrix}$$

z.B.  $c_{11} = 1 \cdot 5 + 2 \cdot 7 = 19$ .

Matrixmultiplikation: Zeile mal Spalte



**Matrixmultiplikation ist nicht kommutativ: Im Allgemeinen gilt  $\mathbf{AB} \neq \mathbf{BA}$ .**

## Eigenschaften:

- **Assoziativ:**  $(\mathbf{AB})\mathbf{C} = \mathbf{A}(\mathbf{BC})$
- **Distributiv:**  $\mathbf{A}(\mathbf{B} + \mathbf{C}) = \mathbf{AB} + \mathbf{AC}$
- **Nicht kommutativ:**  $\mathbf{AB} \neq \mathbf{BA}$  im Allgemeinen
- **Neutrales Element:**  $\mathbf{AI} = \mathbf{IA} = \mathbf{A}$
- **Nullteiler moeglich:**  $\mathbf{AB} = \mathbf{0}$  mit  $\mathbf{A} \neq \mathbf{0}$ ,  $\mathbf{B} \neq \mathbf{0}$

## Gegenbeispiel zur Kommutativitaet:

$$\mathbf{A} = \begin{pmatrix} 1 & 0 \\ 0 & 0 \end{pmatrix}, \mathbf{B} = \begin{pmatrix} 0 & 1 \\ 0 & 0 \end{pmatrix} : \mathbf{AB} = \begin{pmatrix} 0 & 1 \\ 0 & 0 \end{pmatrix}, \mathbf{BA} = \begin{pmatrix} 0 & 0 \\ 0 & 0 \end{pmatrix}$$

**Komplexitaet:** Naive Multiplikation zweier  $n \times n$ -Matrizen:  $\mathcal{O}(n^3)$ .

Strassen-Algorithmus:  $\mathcal{O}(n^{2,807})$ . Aktueller Rekord:  $\mathcal{O}(n^{2,373})$ .

---

Die  $\mathcal{O}(n^3)$ -Komplexitaet macht Matrixmultiplikation zum Flaschenhals vieler numerischer Verfahren.

## Matrix-Vektor-Produkt:

$$\mathbf{Ax} = \begin{pmatrix} a_{11} & a_{12} \\ a_{21} & a_{22} \end{pmatrix} \begin{pmatrix} x_1 \\ x_2 \end{pmatrix} = \begin{pmatrix} a_{11}x_1 + a_{12}x_2 \\ a_{21}x_1 + a_{22}x_2 \end{pmatrix} = x_1 \begin{pmatrix} a_{11} \\ a_{21} \end{pmatrix} + x_2 \begin{pmatrix} a_{12} \\ a_{22} \end{pmatrix}$$

⇒  $\mathbf{Ax}$  ist **Linearkombination der Spalten** von  $\mathbf{A}$ .

## Lineares Gleichungssystem:

$$\mathbf{Ax} = \mathbf{b} \iff \begin{cases} a_{11}x_1 + a_{12}x_2 + \cdots + a_{1n}x_n = b_1 \\ a_{21}x_1 + a_{22}x_2 + \cdots + a_{2n}x_n = b_2 \\ \vdots \\ a_{m1}x_1 + a_{m2}x_2 + \cdots + a_{mn}x_n = b_m \end{cases}$$

## Loesungsverhalten:

- **Eindeutig:**  $\text{rk}(\mathbf{A}) = \text{rk}(\mathbf{A}|\mathbf{b}) = n$
- **Unendlich viele:**  $\text{rk}(\mathbf{A}) = \text{rk}(\mathbf{A}|\mathbf{b}) < n$
- **Keine:**  $\text{rk}(\mathbf{A}) < \text{rk}(\mathbf{A}|\mathbf{b})$

---

Jedes lineare Gleichungssystem lässt sich kompakt als  $\mathbf{Ax} = \mathbf{b}$  schreiben.

## Definition

Der **Rang**  $\text{rk}(\mathbf{A})$  ist die maximale Anzahl linear unabhängiger Zeilen (= Spalten) von  $\mathbf{A}$ .

### Aequivalente Charakterisierungen:

- Dimension des Spaltenraums (= Bildraum)
- Dimension des Zeilenraums
- Anzahl der Pivotelemente in Zeilenstufenform
- Grösse der grössten nicht-verschwindenden Unterdeterminante

### Beispiel:

$$\mathbf{A} = \begin{pmatrix} 1 & 2 & 3 \\ 2 & 4 & 6 \\ 0 & 1 & 1 \end{pmatrix} \xrightarrow{\text{ZSF}} \begin{pmatrix} 1 & 2 & 3 \\ 0 & 1 & 1 \\ 0 & 0 & 0 \end{pmatrix} \Rightarrow \text{rk}(\mathbf{A}) = 2$$

### Rechenregeln:

- $\text{rk}(\mathbf{A}) \leq \min(m, n)$  fuer  $\mathbf{A} \in \mathbb{R}^{m \times n}$
- $\text{rk}(\mathbf{AB}) \leq \min(\text{rk}(\mathbf{A}), \text{rk}(\mathbf{B}))$
- $\text{rk}(\mathbf{A}) = \text{rk}(\mathbf{A}^T)$

**Voller Rang** ( $\text{rk}(\mathbf{A}) = \min(m, n)$ ) bedeutet: **Keine Zeile/Spalte ist "ueberfluessig"**.

## Definition

Die **Determinante** ordnet jeder quadratischen Matrix  $\mathbf{A} \in \mathbb{R}^{n \times n}$  eine reelle Zahl  $\det(\mathbf{A}) \in \mathbb{R}$  zu.


**2 × 2-Fall:**

$$\det\left(\begin{pmatrix} a & b \\ c & d \end{pmatrix}\right) = ad - bc$$

**3 × 3 (Sarrus):**

$$\det(\mathbf{A}) = a_{11}a_{22}a_{33} + a_{12}a_{23}a_{31} + a_{13}a_{21}a_{32} \\ - a_{13}a_{22}a_{31} - a_{12}a_{21}a_{33} - a_{11}a_{23}a_{32}$$

**Allgemein (Laplace-Entwicklung):**



## Fundamentale Eigenschaften:

1.  $\det(\mathbf{I}) = 1$
2. Zeilenvertauschung ändert Vorzeichen:  $\det(\dots) \rightarrow -\det(\dots)$
3.  $\det(\alpha\mathbf{A}) = \alpha^n \det(\mathbf{A})$  fuer  $\mathbf{A} \in \mathbb{R}^{n \times n}$
4.  $\det(\mathbf{AB}) = \det(\mathbf{A}) \cdot \det(\mathbf{B})$  (Produktsatz)
5.  $\det(\mathbf{A}^T) = \det(\mathbf{A})$
6.  $\mathbf{A}$  invertierbar  $\Leftrightarrow \det(\mathbf{A}) \neq 0$
7.  $\det(\mathbf{A}^{-1}) = \frac{1}{\det(\mathbf{A})}$  (falls  $\mathbf{A}$  invertierbar)

## Geometrische Interpretation:

- $|\det(\mathbf{A})|$  = Faktor der Volumenaenderung unter der Abbildung  $\mathbf{x} \mapsto \mathbf{Ax}$
- $\det(\mathbf{A}) > 0$ : Orientierung bleibt erhalten
- $\det(\mathbf{A}) < 0$ : Orientierung wird umgekehrt
- $\det(\mathbf{A}) = 0$ : Dimension wird reduziert (Abbildung ist nicht injektiv)

**Beispiel:**  $\mathbf{A} = \begin{pmatrix} 2 & 0 \\ 0 & 3 \end{pmatrix}$ :  $\det(\mathbf{A}) = 6$  – Flaeche wird um Faktor 6 skaliert.

---

Der Produktsatz  $\det(\mathbf{AB}) = \det(\mathbf{A}) \det(\mathbf{B})$  ist eines der elegantesten Resultate der linearen Algebra.

Berechne:

$$\mathbf{A} = \begin{pmatrix} 2 & 1 & 3 \\ 0 & -1 & 4 \\ 5 & 2 & 1 \end{pmatrix}$$

**Methode 1: Sarrus-Regel**

$$\begin{aligned} \det(\mathbf{A}) &= 2 \cdot (-1) \cdot 1 + 1 \cdot 4 \cdot 5 + 3 \cdot 0 \cdot 2 \\ &\quad - 3 \cdot (-1) \cdot 5 - 1 \cdot 0 \cdot 1 - 2 \cdot 4 \cdot 2 \\ &= -2 + 20 + 0 + 15 - 0 - 16 = 17 \end{aligned}$$

**Methode 2: Laplace-Entwicklung nach 1. Spalte**

$$\begin{aligned} \det(\mathbf{A}) &= 2 \cdot \det \begin{pmatrix} -1 & 4 \\ 2 & 1 \end{pmatrix} - 0 \cdot \det \begin{pmatrix} 1 & 3 \\ 2 & 1 \end{pmatrix} + 5 \cdot \det \begin{pmatrix} 1 & 3 \\ -1 & 4 \end{pmatrix} \\ &= 2(-1 - 8) - 0 + 5(4 + 3) = 2 \cdot (-9) + 5 \cdot 7 = -18 + 35 = 17 \checkmark \end{aligned}$$

---

**Tip:** Entwickle nach der Zeile/Spalte mit den meisten Nullen – das spart Rechenaufwand.

## Definition

Eine Matrix  $\mathbf{A} \in \mathbb{R}^{n \times n}$  heisst **invertierbar** (regulaer), falls eine Matrix  $\mathbf{A}^{-1}$  existiert mit

$$\mathbf{A}\mathbf{A}^{-1} = \mathbf{A}^{-1}\mathbf{A} = \mathbf{I}_n.$$


## Aequivalente Bedingungen:

- $\det(\mathbf{A}) \neq 0$
- $\text{rk}(\mathbf{A}) = n$  (voller Rang)
- $\mathbf{A}\mathbf{x} = \mathbf{0}$  hat nur  $\mathbf{x} = \mathbf{0}$  als Loesung
- Spalten (Zeilen) sind linear unabhaengig
- 0 ist kein Eigenwert von  $\mathbf{A}$

## Rechenregeln:

- $(\mathbf{A}^{-1})^{-1} = \mathbf{A}$
- $(\mathbf{A}\mathbf{B})^{-1} = \mathbf{B}^{-1}\mathbf{A}^{-1}$
- $(\mathbf{A}^T)^{-1} = (\mathbf{A}^{-1})^T$

Die Inverse “macht die Transformation rueckgaengig”:  $\mathbf{A}^{-1}(\mathbf{A}\mathbf{x}) = \mathbf{x}$ .



