

Lineare Algebra Woche 5

Zusammenfassung: Eigenwerte und Anwendungen

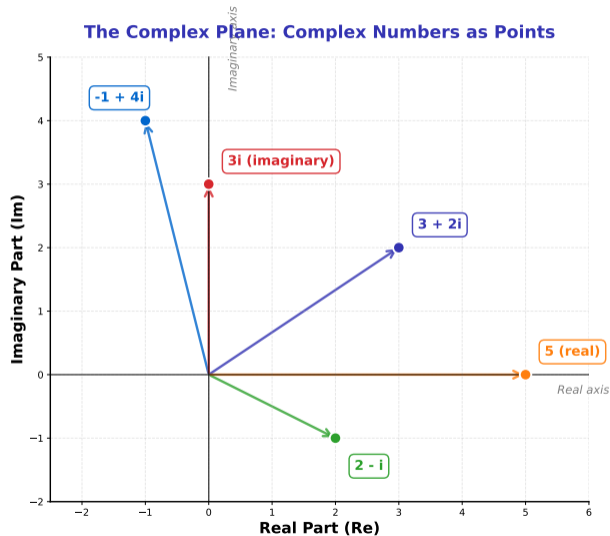
14 Kernkonzepte mit Visualisierungen und Beispielen

Teil 1: Komplexe Zahlen — Teil 2: Eigenwerte — Teil 3: Diagonalisierung — Teil 4: Anwendungen

Die komplexe Ebene (Argand-Diagramm)

- Komplexe Zahl $z = a + bi$ als Punkt (a, b) in der 2D-Ebene
- Kerneigenschaft: $i^2 = -1$ erweitert reelle Zahlen

Beispiel: $z = 3 + 2i$ liegt bei $(3, 2)$ mit Betrag $|z| = \sqrt{13} \approx 3.6$



Beispiel: $z = 3 + 4i$

- Realteil: $\operatorname{Re}(z) = 3$
- Imaginärteil: $\operatorname{Im}(z) = 4$
- Punkt in der Ebene: $(3, 4)$
- Betrag: $|z| = \sqrt{3^2 + 4^2} = \sqrt{9 + 16} = \sqrt{25} = 5$
- Konjugiert: $\bar{z} = 3 - 4i$


Merke: Der Betrag ist der Abstand zum Ursprung (Pythagoras)

Polarform und Euler-Formel

- Jede komplexe Zahl hat Polarform: $z = r \cdot e^{i\theta}$
- Euler-Formel: $e^{i\theta} = \cos \theta + i \sin \theta$

Beispiel: $z = 1 + i$ in Polarform: $r = \sqrt{2}$, $\theta = \pi/4$

Euler's Formula: Complex Exponentials on the Unit Circle



Beispiel: $e^{i\pi/4}$ berechnen

$$e^{i\pi/4} = \cos \frac{\pi}{4} + i \sin \frac{\pi}{4} = \frac{\sqrt{2}}{2} + i \frac{\sqrt{2}}{2}$$

Spezialfalle:

- $e^{i\pi} = \cos \pi + i \sin \pi = -1$ (Euler-Identitaet: $e^{i\pi} + 1 = 0$)
- $e^{i\pi/2} = \cos \frac{\pi}{2} + i \sin \frac{\pi}{2} = i$



Merke: $e^{i\theta}$ liegt auf dem Einheitskreis bei Winkel θ

Operationen in der komplexen Ebene


- Addition: Vektoraddition (komponentenweise)
- Multiplikation: Beträge multiplizieren, Winkel addieren

Division: $\frac{z_1}{z_2} = \frac{z_1 \cdot \bar{z}_2}{|z_2|^2}$ mit $\bar{z} = a - bi$


Complex Arithmetic Operations



(c) Conjugate: Reflection Across Real Axis



(d) Polar Form: $r \cdot e^{i\theta}$



Beispiel: $(1 + i)(1 - i)$ berechnen

Methode 1 (direkt):

$$(1 + i)(1 - i) = 1 - i + i - i^2 = 1 - (-1) = 2$$

Methode 2 (Polarform):

- $1 + i = \sqrt{2} \cdot e^{i\pi/4}$, $1 - i = \sqrt{2} \cdot e^{-i\pi/4}$
- Produkt: $\sqrt{2} \cdot \sqrt{2} \cdot e^{i(\pi/4 - \pi/4)} = 2 \cdot e^0 = 2$