## Formel fuer $2 \times 2$

$$\mathbf{A} = \begin{pmatrix} a & b \\ c & d \end{pmatrix} \implies \mathbf{A}^{-1} = \frac{1}{ad - bc} \begin{pmatrix} d & -b \\ -c & a \end{pmatrix}$$

falls  $\det(\mathbf{A}) = ad - bc \neq 0$ .

**Beispiel:**

$$\mathbf{A} = \begin{pmatrix} 3 & 1 \\ 5 & 2 \end{pmatrix}, \quad \det(\mathbf{A}) = 6 - 5 = 1, \quad \mathbf{A}^{-1} = \begin{pmatrix} 2 & -1 \\ -5 & 3 \end{pmatrix}$$

**Probe:**

$$\mathbf{A}\mathbf{A}^{-1} = \begin{pmatrix} 3 & 1 \\ 5 & 2 \end{pmatrix} \begin{pmatrix} 2 & -1 \\ -5 & 3 \end{pmatrix} = \begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix} = \mathbf{I} \checkmark$$

**Anwendung – Loesung von  $\mathbf{Ax} = \mathbf{b}$ :**

$$\mathbf{x} = \mathbf{A}^{-1}\mathbf{b} = \begin{pmatrix} 2 & -1 \\ -5 & 3 \end{pmatrix} \begin{pmatrix} 7 \\ 4 \end{pmatrix} = \begin{pmatrix} 10 \\ -23 \end{pmatrix}$$

Fuer grosse Systeme ist die direkte Inversion ineffizient – Gauss-Elimination ist besser.

**Methode:** Erweitere  $(\mathbf{A} \mid \mathbf{I})$  und bringe  $\mathbf{A}$  durch Zeilenumformungen auf  $\mathbf{I}$ :

$$(\mathbf{A} \mid \mathbf{I}) \xrightarrow{\text{Gauss-Jordan}} (\mathbf{I} \mid \mathbf{A}^{-1})$$

**Beispiel:**

$$\begin{aligned} & \left( \begin{array}{cc|cc} 2 & 1 & 1 & 0 \\ 5 & 3 & 0 & 1 \end{array} \right) \xrightarrow{Z_2 - \frac{5}{2}Z_1} \left( \begin{array}{cc|cc} 2 & 1 & 1 & 0 \\ 0 & \frac{1}{2} & -\frac{5}{2} & 1 \end{array} \right) \\ & \xrightarrow{2 \cdot Z_2} \left( \begin{array}{cc|cc} 2 & 1 & 1 & 0 \\ 0 & 1 & -5 & 2 \end{array} \right) \xrightarrow{Z_1 - Z_2} \left( \begin{array}{cc|cc} 2 & 0 & 6 & -2 \\ 0 & 1 & -5 & 2 \end{array} \right) \\ & \xrightarrow{\frac{1}{2}Z_1} \left( \begin{array}{cc|cc} 1 & 0 & 3 & -1 \\ 0 & 1 & -5 & 2 \end{array} \right) \Rightarrow \mathbf{A}^{-1} = \begin{pmatrix} 3 & -1 \\ -5 & 2 \end{pmatrix} \end{aligned}$$

---

Das Gauss-Jordan-Verfahren berechnet gleichzeitig  $\mathbf{A}^{-1}$  und prüft die Invertierbarkeit.

## Ziel

Bringe die erweiterte Koeffizientenmatrix ( $\mathbf{A|b}$ ) durch **elementare Zeilenumformungen** auf **Zeilenstufenform (ZSF)**.

### Erlaubte Zeilenumformungen:

1. Vertausche Zeile  $i$  und Zeile  $j$ :  $Z_i \leftrightarrow Z_j$
2. Multipliziere Zeile  $i$  mit  $\alpha \neq 0$ :  $Z_i \rightarrow \alpha Z_i$
3. Addiere das  $\alpha$ -fache von Zeile  $j$  zu Zeile  $i$ :  $Z_i \rightarrow Z_i + \alpha Z_j$

### Zeilenstufenform (ZSF):

- Nullzeilen stehen unten
- Das erste Nicht-Null-Element jeder Zeile (Pivot) steht rechts vom Pivot der Zeile darüber

### Reduzierte ZSF (RZSF):

- Jedes Pivot ist 1
- Ueber jedem Pivot stehen nur Nullen

Gauss-Elimination: Schrittweise Umformung



Gauss-Elimination hat Komplexitaet  $\mathcal{O}(n^3)$  und ist der Standard-Algorithmus fuer LGS.

**Loese:**

$$\begin{cases} x + 2y - z = 3 \\ 2x + 5y + z = 8 \\ 3x + 7y - 2z = 7 \end{cases} \longleftrightarrow \left( \begin{array}{ccc|c} 1 & 2 & -1 & 3 \\ 2 & 5 & 1 & 8 \\ 3 & 7 & -2 & 7 \end{array} \right)$$

**Schritt 1:**  $Z_2 \rightarrow Z_2 - 2Z_1$ ,  $Z_3 \rightarrow Z_3 - 3Z_1$ :

$$\left( \begin{array}{ccc|c} 1 & 2 & -1 & 3 \\ 0 & 1 & 3 & 2 \\ 0 & 1 & 1 & -2 \end{array} \right)$$

**Schritt 2:**  $Z_3 \rightarrow Z_3 - Z_2$ :

$$\left( \begin{array}{ccc|c} 1 & 2 & -1 & 3 \\ 0 & 1 & 3 & 2 \\ 0 & 0 & -2 & -4 \end{array} \right)$$

**Rueckwaerts einsetzen:**  $z = 2$ ,  $y = 2 - 3 \cdot 2 = -4$ ,  $x = 3 - 2(-4) + 2 = 13$ .

**Probe:**  $13 + 2(-4) - 2 = 3 \checkmark$ ,  $26 + 5(-4) + 2 = 8 \checkmark$ ,  $39 + 7(-4) - 4 = 7 \checkmark$ .

---

Systematisches Rueckwaertseinsetzen liefert die Loesung – Probe stets empfohlen!

## Fall: Unendlich viele Lösungen

$$\begin{cases} x + 2y + z = 4 \\ 2x + 4y + 3z = 9 \\ x + 2y + 2z = 5 \end{cases} \longrightarrow \left( \begin{array}{ccc|c} 1 & 2 & 1 & 4 \\ 0 & 0 & 1 & 1 \\ 0 & 0 & 0 & 0 \end{array} \right)$$

$\text{rk}(\mathbf{A}) = 2 < 3 = n$ , aber  $\text{rk}(\mathbf{A}|\mathbf{b}) = 2 \Rightarrow \infty$  viele Lösungen.

Freie Variable:  $y = t$  (Parameter). Aus ZSF:  $z = 1$ ,  $x = 4 - 2t - 1 = 3 - 2t$ .

$$\mathbf{x} = \begin{pmatrix} 3 - 2t \\ t \\ 1 \end{pmatrix} = \underbrace{\begin{pmatrix} 3 \\ 0 \\ 1 \end{pmatrix}}_{\text{partikulaer}} + t \underbrace{\begin{pmatrix} -2 \\ 1 \\ 0 \end{pmatrix}}_{\in \ker(\mathbf{A})}, \quad t \in \mathbb{R}$$

## Fall: Keine Lösung

$$\left( \begin{array}{cc|c} 1 & 2 & 3 \\ 2 & 4 & 8 \end{array} \right) \longrightarrow \left( \begin{array}{cc|c} 1 & 2 & 3 \\ 0 & 0 & 2 \end{array} \right) \Rightarrow 0 = 2 \text{ Widerspruch!}$$

Die Struktur der Lösungsmenge: Partikuläre Lösung + Kern (affiner Unterraum).

## Zusammenfassung

Der Rang  $\text{rk}(\mathbf{A})$  kann auf mehrere äquivalente Weisen bestimmt werden.

### Methode 1: Zeilenstufenform (effizienteste Methode)

$$\mathbf{A} = \begin{pmatrix} 1 & 3 & 2 & 4 \\ 2 & 6 & 5 & 9 \\ 1 & 3 & 4 & 8 \end{pmatrix} \xrightarrow{\text{Gauss}} \begin{pmatrix} 1 & 3 & 2 & 4 \\ 0 & 0 & 1 & 1 \\ 0 & 0 & 0 & 0 \end{pmatrix} \Rightarrow \text{rk}(\mathbf{A}) = 2$$

### Methode 2: Unterdeterminanten

$\text{rk}(\mathbf{A}) = r \Leftrightarrow$  es gibt eine nicht-verschwindende  $r \times r$ -Unterdeterminante, aber keine  $(r+1) \times (r+1)$ -Unterdeterminante  $\neq 0$ .

### Methode 3: Lineare Unabhaengigkeit der Spalten/Zeilen

Maximale Anzahl linear unabhaenger Spalten- oder Zeilenvektoren.

**Merke:** Zeilenrang = Spaltenrang =  $\text{rk}(\mathbf{A})$  (Rangsatz).

In der Praxis ist die Zeilenstufenform die effizienteste Methode zur Rangbestimmung.

## Satz (Kronecker-Capelli)

Das System  $\mathbf{Ax} = \mathbf{b}$  ist loesbar genau dann, wenn

$$\text{rk}(\mathbf{A}) = \text{rk}(\mathbf{A}|\mathbf{b}).$$

**Vollstaendige Fallunterscheidung:** Sei  $\mathbf{A} \in \mathbb{R}^{m \times n}$ .

Bedingung	Loesung	Loesungsraum
$\text{rk}(\mathbf{A}) < \text{rk}(\mathbf{A} \mathbf{b})$	keine	$\emptyset$
$\text{rk}(\mathbf{A}) = \text{rk}(\mathbf{A} \mathbf{b}) = n$	eindeutig	$\{\mathbf{x}_0\}$
$\text{rk}(\mathbf{A}) = \text{rk}(\mathbf{A} \mathbf{b}) = r < n$	$\infty$ viele	$\mathbf{x}_0 + \ker(\mathbf{A})$

**Loesung bei unendlich vielen:**

$$\mathbf{x} = \mathbf{x}_{\text{partikulaer}} + \sum_{i=1}^{n-r} c_i \mathbf{h}_i, \quad c_i \in \mathbb{R}$$

wobei  $\mathbf{h}_1, \dots, \mathbf{h}_{n-r}$  eine Basis von  $\ker(\mathbf{A})$  bilden.