Merke: $z \cdot \bar{z} = |z|^2$ ist immer reell und positiv


Aehnlichkeitstransformation

- $B = P^{-1}AP$ bedeutet A und B sind aehnlich
- Gleiche: Eigenwerte, Spur, Determinante, Rang


P ist Basiswechselmatrix; Diagonalisierung ist Spezialfall

Similarity Transformation: Same Linear Map, Different Bases


(a) Standard Basis: Transformation A




(b) New Basis: $\{v_1, v_2\}$



(c) Same Transformation in New Basis: B



(d) Similarity Transformation Diagram
Commutative Diagram: $B = P^{-1}AP$



Aehnliche Matrizen: Beispiel

Beispiel: $A = \begin{pmatrix} 3 & 1 \\ 1 & 3 \end{pmatrix}$ und $D = \begin{pmatrix} 4 & 0 \\ 0 & 2 \end{pmatrix}$

A und D sind *aehnlich*, denn mit $P = \begin{pmatrix} 1 & 1 \\ 1 & -1 \end{pmatrix}$ gilt:

$$D = P^{-1}AP$$

Gleiche Invarianten:

- Spur: $\text{tr}(A) = 3 + 3 = 6 = 4 + 2 = \text{tr}(D)$
- Determinante: $\det(A) = 9 - 1 = 8 = 4 \cdot 2 = \det(D)$
- Eigenwerte: $\lambda_1 = 4, \lambda_2 = 2$ (beide Matrizen!)

Merke: *Aehnliche Matrizen beschreiben dieselbe Transformation in verschiedenen Basen*



Eigenvektoren: Richtungen die nur skaliert werden

Die Grundgleichung: $A\mathbf{v} = \lambda\mathbf{v}$

- Eigenvektor \mathbf{v} : Richtung bleibt erhalten
- Eigenwert λ : Skalierungsfaktor (> 1 Streckung, < 0 Spiegelung)

Beispiel: Diagonalmatrix hat Standardbasisvektoren als Eigenvektoren

Eigenvalue Geometric Interpretation: Diagonal Matrix



Beispiel: Mit $A = \begin{pmatrix} 3 & 1 \\ 1 & 3 \end{pmatrix}$ und $\mathbf{v}_1 = \begin{pmatrix} 1 \\ 1 \end{pmatrix}$

$$A\mathbf{v}_1 = \begin{pmatrix} 3 & 1 \\ 1 & 3 \end{pmatrix} \begin{pmatrix} 1 \\ 1 \end{pmatrix} = \begin{pmatrix} 3+1 \\ 1+3 \end{pmatrix} = \begin{pmatrix} 4 \\ 4 \end{pmatrix} = 4 \begin{pmatrix} 1 \\ 1 \end{pmatrix} = 4\mathbf{v}_1$$

$\Rightarrow \mathbf{v}_1 = (1, 1)^T$ ist Eigenvektor mit Eigenwert $\lambda_1 = 4$

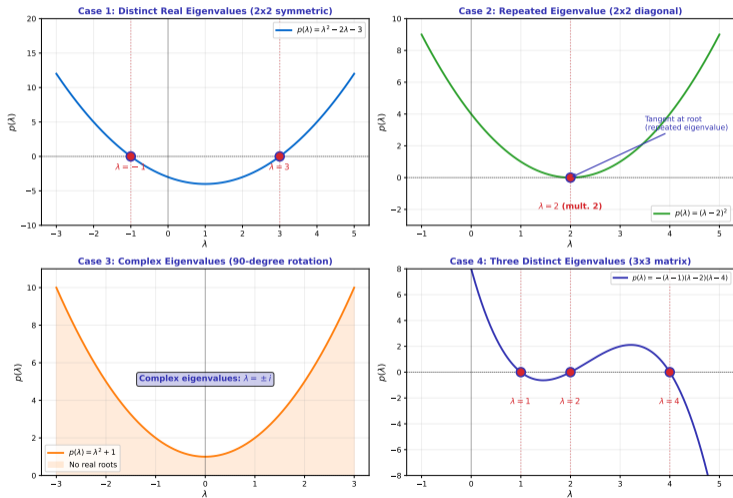
Merke: Der Vektor wird nur um Faktor 4 gestreckt, Richtung bleibt gleich

Eigenwerte berechnen

- Charakteristisches Polynom: $p(\lambda) = \det(A - \lambda I)$
- Eigenwerte sind Nullstellen von $p(\lambda) = 0$

Fuer $n \times n$ Matrix ist $p(\lambda)$ Polynom vom Grad n

Characteristic Polynomial: Roots are Eigenvalues



Beispiel: Mit $A = \begin{pmatrix} 3 & 1 \\ 1 & 3 \end{pmatrix}$

$$A - \lambda I = \begin{pmatrix} 3 - \lambda & 1 \\ 1 & 3 - \lambda \end{pmatrix}$$

$$\rho(\lambda) = \det(A - \lambda I) = (3 - \lambda)^2 - 1 = \lambda^2 - 6\lambda + 8$$

$$= (\lambda - 4)(\lambda - 2) = 0$$

⇒ Eigenwerte: $\lambda_1 = 4$, $\lambda_2 = 2$

Merke: Spur = Summe der Eigenwerte ($4 + 2 = 6$), Det = Produkt ($4 \cdot 2 = 8$)


Eigenvektoren aus Eigenwerten

- Für jeden Eigenwert λ : Löse $(A - \lambda I)\mathbf{v} = \mathbf{0}$
- Eigenraum $E_\lambda = \ker(A - \lambda I)$


Gausselimination auf $(A - \lambda I)$ anwenden

3D Eigenvektoren: Principal Axes of Transformation

Eigenvektoren (Original)



After Transformation (Scaled)



Eigenvektoren berechnen: Beispiel

Beispiel: Eigenvektor zu $\lambda_1 = 4$ fuer $A = \begin{pmatrix} 3 & 1 \\ 1 & 3 \end{pmatrix}$

$$(A - 4I)\mathbf{v} = \begin{pmatrix} -1 & 1 \\ 1 & -1 \end{pmatrix} \begin{pmatrix} v_1 \\ v_2 \end{pmatrix} = \begin{pmatrix} 0 \\ 0 \end{pmatrix}$$

Gleichung: $-v_1 + v_2 = 0 \Rightarrow v_1 = v_2$

\Rightarrow Eigenvektor: $\mathbf{v}_1 = \begin{pmatrix} 1 \\ 1 \end{pmatrix}$ (oder jedes Vielfache)

Merke: Eigenvektoren sind bis auf Skalierung eindeutig

Wann ist Diagonalisierung moeglich?

- Algebraische: Wie oft λ als Nullstelle auftritt
- Geometrische: $\dim(E_\lambda)$ — Ungleichung: $1 \leq \text{geo} \leq \text{alg}$

Diagonalisierbar \Leftrightarrow geo = alg fuer alle Eigenwerte

Algebraic vs. Geometric Multiplicity: Comparison

Case 1: Multiplicities Match

Matrix A: diagonal(5, 5, 3)

Characteristic polynomial:

$$p(\lambda) = (5 - \lambda)^2(3 - \lambda)$$

Eigenvalue $\lambda = 5$:

Algebraic mult. = 2 | Geometric mult. = 2

Eigenspace:

Dim = 2 (spans first two coordinates)

STATUS: DIAGONALIZABLE

Multiplicities match - Full set of eigenvectors

Case 3: Mixed Multiplicities (Both Match)

Matrix C: diagonal(2, 3, 3)

$$p(\lambda) = (2 - \lambda)(3 - \lambda)^2$$

Eigenvalue Analysis:

λ	Alg. Mult.	Geom. Mult.
2	1	1
3	2	2

Both eigenvalues have matching multiplicities

Diagonalizable: YES

Full set of 3 independent eigenvectors

Case 2: Multiplicities Differ

Matrix B: upper triangular

(5,1,0 on diag, 1 above diag)

Characteristic polynomial:

$$p(\lambda) = (5 - \lambda)^2(3 - \lambda)$$

Eigenvalue $\lambda = 5$:

Algebraic mult. = 2 | Geometric mult. = 1

Eigenspace:

Dim = 1 (only ONE independent eigenvector!)

STATUS: NOT DIAGONALIZABLE

DEFECTIVE MATRIX

Case 4: Severely Defective Matrix

Matrix D: Jordan block

(4 on diag, 1 above diag)

$$p(\lambda) = (4 - \lambda)^3$$

Single Eigenvalue $\lambda = 4$:

Algebraic mult. = 3 | Geometric mult. = 1

Eigenspace:

Dimension = 1

(Only 1 eigenvector for 3x3 matrix!)