$n - r = n - \text{rk}(\mathbf{A}) =$  Anzahl der **freien Parameter** (Freiheitsgrade).

Der Rang entscheidet alles: Existenz, Eindeutigkeit und Dimension des Loesungsraums.

### Lineares Produktionsmodell:

$m$  Gleichungen (Ressourcen),  $n$  Unbekannte (Produkte), System  $\mathbf{Ax} = \mathbf{b}$ .

### Interpretation der Faelle:

- $\text{rk}(\mathbf{A}) = n = m$  (quadratisch, voller Rang): Genau ein Produktionsplan moeglich
- $\text{rk}(\mathbf{A}) < n$ : Ueberbestimmte Kapazitaeten – Freiheitsgrade in der Planung
- $\text{rk}(\mathbf{A}) < \text{rk}(\mathbf{A}|\mathbf{b})$ : Inkonsistente Anforderungen – Nachfrage nicht erfuellbar

**Beispiel:** 3 Maschinen, 4 Produkte:

$$\begin{pmatrix} 2 & 1 & 3 & 1 \\ 1 & 2 & 1 & 2 \\ 3 & 3 & 4 & 3 \end{pmatrix} \mathbf{x} = \begin{pmatrix} 100 \\ 80 \\ 180 \end{pmatrix}$$

Zeile 3 = Zeile 1 + Zeile 2, also  $\text{rk}(\mathbf{A}) = 2$ ,  $\text{rk}(\mathbf{A}|\mathbf{b}) = 2$  (da  $180 = 100 + 80$ ).

$\Rightarrow \infty$  viele Loesungen mit  $4 - 2 = 2$  freien Parametern.

**Bedeutung:** Das Unternehmen hat Flexibilitaet bei der Wahl des Produktionsmixes.

---

Der Rang misst die "effektive Dimensionalitaet" eines Systems – redundante Gleichungen zaehlen nicht.

## Definition

Sei  $\mathbf{A} \in \mathbb{R}^{n \times n}$ . Ein Skalar  $\lambda \in \mathbb{R}$  (oder  $\mathbb{C}$ ) heisst **Eigenwert** von  $\mathbf{A}$ , falls ein Vektor  $\mathbf{v} \neq \mathbf{0}$  existiert mit

$$\mathbf{A}\mathbf{v} = \lambda\mathbf{v}.$$

Der Vektor  $\mathbf{v}$  heisst **Eigenvektor** zum Eigenwert  $\lambda$ .

## Interpretation:

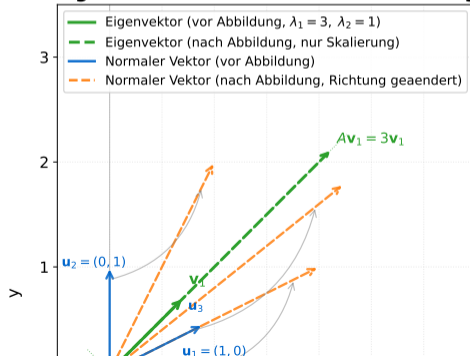
- $\mathbf{A}$  streckt  $\mathbf{v}$  um Faktor  $\lambda$
- Richtung bleibt erhalten (oder kehrt um bei  $\lambda < 0$ )
- $\mathbf{v}$  liegt auf einer **invarianten Geraden**

## Charakteristisches Polynom:

$$p(\lambda) = \det(\mathbf{A} - \lambda\mathbf{I}) = 0$$

Die Nullstellen von  $p(\lambda)$  sind die Eigenwerte.

## Eigenvektoren unter linearer Abbildung



**Beispiel:**

$$\mathbf{A} = \begin{pmatrix} 4 & 1 \\ 2 & 3 \end{pmatrix}$$

**Schritt 1:** Charakteristisches Polynom:

$$\det(\mathbf{A} - \lambda \mathbf{I}) = \det \begin{pmatrix} 4 - \lambda & 1 \\ 2 & 3 - \lambda \end{pmatrix} = (4 - \lambda)(3 - \lambda) - 2 = \lambda^2 - 7\lambda + 10$$

**Schritt 2:** Nullstellen:  $\lambda^2 - 7\lambda + 10 = (\lambda - 2)(\lambda - 5) = 0$

$$\lambda_1 = 2, \quad \lambda_2 = 5$$

**Schritt 3:** Eigenvektoren bestimmen:

- $\lambda_1 = 2$ :  $(\mathbf{A} - 2\mathbf{I})\mathbf{v} = \mathbf{0}$ :  $\begin{pmatrix} 2 & 1 \\ 2 & 1 \end{pmatrix} \mathbf{v} = \mathbf{0} \Rightarrow \mathbf{v}_1 = t \begin{pmatrix} 1 \\ -2 \end{pmatrix}$
- $\lambda_2 = 5$ :  $(\mathbf{A} - 5\mathbf{I})\mathbf{v} = \mathbf{0}$ :  $\begin{pmatrix} -1 & 1 \\ 2 & -2 \end{pmatrix} \mathbf{v} = \mathbf{0} \Rightarrow \mathbf{v}_2 = s \begin{pmatrix} 1 \\ 1 \end{pmatrix}$

**Kontrolle:**  $\text{Sp}(\mathbf{A}) = 4 + 3 = 7 = \lambda_1 + \lambda_2 \checkmark$ ,  $\det(\mathbf{A}) = 10 = \lambda_1 \lambda_2 \checkmark$ .

---

**Spur = Summe der Eigenwerte, Determinante = Produkt der Eigenwerte – stets prüfen!**

## Satz

Falls  $\mathbf{A} \in \mathbb{R}^{n \times n}$  genau  $n$  linear unabhängige Eigenvektoren besitzt, dann gilt

$$\mathbf{A} = \mathbf{P} \mathbf{D} \mathbf{P}^{-1},$$

wobei  $\mathbf{D} = \text{diag}(\lambda_1, \dots, \lambda_n)$  und  $\mathbf{P} = (\mathbf{v}_1 \mid \dots \mid \mathbf{v}_n)$ .

**Beispiel (Fortsetzung):**

$$\mathbf{P} = \begin{pmatrix} 1 & 1 \\ -2 & 1 \end{pmatrix}, \quad \mathbf{D} = \begin{pmatrix} 2 & 0 \\ 0 & 5 \end{pmatrix}, \quad \mathbf{A} = \mathbf{P} \mathbf{D} \mathbf{P}^{-1}$$

**Nutzen der Diagonalisierung:**

- **Matrixpotenzen:**  $\mathbf{A}^k = \mathbf{P} \mathbf{D}^k \mathbf{P}^{-1} = \mathbf{P} \text{diag}(\lambda_1^k, \dots, \lambda_n^k) \mathbf{P}^{-1}$
- **Exponential:**  $e^{\mathbf{A}t} = \mathbf{P} \text{diag}(e^{\lambda_1 t}, \dots, e^{\lambda_n t}) \mathbf{P}^{-1}$
- **Stabilität:**  $\mathbf{A}^k \rightarrow \mathbf{0} \Leftrightarrow$  alle  $|\lambda_i| < 1$

**Nicht diagonalisierbar:**  $\mathbf{A} = \begin{pmatrix} 1 & 1 \\ 0 & 1 \end{pmatrix}$  hat  $\lambda = 1$  (doppelt), aber nur einen Eigenvektor.

Diagonalisierung reduziert Matrixoperationen auf skalare Operationen – ein mächtiges Werkzeug.

## Spur (Trace)

Die **Spur** einer Matrix  $\mathbf{A} \in \mathbb{R}^{n \times n}$  ist  $\text{Sp}(\mathbf{A}) = \sum_{i=1}^n a_{ii} = \sum_{i=1}^n \lambda_i$ .

### Eigenschaften der Spur:

- $\text{Sp}(\mathbf{A} + \mathbf{B}) = \text{Sp}(\mathbf{A}) + \text{Sp}(\mathbf{B})$
- $\text{Sp}(\alpha \mathbf{A}) = \alpha \text{Sp}(\mathbf{A})$
- $\text{Sp}(\mathbf{AB}) = \text{Sp}(\mathbf{BA})$  (zyklische Vertauschung)
- $\text{Sp}(\mathbf{A}^T) = \text{Sp}(\mathbf{A})$

## Spektralsatz (für symmetrische Matrizen)

Sei  $\mathbf{A} = \mathbf{A}^T \in \mathbb{R}^{n \times n}$ . Dann:

1. Alle Eigenwerte von  $\mathbf{A}$  sind **reell**.
2. Eigenvektoren zu verschiedenen Eigenwerten sind **orthogonal**.
3. Es existiert eine orthogonale Matrix  $\mathbf{Q}$  mit  $\mathbf{A} = \mathbf{QDQ}^T$ .

Der Spektralsatz ist fundamental für Hauptachsentransformation, PCA und Quantenmechanik.

Was passiert geometrisch bei  $\mathbf{A}\mathbf{v} = \lambda\mathbf{v}$ ?

Eigenwert $\lambda$	Wirkung auf Eigenvektor	Beispiel
$\lambda > 1$	Streckung in Eigenrichtung	Wachstumsmodus
$0 < \lambda < 1$	Stauchung in Eigenrichtung	Daempfungsmodus
$\lambda = 1$	Fixrichtung (invariant)	Stationaerer Zustand
$\lambda = 0$	Projektion (Richtung verschwindet)	Singulaerer Modus
$\lambda < 0$	Spiegelung + Skalierung	Oszillation
$\lambda \in \mathbb{C} \setminus \mathbb{R}$	Drehung + Skalierung	Spiralbewegung

## Hauptachsentransformation:

Fuer symmetrisches  $\mathbf{A} = \mathbf{A}^T$ : Die Eigenvektoren bilden ein orthogonales Koordinatensystem, in dem  $\mathbf{A}$  als reine Skalierung wirkt.