SEVERELY DEFECTIVE

Needs generalized eigenvectors

Not Diagonalizable - Use Jordan Form

Beispiel: $A = \begin{pmatrix} 3 & 1 \\ 1 & 3 \end{pmatrix}$

Eigenwerte: $\lambda_1 = 4, \lambda_2 = 2$

- $\lambda_1 = 4$: alg = 1, geo = $\dim(E_4) = 1$ ✓
- $\lambda_2 = 2$: alg = 1, geo = $\dim(E_2) = 1$ ✓

\Rightarrow geo = alg fuer alle Eigenwerte \Rightarrow **diagonalisierbar**

Gegenbeispiel: $B = \begin{pmatrix} 2 & 1 \\ 0 & 2 \end{pmatrix}$ hat $\lambda = 2$ (doppelt), aber nur 1 Eigenvektor \Rightarrow nicht diagonalisierbar

Merke: Symmetrische Matrizen sind immer diagonalisierbar

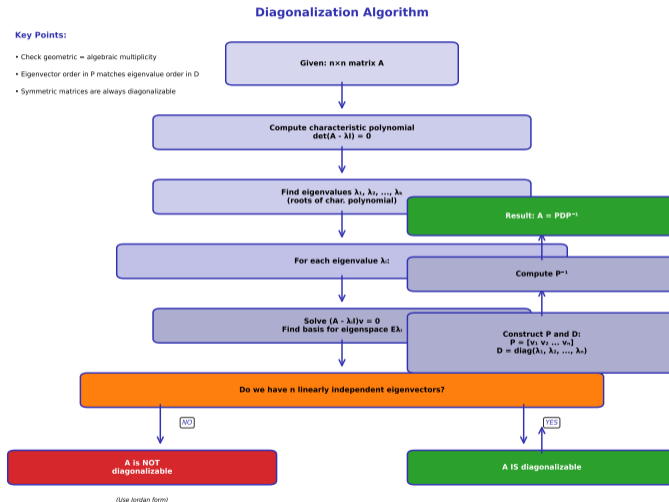
$A = PDP^{-1}$ bestimmen

- $D = \text{diag}(\lambda_1, \dots, \lambda_n)$ Eigenwerte auf Diagonale
- $P = [\mathbf{v}_1 | \dots | \mathbf{v}_n]$ Eigenvektoren als Spalten

Symmetrische Matrizen sind immer diagonalisierbar

Key Points:

- Check geometric = algebraic multiplicity
- Eigenvector order in P matches eigenvalue order in D
- Symmetric matrices are always diagonalizable



Beispiel: $A = \begin{pmatrix} 3 & 1 \\ 1 & 3 \end{pmatrix}$ diagonalisieren

Eigenwerte: $\lambda_1 = 4$, $\lambda_2 = 2$

Eigenvektoren: $\mathbf{v}_1 = \begin{pmatrix} 1 \\ 1 \end{pmatrix}$, $\mathbf{v}_2 = \begin{pmatrix} 1 \\ -1 \end{pmatrix}$

$$P = \begin{pmatrix} 1 & 1 \\ 1 & -1 \end{pmatrix}, \quad D = \begin{pmatrix} 4 & 0 \\ 0 & 2 \end{pmatrix}$$

$$A = PDP^{-1}$$


Merke: Spalten von P sind Eigenvektoren in gleicher Reihenfolge wie Eigenwerte in D

Stochastische Matrizen

- Stochastische Matrix P : Spaltensummen = 1, alle Eintraege ≥ 0
- Zustandsentwicklung: $\mathbf{x}^{(k+1)} = P \cdot \mathbf{x}^{(k)}$

Wetter: Sonnig \rightarrow Sonnig 70%, Regnerisch \rightarrow Sonnig 40%

Markov Chain: Weather Model



$$P = \begin{bmatrix} 0.7 & 0.4 \\ 0.3 & 0.6 \end{bmatrix}$$

Each arrow shows transition probability (edges sum to 1 from each state)

Beispiel: Wetter-Modell mit $P = \begin{pmatrix} 0.7 & 0.4 \\ 0.3 & 0.6 \end{pmatrix}$

Start: Heute sonnig $\Rightarrow \mathbf{x}^{(0)} = \begin{pmatrix} 1 \\ 0 \end{pmatrix}$

Nach 1 Tag: $\mathbf{x}^{(1)} = P\mathbf{x}^{(0)} = \begin{pmatrix} 0.7 & 0.4 \\ 0.3 & 0.6 \end{pmatrix} \begin{pmatrix} 1 \\ 0 \end{pmatrix} = \begin{pmatrix} 0.7 \\ 0.3 \end{pmatrix}$