## Anwendung – Hauptkomponentenanalyse (PCA):

Kovarianzmatrix  $\Sigma$  einer Datenwolke: Eigenvektoren = Hauptachsen der Streuung, Eigenwerte = Varianz in jeder Richtung.

Eigenwerte machen komplexe Transformationen verstaendlich – jede Richtung einzeln betrachtet.

**Beispiel:**

$$\mathbf{A} = \begin{pmatrix} 2 & 0 & 0 \\ 0 & 3 & 1 \\ 0 & 1 & 3 \end{pmatrix}$$

**Charakteristisches Polynom:**

$$\begin{aligned} p(\lambda) &= \det(\mathbf{A} - \lambda \mathbf{I}) = (2 - \lambda) [(3 - \lambda)^2 - 1] = (2 - \lambda)(\lambda^2 - 6\lambda + 8) \\ &= (2 - \lambda)(2 - \lambda)(4 - \lambda) = -(2 - \lambda)^2(\lambda - 4) \cdot (-1) = (2 - \lambda)^2(\lambda - 4) \cdot (-1) \end{aligned}$$

Korrekt:  $p(\lambda) = (2 - \lambda)[(3 - \lambda)^2 - 1] = (2 - \lambda)(\lambda - 2)(\lambda - 4) = -(2 - \lambda)^2(\lambda - 4)$   
 $\Rightarrow \lambda_1 = 2$  (algebraische Vielfachheit 2),  $\lambda_2 = 4$  (Vielfachheit 1).

**Eigenvektoren:**

- $\lambda = 2$ :  $\ker(\mathbf{A} - 2\mathbf{I}) = \text{Sp} \left\{ \begin{pmatrix} 1 \\ 0 \\ 0 \end{pmatrix}, \begin{pmatrix} 0 \\ 1 \\ -1 \end{pmatrix} \right\}$  (geometrische Vielfachheit = 2)
- $\lambda = 4$ :  $\ker(\mathbf{A} - 4\mathbf{I}) = \text{Sp} \left\{ \begin{pmatrix} 0 \\ 1 \\ 1 \end{pmatrix} \right\}$

Da algebraische = geometrische Vielfachheit fuer alle  $\lambda$ :  $\mathbf{A}$  ist diagonalisierbar.

Bei symmetrischen Matrizen stimmen algebraische und geometrische Vielfachheit stets ueberein.

## Definition

Eine Abbildung  $T: \mathbb{R}^n \rightarrow \mathbb{R}^m$  heisst **linear**, falls fuer alle  $\mathbf{u}, \mathbf{v} \in \mathbb{R}^n$  und  $\alpha \in \mathbb{R}$ :





$$T(\mathbf{u} + \mathbf{v}) = T(\mathbf{u}) + T(\mathbf{v}), \quad T(\alpha \mathbf{v}) = \alpha T(\mathbf{v}).$$

**Fundamentalsatz:** Jede lineare Abbildung  $T: \mathbb{R}^n \rightarrow \mathbb{R}^m$  wird durch genau eine Matrix  $\mathbf{A} \in \mathbb{R}^{m \times n}$  dargestellt:  
 $T(\mathbf{x}) = \mathbf{A}\mathbf{x}$ .

**Wichtige Transformationen in  $\mathbb{R}^2$ :**

- Drehung um  $\theta$ :  $\begin{pmatrix} \cos \theta & -\sin \theta \\ \sin \theta & \cos \theta \end{pmatrix}$
- Spiegelung an  $x$ -Achse:  $\begin{pmatrix} 1 & 0 \\ 0 & -1 \end{pmatrix}$
- Skalierung:  $\begin{pmatrix} s_x & 0 \\ 0 & s_y \end{pmatrix}$
- Scherung:  $\begin{pmatrix} 1 & k \\ 0 & 1 \end{pmatrix}$

Lineare Transformationen des Einheitsquadrats



## Methode

Die **Darstellungsmatrix** einer linearen Abbildung  $T: \mathbb{R}^n \rightarrow \mathbb{R}^m$  bzgl. der Standardbasen ist

$$\mathbf{A} = (T(\mathbf{e}_1) \mid T(\mathbf{e}_2) \mid \cdots \mid T(\mathbf{e}_n)) \in \mathbb{R}^{m \times n}$$

Die  $j$ -te Spalte von  $\mathbf{A}$  ist das Bild des  $j$ -ten Standardbasisvektors.

**Beispiel:** Drehung um  $60$  in  $\mathbb{R}^2$ :

$$\begin{aligned} T(\mathbf{e}_1) &= \begin{pmatrix} \cos 60 \\ \sin 60 \end{pmatrix} = \begin{pmatrix} 0,5 \\ \frac{\sqrt{3}}{2} \end{pmatrix}, & T(\mathbf{e}_2) &= \begin{pmatrix} -\sin 60 \\ \cos 60 \end{pmatrix} = \begin{pmatrix} -\frac{\sqrt{3}}{2} \\ 0,5 \end{pmatrix} \\ \Rightarrow \mathbf{A} &= \begin{pmatrix} 0,5 & -\frac{\sqrt{3}}{2} \\ \frac{\sqrt{3}}{2} & 0,5 \end{pmatrix} \end{aligned}$$

**Eigenschaften von Drehmatrizen:**

- Orthogonal:  $\mathbf{A}^T \mathbf{A} = \mathbf{I}$  ( $\Rightarrow$  Längen und Winkel bleiben erhalten)
- $\det(\mathbf{A}) = 1$  (Orientierungserhaltend)
- Eigenwerte:  $\lambda = e^{\pm i\theta}$  (komplex für  $\theta \neq 0, \pi$ )

**Basiswechsel:** Bei anderer Basis  $\mathcal{B}$ :  $\mathbf{A}_{\mathcal{B}} = \mathbf{S}^{-1} \mathbf{A} \mathbf{S}$  mit Basiswechselmatrix  $\mathbf{S}$ .

Dieselbe Abbildung hat verschiedene Matrixdarstellungen – abhängig von der gewählten Basis.

## Definitionen

Fuer  $T(\mathbf{x}) = \mathbf{Ax}$ :

- **Kern:**  $\ker(\mathbf{A}) = \{\mathbf{x} \in \mathbb{R}^n \mid \mathbf{Ax} = \mathbf{0}\}$  (Nullraum)
- **Bild:**  $\text{im}(\mathbf{A}) = \{\mathbf{Ax} \mid \mathbf{x} \in \mathbb{R}^n\}$  (Spaltenraum)

**Dimensionsformel (Rang-Nulltaets-Satz):**

$$\dim(\ker(\mathbf{A})) + \dim(\text{im}(\mathbf{A})) = n \iff \text{Nulltaet} + \text{rk}(\mathbf{A}) = n$$

**Beispiel:**

$$\mathbf{A} = \begin{pmatrix} 1 & 2 & 1 \\ 2 & 4 & 2 \end{pmatrix} : \quad \text{rk}(\mathbf{A}) = 1, \quad \dim(\ker(\mathbf{A})) = 3 - 1 = 2$$

**Interpretation:**

- $\ker(\mathbf{A}) = \{\mathbf{0}\} \Leftrightarrow T$  ist injektiv
- $\text{im}(\mathbf{A}) = \mathbb{R}^m \Leftrightarrow T$  ist surjektiv
- Beides  $\Leftrightarrow T$  ist bijektiv ( $\mathbf{A}$  invertierbar, nur fuer  $m = n$ )

Die Dimensionsformel ist eines der zentralen Resultate der linearen Algebra.

## Modell (Wassily Leontief, 1936)

Die Wirtschaft besteht aus  $n$  Sektoren. Sektor  $j$  benötigt zur Produktion von einer Einheit Output den Anteil  $a_{ij}$  vom Output des Sektors  $i$ . Die **Technologiematrix** ist  $\mathbf{A} = (a_{ij})$ .


**Gleichgewichtsbedingung:**

$$\mathbf{x} = \mathbf{Ax} + \mathbf{d} \implies (\mathbf{I} - \mathbf{A})\mathbf{x} = \mathbf{d}$$


$$\mathbf{x} = (\mathbf{I} - \mathbf{A})^{-1}\mathbf{d}$$

wobei  $\mathbf{x}$  = Gesamtproduktion,  $\mathbf{d}$  = Endnachfrage.

$(\mathbf{I} - \mathbf{A})^{-1}$  heisst **Leontief-Inverse**.



Leontief Input-Output-Modell



**Bedingung:**  $(\mathbf{I} - \mathbf{A})$  muss invertierbar sein. Hinreichend: Alle Spaltensummen von  $\mathbf{A}$  sind  $< 1$  (produktive Wirtschaft).

Leontief erhielt 1973 den Nobelpreis fuer Wirtschaftswissenschaften fuer dieses Modell.

**Drei-Sektoren-Wirtschaft:** Landwirtschaft (L), Industrie (I), Dienstleistungen (D).

$$\mathbf{A} = \begin{pmatrix} 0,2 & 0,1 & 0,1 \\ 0,3 & 0,2 & 0,2 \\ 0,1 & 0,3 & 0,1 \end{pmatrix}, \quad \mathbf{d} = \begin{pmatrix} 50 \\ 80 \\ 60 \end{pmatrix}$$

**Berechnung:**

$$\mathbf{I} - \mathbf{A} = \begin{pmatrix} 0,8 & -0,1 & -0,1 \\ -0,3 & 0,8 & -0,2 \\ -0,1 & -0,3 & 0,9 \end{pmatrix}$$

$$\mathbf{x} = (\mathbf{I} - \mathbf{A})^{-1} \mathbf{d} \approx \begin{pmatrix} 96,7 \\ 155,1 \\ 121,3 \end{pmatrix}$$

**Interpretation:** Um die Endnachfrage  $\mathbf{d}$  zu befriedigen, muss Sektor L ca. 96,7, Sektor I ca. 155,1 und Sektor D ca. 121,3 Einheiten produzieren.

**Spaltensummen von  $\mathbf{A}$ :** 0,6; 0,6; 0,4 – alle  $< 1 \Rightarrow$  produktive Wirtschaft. ✓

---

Die Leontief-Inverse zeigt direkte und indirekte Verflechtungen zwischen den Sektoren.

## Definition

Eine **Markov-Kette** ist ein stochastischer Prozess, bei dem der naechste Zustand nur vom aktuellen Zustand abhaengt (Gedaechtnislosigkeit). Die Uebergangswahrscheinlichkeiten bilden eine **stochastische Matrix P**.

## Uebergangsmatrix:

$$\mathbf{P} = (p_{ij}), \quad p_{ij} \geq 0, \quad \sum_j p_{ij} = 1$$

$p_{ij}$  = Wahrscheinlichkeit, von Zustand  $i$  nach  $j$  zu wechseln.



## Zustandsvektor:

$$\pi^{(t+1)} = \pi^{(t)}\mathbf{P} \quad \Rightarrow \quad \pi^{(t)} = \pi^{(0)}\mathbf{P}^t$$

**Stationaere Verteilung:**  $\pi = \pi\mathbf{P}$  mit  $\sum_i \pi_i = 1$ .  
 $\Rightarrow \pi$  ist Linkseigenvektor zum Eigenwert  $\lambda = 1$ .

Markov-Ketten modellieren Wetter, Finanzmaerkte, PageRank, Genetik und viele weitere Prozesse.

Markov-Kette: Uebergangsmatrix und stationaere Verteilung



**Wettermodell:** Zwei Zustände: Sonnig (S) und Regnerisch (R).

$$\mathbf{P} = \begin{pmatrix} 0,8 & 0,2 \\ 0,4 & 0,6 \end{pmatrix} \quad (\text{Zeilen: von; Spalten: nach})$$

**Interpretation:** Wenn heute sonnig, dann morgen zu 80% sonnig, zu 20% regnerisch.

**Stationäre Verteilung:**  $\pi \mathbf{P} = \pi$ ,  $\pi_S + \pi_R = 1$ .

$$0,8\pi_S + 0,4\pi_R = \pi_S \quad \Rightarrow \quad 0,4\pi_R = 0,2\pi_S \quad \Rightarrow \quad \pi_S = 2\pi_R$$

$$\pi_S + \pi_R = 1 \quad \Rightarrow \quad \pi_S = \frac{2}{3}, \quad \pi_R = \frac{1}{3}$$

**Langzeitverhalten:** Unabhängig vom Startzustand konvergiert die Verteilung gegen  $(\frac{2}{3}, \frac{1}{3})$ .

**Numerisch:**  $\pi^{(0)} = (1, 0)$ : Nach 5 Schritten:  $(0,6671; 0,3329) \approx (\frac{2}{3}, \frac{1}{3})$ .

---

Ergodische Markov-Ketten konvergieren stets gegen eine eindeutige stationäre Verteilung.

## Modell

Ein Portfolio mit  $n$  Anlagen hat den Renditevektor  $\mathbf{r} \in \mathbb{R}^n$  und die Kovarianzmatrix  $\mathbf{\Sigma} \in \mathbb{R}^{n \times n}$  (symmetrisch, positiv semidefinit).

**Gewichtungsvektor:**  $\mathbf{w} \in \mathbb{R}^n$  mit  $\mathbf{w}^T \mathbf{1} = 1$ .

**Portfolio-Rendite:**  $\mu_P = \mathbf{w}^T \mathbf{r}$  (Skalarprodukt!)

**Portfolio-Risiko:**  $\sigma_P^2 = \mathbf{w}^T \mathbf{\Sigma} \mathbf{w}$  (quadratische Form!)

**Minimum-Varianz-Portfolio:**

$$\min_{\mathbf{w}} \mathbf{w}^T \mathbf{\Sigma} \mathbf{w} \quad \text{u.d.N.} \quad \mathbf{w}^T \mathbf{1} = 1$$

**Loesung (Lagrange):**

$$\mathbf{w}^* = \frac{\mathbf{\Sigma}^{-1} \mathbf{1}}{\mathbf{1}^T \mathbf{\Sigma}^{-1} \mathbf{1}}$$

**Beispiel:** 2 Anlagen mit  $\mathbf{\Sigma} = \begin{pmatrix} 0,04 & 0,01 \\ 0,01 & 0,09 \end{pmatrix}$ :  $\mathbf{w}^* \approx (0,73; 0,27)^T$ .

Markowitz' Portfoliotheorie (1952) zeigt: Diversifikation reduziert Risiko – quantifiziert durch  $\mathbf{\Sigma}$ .

## Multiplikatoreffekte:

Die Leontief-Inverse  $(\mathbf{I} - \mathbf{A})^{-1}$  lässt sich als geometrische Reihe entwickeln:

$$(\mathbf{I} - \mathbf{A})^{-1} = \mathbf{I} + \mathbf{A} + \mathbf{A}^2 + \mathbf{A}^3 + \dots = \sum_{k=0}^{\infty} \mathbf{A}^k$$

falls alle Eigenwerte von  $\mathbf{A}$  betragskleiner als 1 sind.

## Interpretation der Terme:

- **Id**: Direkte Nachfrage
- **Ad**: Vorleistungsbedarf 1. Stufe
- **A<sup>2</sup>d**: Vorleistungsbedarf 2. Stufe (indirekte Effekte)
- **A<sup>k</sup>d**: Multiplikatoreffekte  $k$ -ter Ordnung

**Output-Multiplikator** fuer Sektor  $j$ :

$$m_j = \sum_{i=1}^n [(\mathbf{I} - \mathbf{A})^{-1}]_{ij} = \text{Spaltensumme der Leontief-Inversen}$$

$m_j > 1$  bedeutet: Eine zusätzliche Einheit Endnachfrage in Sektor  $j$  erzeugt mehr als eine Einheit Gesamtproduktion.

Die Multiplikatoranalyse zeigt, wie sich ein Nachfrageschock durch die gesamte Volkswirtschaft fortpflanzt.

**Stuecklisten-Problem:** Ein Unternehmen stellt  $m$  Endprodukte aus  $n$  Rohstoffen her.

**Bedarfsmatrix:**  $\mathbf{B} \in \mathbb{R}^{n \times m}$ , wobei  $b_{ij}$  = Menge von Rohstoff  $i$  fuer eine Einheit von Produkt  $j$ .

**Produktionsvektor:**  $\mathbf{p} \in \mathbb{R}^m$  (geplante Stueckzahlen).

**Gesamtbedarf:**  $\mathbf{r} = \mathbf{B}\mathbf{p}$  (Rohstoffbedarf).

**Beispiel:** Moebelfabrik produziert Stuehle und Tische:

$$\mathbf{B} = \begin{pmatrix} 4 & 8 \\ 2 & 1 \\ 6 & 4 \end{pmatrix} \begin{array}{l} \leftarrow \text{Holz (Einheiten)} \\ \leftarrow \text{Schrauben (Packungen)} \\ \leftarrow \text{Arbeitszeit (Stunden)} \end{array}, \quad \mathbf{p} = \begin{pmatrix} 50 \\ 30 \end{pmatrix}$$

$$\mathbf{r} = \mathbf{B}\mathbf{p} = \begin{pmatrix} 4 \cdot 50 + 8 \cdot 30 \\ 2 \cdot 50 + 1 \cdot 30 \\ 6 \cdot 50 + 4 \cdot 30 \end{pmatrix} = \begin{pmatrix} 440 \\ 130 \\ 420 \end{pmatrix}$$

**Kostenvektor:** Bei Rohstoffpreisen  $\mathbf{c}$ : Gesamtkosten =  $\mathbf{c}^T \mathbf{B}\mathbf{p}$ .

---

Lineare Algebra ermoeeglicht effiziente Planung in Produktion, Logistik und Supply-Chain-Management.

## Kleinste-Quadrate-Methode

Gegeben:  $m$  Datenpunkte  $(x_i, y_i)$ . Gesucht: Gerade  $y = \beta_0 + \beta_1 x$ , die den quadratischen Fehler minimiert.

**Matrixformulierung:**  $\mathbf{X}\beta \approx \mathbf{y}$  mit

$$\mathbf{X} = \begin{pmatrix} 1 & x_1 \\ 1 & x_2 \\ \vdots & \vdots \\ 1 & x_m \end{pmatrix}, \quad \beta = \begin{pmatrix} \beta_0 \\ \beta_1 \end{pmatrix}, \quad \mathbf{y} = \begin{pmatrix} y_1 \\ y_2 \\ \vdots \\ y_m \end{pmatrix}$$

Ueberbestimmtes System ( $m > 2$ ): i. d. R. keine exakte Loesung.

**Normalgleichung:**

$$\mathbf{X}^T \mathbf{X} \beta = \mathbf{X}^T \mathbf{y} \implies \hat{\beta} = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{y}$$

**Geometrie:**  $\hat{\mathbf{y}} = \mathbf{X}\hat{\beta}$  ist die **orthogonale Projektion** von  $\mathbf{y}$  auf den Spaltenraum von  $\mathbf{X}$ .

---

Die gesamte Regressionsanalyse – von einfach bis multipel – ist lineare Algebra.

**Adjazenzmatrix:** Ein Graph mit  $n$  Knoten wird durch  $\mathbf{A} \in \{0, 1\}^{n \times n}$  dargestellt:

$$a_{ij} = \begin{cases} 1 & \text{falls Kante von } i \text{ nach } j \\ 0 & \text{sonst} \end{cases}$$

**Beispiel (Handelsbeziehungen):**

$$\mathbf{A} = \begin{pmatrix} 0 & 1 & 1 & 0 \\ 1 & 0 & 1 & 1 \\ 1 & 1 & 0 & 0 \\ 0 & 1 & 0 & 0 \end{pmatrix} \quad \text{4 Laender, 5 Handelsrouten}$$

**Matrixpotenzen und Wege:**

- $(\mathbf{A}^k)_{ij}$  = Anzahl der Wege der Laenge  $k$  von Knoten  $i$  nach  $j$
- $(\mathbf{I} + \mathbf{A} + \mathbf{A}^2 + \dots + \mathbf{A}^k)_{ij}$  = Erreichbarkeit in  $\leq k$  Schritten

**Zentralitaetsmasse:**

- **Grad-Zentralitaet:** Zeilensumme von  $\mathbf{A}$  (Anzahl Verbindungen)
- **Eigenvektorzentralitaet:** Eigenvektor zum groessten Eigenwert (Google PageRank!)

---

PageRank berechnet den dominanten Eigenvektor einer modifizierten Adjazenzmatrix des Internets.

## NumPy Grundlagen

NumPy ist die Standard-Bibliothek fuer numerische lineare Algebra in Python.

```
import numpy as np

# Vektoren
v = np.array([1, 2, 3])
w = np.array([4, -1, 2])

# Operationen
print("Summe:", v + w)           # [5, 1, 5]
print("Skalarprodukt:", np.dot(v, w)) # 8
print("Norm:", np.linalg.norm(v))    # 3.742
print("Kreuzprodukt:", np.cross(v, w)) # [7, 10, -9]

# Matrizen
A = np.array([[1, 2], [3, 4]])
B = np.array([[5, 6], [7, 8]])

print("Produkt:\n", A @ B)       # Matrixmultiplikation
print("Determinante:", np.linalg.det(A)) # -2.0
print("Inverse:\n", np.linalg.inv(A))
```

```
import numpy as np

# Eigenwerte und Eigenvektoren
A = np.array([[4, 1], [2, 3]])
eigvals, eigvecs = np.linalg.eig(A)
print("Eigenwerte:", eigvals)      # [5. 2.]
print("Eigenvektoren:\n", eigvecs)

# Lineares Gleichungssystem Ax = b
A = np.array([[1, 2, -1], [2, 5, 1], [3, 7, -2]])
b = np.array([3, 8, 7])
x = np.linalg.solve(A, b)
print("Loesung:", x)                # [13. -4.  2.]

# Probe
print("Probe:", np.allclose(A @ x, b)) # True

# Symmetrische Matrix: reelle Eigenwerte garantiert
S = np.array([[2, 1], [1, 3]])
eigvals_s, _ = np.linalg.eigh(S) # eigh fuer symmetrisch
print("Eigenwerte (sym.):", eigvals_s)

Hinweis: np.linalg.solve() ist numerisch stabiler und schneller als np.linalg.inv(A) @ b.
```

## Markov-Ketten Simulation in Python

```
import numpy as np

# Uebergangsmatrix (Zeilen = von, Spalten = nach)
P = np.array([[0.8, 0.2],
              [0.4, 0.6]])

# Simulation: Zustandsvektor ueber 20 Schritte
pi = np.array([1.0, 0.0]) # Start: sicher sonnig
for t in range(20):
    pi = pi @ P
    if t < 5 or t == 19:
        print(f"t={t+1:2d}: pi = [{pi[0]:.4f}, {pi[1]:.4f}]")

# Stationaere Verteilung (Eigenvektor zu lambda=1)
eigvals, eigvecs = np.linalg.eig(P.T)
idx = np.argmax(np.abs(eigvals - 1.0))
pi_stat = np.real(eigvecs[:, idx])
pi_stat = pi_stat / pi_stat.sum()
print("Stationaer:", pi_stat) # [0.6667, 0.3333]
```

### Ausgabe (Auszug):

```
t= 1: pi = [0.8000, 0.2000]
t= 5: pi = [0.6671, 0.3329]
t=20: pi = [0.6667, 0.3333]
```

```
import numpy as np
import matplotlib.pyplot as plt

# Einheitskreis als Ausgangspunkte
theta = np.linspace(0, 2*np.pi, 100)
circle = np.array([np.cos(theta), np.sin(theta)])

# Transformationsmatrix (Scherung + Streckung)
A = np.array([[2, 1], [0.5, 1.5]])
ellipse = A @ circle

fig, (ax1, ax2) = plt.subplots(1, 2, figsize=(10, 4))
ax1.plot(circle[0], circle[1], 'b-')
ax1.set_title('Original (Einheitskreis)')
ax1.set_aspect('equal'); ax1.grid(True)

ax2.plot(ellipse[0], ellipse[1], 'r-')
ax2.set_title(f'Transformiert (det={np.linalg.det(A):.1f})')
ax2.set_aspect('equal'); ax2.grid(True)
plt.tight_layout(); plt.show()
```

**Beobachtung:** Die Einheitskreis-zu-Ellipse-Transformation zeigt:

- Halbachsen der Ellipse = Singulärwerte von  $\mathbf{A}$
- Flächenverhältnis =  $|\det(\mathbf{A})|$

## Lineare Regression in Python

```
import numpy as np

# Beispieldaten: Werbeausgaben vs. Umsatz
x = np.array([1, 2, 3, 4, 5, 6, 7, 8])
y = np.array([2.1, 3.8, 6.2, 7.9, 10.5, 12.1, 14.3, 15.8])

# Designmatrix X = [1, x]
X = np.column_stack([np.ones_like(x), x])

# Normalengleichung:  $\beta = (X^T X)^{-1} X^T y$ 
beta = np.linalg.solve(X.T @ X, X.T @ y)
print(f"y = {beta[0]:.2f} + {beta[1]:.2f} * x")
# y = 0.14 + 2.00 * x

# Bestimmtheitsmass  $R^2$ 
y_hat = X @ beta
SS_res = np.sum((y - y_hat)**2)
SS_tot = np.sum((y - np.mean(y))**2)
R2 = 1 - SS_res / SS_tot
print(f"R^2 = {R2:.4f}") # R^2 = 0.9975

# Alternativ: np.polyfit
beta_alt = np.polyfit(x, y, 1) # [Steigung, Achsenabschnitt]
```

## Satz (Cauchy-Schwarz)

Fuer alle  $\mathbf{u}, \mathbf{v} \in \mathbb{R}^n$  gilt:

$$|\langle \mathbf{u}, \mathbf{v} \rangle| \leq \|\mathbf{u}\| \cdot \|\mathbf{v}\|$$

Gleichheit gilt genau dann, wenn  $\mathbf{u}$  und  $\mathbf{v}$  linear abhaengig sind.

**Beweis:** Falls  $\mathbf{v} = \mathbf{0}$ , gilt die Ungleichung trivial. Sei also  $\mathbf{v} \neq \mathbf{0}$ .

Betrachte fuer  $t \in \mathbb{R}$  die Funktion  $f(t) = \|\mathbf{u} + t\mathbf{v}\|^2 \geq 0$ :

$$\begin{aligned} f(t) &= \langle \mathbf{u} + t\mathbf{v}, \mathbf{u} + t\mathbf{v} \rangle \\ &= \|\mathbf{u}\|^2 + 2t\langle \mathbf{u}, \mathbf{v} \rangle + t^2 \|\mathbf{v}\|^2 \geq 0 \quad \forall t \in \mathbb{R} \end{aligned}$$

Dies ist ein quadratisches Polynom in  $t$  mit nicht-negativen Werten. Die Diskriminante muss  $\leq 0$  sein:

$$\begin{aligned} \Delta &= 4\langle \mathbf{u}, \mathbf{v} \rangle^2 - 4\|\mathbf{u}\|^2 \|\mathbf{v}\|^2 \leq 0 \\ \implies \langle \mathbf{u}, \mathbf{v} \rangle^2 &\leq \|\mathbf{u}\|^2 \|\mathbf{v}\|^2 \implies |\langle \mathbf{u}, \mathbf{v} \rangle| \leq \|\mathbf{u}\| \cdot \|\mathbf{v}\| \quad \square \end{aligned}$$

Cauchy-Schwarz ist die Grundlage der Winkelformel und der Dreiecksungleichung.

## Satz (Gabriel Cramer, 1750)

Sei  $\mathbf{A} \in \mathbb{R}^{n \times n}$  mit  $\det(\mathbf{A}) \neq 0$  und  $\mathbf{Ax} = \mathbf{b}$ . Dann gilt:

$$x_j = \frac{\det(\mathbf{A}_j)}{\det(\mathbf{A})}, \quad j = 1, \dots, n,$$

wobei  $\mathbf{A}_j$  aus  $\mathbf{A}$  durch Ersetzen der  $j$ -ten Spalte durch  $\mathbf{b}$  entsteht.

**Beispiel** ( $2 \times 2$ ):

$$\begin{cases} 3x + 2y = 7 \\ x - y = 1 \end{cases} \quad \mathbf{A} = \begin{pmatrix} 3 & 2 \\ 1 & -1 \end{pmatrix}, \quad \mathbf{b} = \begin{pmatrix} 7 \\ 1 \end{pmatrix}$$

$$\det(\mathbf{A}) = -5, \quad x = \frac{\det \begin{pmatrix} 7 & 2 \\ 1 & -1 \end{pmatrix}}{-5} = \frac{-9}{-5} = 1,8, \quad y = \frac{\det \begin{pmatrix} 3 & 7 \\ 1 & 1 \end{pmatrix}}{-5} = \frac{-4}{-5} = 0,8$$

**Probe:**  $3(1,8) + 2(0,8) = 7 \checkmark$ ,  $1,8 - 0,8 = 1 \checkmark$ .

**Komplexitaet:**  $\mathcal{O}((n+1)!)$  – daher nur fuer kleine  $n$  praktikabel. Fuer grosse Systeme: Gauss-Elimination.

Cramer's Regel ist theoretisch elegant, aber fuer  $n > 3$  numerisch dem Gauss-Verfahren unterlegen.

## Satz

Sei  $\mathbf{A} = (\mathbf{a}_1 \mid \cdots \mid \mathbf{a}_n) \in \mathbb{R}^{n \times n}$ . Dann ist  $|\det(\mathbf{A})|$  das  $n$ -dimensionale Volumen des von den Spaltenvektoren  $\mathbf{a}_1, \dots, \mathbf{a}_n$  aufgespannten **Parallelotops**.

**Herleitung fuer  $n = 2$ :**

Parallelogramm aufgespannt von  $\mathbf{a} = (a_1, a_2)^T$  und  $\mathbf{b} = (b_1, b_2)^T$ :

$$\text{Flaeche} = \|\mathbf{a}\| \cdot \|\mathbf{b}\| \cdot |\sin \theta|$$

Mit  $\sin^2 \theta = 1 - \cos^2 \theta$  und  $\cos \theta = \frac{\langle \mathbf{a}, \mathbf{b} \rangle}{\|\mathbf{a}\| \|\mathbf{b}\|}$ :

$$\begin{aligned} \text{Flaeche}^2 &= \|\mathbf{a}\|^2 \|\mathbf{b}\|^2 - \langle \mathbf{a}, \mathbf{b} \rangle^2 \\ &= (a_1^2 + a_2^2)(b_1^2 + b_2^2) - (a_1 b_1 + a_2 b_2)^2 \\ &= (a_1 b_2 - a_2 b_1)^2 = \det(\mathbf{A})^2 \end{aligned}$$

$$\implies \text{Flaeche} = |\det(\mathbf{A})| \quad \square$$

**Fuer  $n = 3$ :**  $|\det(\mathbf{A})| = |\langle \mathbf{a}, (\mathbf{b} \times \mathbf{c}) \rangle| = \text{Volumen des Spats}$ .

Diese geometrische Sicht erklart, warum  $\det(\mathbf{A}) = 0$  bedeutet: Die Vektoren sind "flach" – sie spannen kein Volumen auf.

## Definition (Konditionszahl)

Die **Konditionszahl** einer invertierbaren Matrix  $\mathbf{A}$  ist

$$\kappa(\mathbf{A}) = \|\mathbf{A}\| \cdot \|\mathbf{A}^{-1}\|$$

Sie misst, wie empfindlich die Lösung  $\mathbf{x}$  von  $\mathbf{Ax} = \mathbf{b}$  auf Störungen in  $\mathbf{b}$  oder  $\mathbf{A}$  reagiert.

**Fehlerabschaetzung:**

$$\frac{\|\Delta\mathbf{x}\|}{\|\mathbf{x}\|} \leq \kappa(\mathbf{A}) \cdot \frac{\|\Delta\mathbf{b}\|}{\|\mathbf{b}\|}$$

**Beispiel – Gut konditioniert:**

$$\mathbf{A} = \begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix} : \quad \kappa(\mathbf{A}) = 1 \quad (\text{optimal})$$

**Beispiel – Schlecht konditioniert (Hilbert-Matrix):**

$$\mathbf{H}_3 = \begin{pmatrix} 1 & \frac{1}{2} & \frac{1}{3} \\ \frac{1}{2} & \frac{1}{3} & \frac{1}{4} \\ \frac{1}{3} & \frac{1}{4} & \frac{1}{5} \end{pmatrix} : \quad \kappa(\mathbf{H}_3) \approx 524$$

Kleine Aenderungen in  $\mathbf{b}$  koennen die Loesung um den Faktor 524 verfaelschen!

Faustregel: Bei  $\kappa \approx 10^k$  verliert man ca.  $k$  Dezimalstellen Genauigkeit.

**Gleitkomma-Arithmetik:** Computer rechnen mit endlicher Genauigkeit ( $\approx 16$  Dezimalstellen bei `double`).

## Problem 1: Pivotierung

Ohne Pivotierung kann Gauss-Elimination instabil sein:

$$\begin{pmatrix} 10^{-20} & 1 \\ 1 & 1 \end{pmatrix} \mathbf{x} = \begin{pmatrix} 1 \\ 2 \end{pmatrix}$$

Division durch  $10^{-20}$  erzeugt riesige Zwischenwerte  $\Rightarrow$  Ausloesung.

**Loesung: Partielle Pivotierung** – waehle stets das betragsgroesste Pivotelement.

## Problem 2: Catastrophic Cancellation

$a - b$  fuer  $a \approx b$  verliert relative Genauigkeit:

$$1,0000001 - 1,0000000 = 0,0000001 \quad (\text{nur 1 signifikante Stelle!})$$

## Best Practices:

- Verwende `np.linalg.solve()` statt  $\mathbf{A}^{-1}\mathbf{b}$
- Pivotierung stets aktivieren (LAPACK Standard)
- Konditionszahl pruefen:  $\kappa(\mathbf{A}) > 10^{10} \Rightarrow$  Vorsicht
- Iterative Verfeinerung bei schlecht konditionierten Systemen

---

Numerische Stabilitaet ist kein Luxus – sie entscheidet ueber Zuverlaessigkeit jeder Berechnung.

## LU-Zerlegung

Jede invertierbare Matrix  $\mathbf{A}$  lässt sich (ggf. mit Zeilenvertauschung) zerlegen in

$$\mathbf{PA} = \mathbf{LU}$$

mit  $\mathbf{L}$  = untere Dreiecksmatrix ( $l_{ii} = 1$ ),  $\mathbf{U}$  = obere Dreiecksmatrix,  $\mathbf{P}$  = Permutationsmatrix.

**Vorteil:** Löse  $\mathbf{Ax} = \mathbf{b}$  in zwei Schritten:

1.  $\mathbf{Ly} = \mathbf{Pb}$  (Vorwaertseinsetzen,  $\mathcal{O}(n^2)$ )
2.  $\mathbf{Ux} = \mathbf{y}$  (Rueckwaertseinsetzen,  $\mathcal{O}(n^2)$ )

Einmalige Zerlegung:  $\mathcal{O}(n^3)$ . Danach jedes neue  $\mathbf{b}$  in  $\mathcal{O}(n^2)$  lösbar!

## Cholesky-Zerlegung (für $\mathbf{A} = \mathbf{A}^T$ positiv definit)

$$\mathbf{A} = \mathbf{LL}^T$$

Halb so viel Aufwand wie LU. Anwendung: Kovarianzmatrizen, Optimierung.

**Praxis:** `np.linalg.solve()` verwendet intern LU mit partieller Pivotierung (LAPACK `dgesv`).

LU-Zerlegung ist der industrielle Standard für das Lösen linearer Systeme in Software.

## Antike und Mittelalter:

- **ca. 200 v. Chr.:** Chinesisches Buch *Jiuzhang Suanshu* – erste systematische Lösung linearer Gleichungssysteme (Gauss-Verfahren!)
- **ca. 300:** Indische Mathematiker lösen LGS mit Eliminationsmethoden

## 17.–18. Jahrhundert:

- **Leibniz (1693):** Erste Determinanten
- **Cramer (1750):** Cramer'sche Regel
- **Gauss (1809):** Systematische Elimination, Methode der kleinsten Quadrate

## 19. Jahrhundert – Geburt der LA:

- **Cayley (1858):** Matrizenalgebra
- **Hamilton (1843):** Quaternionen (4D-Algebra)
- **Grassmann (1844):** Ausdehnungslehre (allgemeine Vektorräume)
- **Sylvester:** Praegte "Matrix" (lat. Gebärmutter)

## 20. Jahrhundert:

- **von Neumann:** Hilberträume, Quantenmechanik
- **Turing/von Neumann:** Numerische LA auf Computern
- **Strang, Golub:** Moderne numerische Methoden

---

Die lineare Algebra ist eine der ältesten und zugleich modernsten Disziplinen der Mathematik.

## Carl Friedrich Gauss (1777–1855):

- “Princeps mathematicorum” (Fuerst der Mathematiker)
- Gauss-Elimination in *Disquisitiones Arithmeticae*
- Methode der kleinsten Quadrate (Astronomie)
- Fundamentalsatz der Algebra

## Arthur Cayley (1821–1895):

- Begründer der Matrizen­theorie
- Cayley-Hamilton-Satz: Jede Matrix erfüllt ihr charakteristisches Polynom
- Verknüpfte Matrizen mit linearen Transformationen

## William Rowan Hamilton (1805–1865):

- Entdeckte Quaternionen (1843, Brougham Bridge)
- Hamiltonsche Mechanik (Physik)
- Cayley-Hamilton-Satz (mit Cayley)

### Cayley-Hamilton-Satz

Sei  $p(\lambda) = \det(\mathbf{A} - \lambda \mathbf{I})$  das charakteristische Polynom von  $\mathbf{A}$ . Dann gilt:

$$p(\mathbf{A}) = \mathbf{0}$$

Beispiel:  $\mathbf{A} = \begin{pmatrix} 1 & 2 \\ 3 & 4 \end{pmatrix}$ ,  $p(\lambda) = \lambda^2 - 5\lambda - 2$ .

$$\mathbf{A}^2 - 5\mathbf{A} - 2\mathbf{I} = \begin{pmatrix} 7 & 10 \\ 15 & 22 \end{pmatrix} - \begin{pmatrix} 5 & 10 \\ 15 & 20 \end{pmatrix} - \begin{pmatrix} 2 & 0 \\ 0 & 2 \end{pmatrix} = \mathbf{0} \checkmark$$

Der Cayley-Hamilton-Satz erlaubt die Berechnung von  $\mathbf{A}^{-1}$  ohne direkte Inversion.

**Aufgabe 1 (Vektoren):** Gegeben:  $\mathbf{a} = (2, -1, 3)^T$ ,  $\mathbf{b} = (1, 4, -2)^T$ .

- (a) Berechnen Sie  $\langle \mathbf{a}, \mathbf{b} \rangle$ ,  $\|\mathbf{a}\|$ ,  $\|\mathbf{b}\|$  und den Winkel zwischen  $\mathbf{a}$  und  $\mathbf{b}$ .
- (b) Berechnen Sie  $\mathbf{a} \times \mathbf{b}$  und verifizieren Sie die Orthogonalität.
- (c) Bestimmen Sie die Fläche des von  $\mathbf{a}$  und  $\mathbf{b}$  aufgespannten Parallelogramms.

**Loesung 1:**

- (a)  $\langle \mathbf{a}, \mathbf{b} \rangle = 2 - 4 - 6 = -8$ ,  $\|\mathbf{a}\| = \sqrt{14}$ ,  $\|\mathbf{b}\| = \sqrt{21}$ ,  $\cos \theta = \frac{-8}{\sqrt{14}\sqrt{21}} \approx -0,467$ ,  $\theta \approx 117,8$
- (b)  $\mathbf{a} \times \mathbf{b} = ((-1)(-2) - 3 \cdot 4, 3 \cdot 1 - 2(-2), 2 \cdot 4 - (-1) \cdot 1)^T = (-10, 7, 9)^T$
- (c) Fläche =  $\|\mathbf{a} \times \mathbf{b}\| = \sqrt{100 + 49 + 81} = \sqrt{230} \approx 15,17$

**Aufgabe 2 (Matrizen):** Berechnen Sie  $\mathbf{A}^2$  und  $\det(\mathbf{A})$  fuer  $\mathbf{A} = \begin{pmatrix} 1 & 2 \\ 3 & 4 \end{pmatrix}$ .

**Loesung:**  $\mathbf{A}^2 = \begin{pmatrix} 7 & 10 \\ 15 & 22 \end{pmatrix}$ ,  $\det(\mathbf{A}) = 4 - 6 = -2$ .

---

**Tipp:** Prüfen Sie Ihre Ergebnisse stets mit dem Skalarprodukt-Orthogonalitätstest.

**Aufgabe 3:** Bestimmen Sie Eigenwerte und Eigenvektoren von  $\mathbf{A} = \begin{pmatrix} 3 & 1 \\ 0 & 2 \end{pmatrix}$ .

**Loesung:**

Charakteristisches Polynom:

$$\det(\mathbf{A} - \lambda \mathbf{I}) = (3 - \lambda)(2 - \lambda) - 0 = \lambda^2 - 5\lambda + 6 = (\lambda - 2)(\lambda - 3) = 0$$

$\Rightarrow \lambda_1 = 2, \lambda_2 = 3.$

Eigenvektoren:

- $\lambda_1 = 2: \begin{pmatrix} 1 & 1 \\ 0 & 0 \end{pmatrix} \mathbf{v} = \mathbf{0} \Rightarrow \mathbf{v}_1 = t \begin{pmatrix} -1 \\ 1 \end{pmatrix}$
- $\lambda_2 = 3: \begin{pmatrix} 0 & 1 \\ 0 & -1 \end{pmatrix} \mathbf{v} = \mathbf{0} \Rightarrow \mathbf{v}_2 = s \begin{pmatrix} 1 \\ 0 \end{pmatrix}$

**Aufgabe 4:** Ist  $\mathbf{A}$  diagonalisierbar? Bestimmen Sie  $\mathbf{P}$  und  $\mathbf{D}$ .

**Loesung:** Ja, da 2 linear unabhängige Eigenvektoren existieren.

$$\mathbf{P} = \begin{pmatrix} -1 & 1 \\ 1 & 0 \end{pmatrix}, \quad \mathbf{D} = \begin{pmatrix} 2 & 0 \\ 0 & 3 \end{pmatrix}, \quad \mathbf{A} = \mathbf{PDP}^{-1}$$

Kontrolle:  $\text{Sp}(\mathbf{A}) = 5 = 2 + 3 \checkmark$ ,  $\det(\mathbf{A}) = 6 = 2 \cdot 3 \checkmark$ .

Obere Dreiecksmatrizen haben die Eigenwerte direkt auf der Diagonalen – das vereinfacht vieles.

**Aufgabe 5 (Leontief):** Zwei-Sektoren-Wirtschaft mit Technologiematrix und Endnachfrage:

$$\mathbf{A} = \begin{pmatrix} 0,1 & 0,3 \\ 0,4 & 0,2 \end{pmatrix}, \quad \mathbf{d} = \begin{pmatrix} 100 \\ 150 \end{pmatrix}$$

Berechnen Sie die Gesamtproduktion  $\mathbf{x} = (\mathbf{I} - \mathbf{A})^{-1}\mathbf{d}$ .

**Loesung:**

$$\mathbf{I} - \mathbf{A} = \begin{pmatrix} 0,9 & -0,3 \\ -0,4 & 0,8 \end{pmatrix}, \quad \det(\mathbf{I} - \mathbf{A}) = 0,72 - 0,12 = 0,6$$

$$(\mathbf{I} - \mathbf{A})^{-1} = \frac{1}{0,6} \begin{pmatrix} 0,8 & 0,3 \\ 0,4 & 0,9 \end{pmatrix} = \begin{pmatrix} 1,\bar{3} & 0,5 \\ 0,\bar{6} & 1,5 \end{pmatrix}$$

$$\mathbf{x} = \begin{pmatrix} 1,\bar{3} & 0,5 \\ 0,\bar{6} & 1,5 \end{pmatrix} \begin{pmatrix} 100 \\ 150 \end{pmatrix} = \begin{pmatrix} 208,3 \\ 291,7 \end{pmatrix}$$

**Aufgabe 6 (Markov):** Finden Sie die stationäre Verteilung von  $\mathbf{P} = \begin{pmatrix} 0,7 & 0,3 \\ 0,5 & 0,5 \end{pmatrix}$ .

**Loesung:**  $\pi_1 = \frac{5}{8} = 0,625$ ,  $\pi_2 = \frac{3}{8} = 0,375$ .

Stets Spaltensummen von  $\mathbf{A}$  prüfen ( $< 1$ ?) und  $\det(\mathbf{I} - \mathbf{A}) \neq 0$  verifizieren.

## Vektoren:

- $\langle \mathbf{u}, \mathbf{v} \rangle = \sum u_i v_i = \|\mathbf{u}\| \|\mathbf{v}\| \cos \theta$
- $\|\mathbf{v}\| = \sqrt{\langle \mathbf{v}, \mathbf{v} \rangle}$
- $|\langle \mathbf{u}, \mathbf{v} \rangle| \leq \|\mathbf{u}\| \|\mathbf{v}\|$  (Cauchy-Schwarz)
- $\|\mathbf{u} \times \mathbf{v}\| = \|\mathbf{u}\| \|\mathbf{v}\| |\sin \theta|$

## Matrizen:

- $(\mathbf{AB})^T = \mathbf{B}^T \mathbf{A}^T$
- $(\mathbf{AB})^{-1} = \mathbf{B}^{-1} \mathbf{A}^{-1}$
- $\det(\mathbf{AB}) = \det(\mathbf{A}) \det(\mathbf{B})$
- $\det(\mathbf{A}^{-1}) = 1/\det(\mathbf{A})$
- $\mathbf{A}_{2 \times 2}^{-1} = \frac{1}{ad-bc} \begin{pmatrix} d & -b \\ -c & a \end{pmatrix}$

## Eigenwerte:

- $\det(\mathbf{A} - \lambda \mathbf{I}) = 0$
- $\sum \lambda_i = \text{Sp}(\mathbf{A}), \prod \lambda_i = \det(\mathbf{A})$
- $\mathbf{A} = \mathbf{PDP}^{-1}$  (Diagonalisierung)
- $\mathbf{A}^k = \mathbf{PD}^k \mathbf{P}^{-1}$

## LGS und Rang:

- $\dim(\ker \mathbf{A}) + \text{rk}(\mathbf{A}) = n$
- Loesbar  $\Leftrightarrow \text{rk}(\mathbf{A}) = \text{rk}(\mathbf{A}|\mathbf{b})$
- Cramer:  $x_j = \det(\mathbf{A}_j) / \det(\mathbf{A})$

## Anwendungen:

- Leontief:  $\mathbf{x} = (\mathbf{I} - \mathbf{A})^{-1} \mathbf{d}$
- Markov:  $\pi = \pi \mathbf{P}$
- Portfolio:  $\sigma_P^2 = \mathbf{w}^T \boldsymbol{\Sigma} \mathbf{w}$
- Regression:  $\hat{\beta} = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{y}$

Diese Formeln bilden das Handwerkszeug fuer alle weiterfuehrenden Kurse.

## Vektoren:

- Vektorraeume und Basen
- Skalarprodukt → Winkel, Orthogonalitaet
- Norm → Laenge, Abstand
- Kreuzprodukt → Flaechе, Volumen
- Lineare (Un-)Abhaengigkeit

## Matrizen:

- Matrix als lineare Abbildung
- Multiplikation, Transponierte, Inverse
- Determinante → Volumen, Invertierbarkeit
- Rang → Dimension des Bildes
- Gauss-Elimination → LGS loesen

## Eigenwerte:

- $\mathbf{A}\mathbf{v} = \lambda\mathbf{v}$ : invariante Richtungen
- Charakteristisches Polynom
- Diagonalisierung:  $\mathbf{A} = \mathbf{P}\mathbf{D}\mathbf{P}^{-1}$
- Spektralsatz fuer symmetrische Matrizen

## Anwendungen:

- Leontief-Modell (Volkswirtschaft)
- Markov-Ketten (Stochastik)
- Portfolio-Theorie (Finanzmaerkte)
- Produktionsplanung (Operations Research)

## Schluesselformel:

$$\dim(\ker \mathbf{A}) + \text{rk}(\mathbf{A}) = n$$

---

Lineare Algebra ist die "Sprache" der angewandten Mathematik, Physik, Informatik und Wirtschaftswissenschaften.

### Vertiefungen in der linearen Algebra:

- **Singulaerwertzerlegung (SVD):**  $A = U\Sigma V^T$  – die “universelle” Matrixzerlegung
- **QR-Zerlegung:** Numerisch stabile Faktorisierung fuer LGS und Eigenwertprobleme
- **LU-Zerlegung:** Effiziente Gauss-Elimination mit Speicherung
- **Positiv definite Matrizen:** Cholesky-Zerlegung, Optimierung
- **Jordansche Normalform:** Verallgemeinerte Diagonalisierung

### Anwendungsgebiete:

- **Machine Learning:** PCA (Hauptkomponentenanalyse), Regression, neuronale Netze
- **Bildverarbeitung:** SVD fuer Kompression, Faltungsmatrizen
- **Google PageRank:** Groesste Eigenwertberechnung einer riesigen Markov-Matrix
- **Quantenmechanik:** Hermitesche Operatoren, Zustandsvektoren im Hilbertraum
- **Kryptographie:** Matrizen ueber endlichen Koerpern, Gitterbasierte Verfahren
- **Optimierung:** Lineare Programmierung (Simplex), konvexe Optimierung

**Naechstes Kapitel:** Folgen, Reihen und Grenzwerte – die Grundlage der Analysis.

---

Lineare Algebra und Analysis bilden gemeinsam das Fundament der gesamten hoeheren Mathematik.