\Rightarrow Morgen: 70% sonnig, 30% regnerisch


Merke: Spaltensumme = 1 garantiert, dass Wahrscheinlichkeiten erhalten bleiben

Langzeitverhalten

- Stationärer π : $P\pi = \pi$ (Eigenvektor mit $\lambda = 1$)
- Jede stochastische Matrix hat Eigenwert $\lambda = 1$

Wetter langfristig: $\pi \approx (0.57, 0.43)$ — 57% sonnig

Markov Chain Convergence to Steady State



Beispiel: Stationären Zustand finden fuer $P = \begin{pmatrix} 0.7 & 0.4 \\ 0.3 & 0.6 \end{pmatrix}$

Loese $P\boldsymbol{\pi} = \boldsymbol{\pi}$ mit $\pi_1 + \pi_2 = 1$:

$$(P - I)\boldsymbol{\pi} = \begin{pmatrix} -0.3 & 0.4 \\ 0.3 & -0.4 \end{pmatrix} \begin{pmatrix} \pi_1 \\ \pi_2 \end{pmatrix} = \mathbf{0}$$

$$\Rightarrow -0.3\pi_1 + 0.4\pi_2 = 0 \Rightarrow \pi_1 = \frac{4}{3}\pi_2$$

$$\text{Mit } \pi_1 + \pi_2 = 1: \boldsymbol{\pi} = \begin{pmatrix} 4/7 \\ 3/7 \end{pmatrix} \approx \begin{pmatrix} 0.57 \\ 0.43 \end{pmatrix}$$

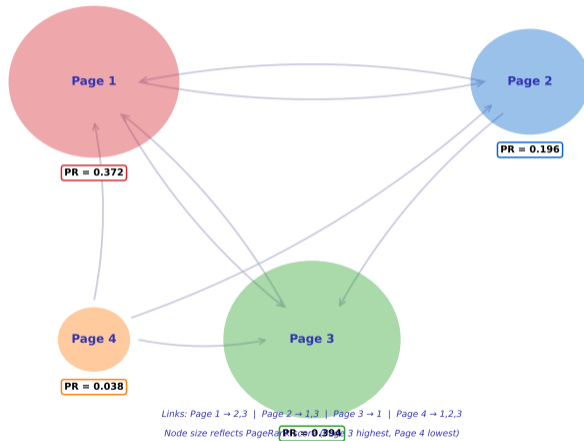
Merke: Langfristig 57% sonnig, 43% regnerisch — egal wie es heute ist

Die Kernidee: Links = Stimmen

- Link von A nach B = A "stimmt fuer" B
- Links von wichtigen Seiten zaehlen mehr

Random-Surfer-Modell: Wo landest du am haeufigsten?

PageRank Network: 4-Page Example



Beispiel: Seite A verlinkt zu B und C

A's PageRank wird gleichmaessig aufgeteilt:

- B erhaelt 50% von A's Stimme
- C erhaelt 50% von A's Stimme

Wenn A wichtig ist (hoher PageRank), sind diese Stimmen wertvoll!

$$G_{BA} = G_{CA} = 0.5$$

Merke: PageRank einer Seite = gewichtete Summe der PageRanks der verlinkenden Seiten

Das Netzwerk:

- A verlinkt zu B und C
- B verlinkt nur zu C
- C verlinkt nur zu A

Matrix: $G = \begin{pmatrix} 0 & 0 & 1 \\ 0.5 & 0 & 0 \\ 0.5 & 1 & 0 \end{pmatrix}$

PageRank:

Start: $\pi^{(0)} = (0.33, 0.33, 0.33)$

Konvergenz: $\pi = (0.4, 0.2, 0.4)$

Ergebnis: A und C je 40%, B nur 20%



C gewinnt durch Link von wichtiger Seite A

Vom Random Surfer zur Linearen Algebra

- G_{ij} = Wahrscheinlichkeit von j zu i
- PageRank = stationärer Zustand mit $G\pi = \pi$

Google 1998: Eigenwert-Idee revolutionierte Websuche

PageRank: Iteration and Convergence ($\alpha=0.85$)



Beispiel: Warum konvergiert PageRank?

Die Google-Matrix G ist stochastisch \Rightarrow hat Eigenwert $\lambda = 1$

$$G\boldsymbol{\pi} = 1 \cdot \boldsymbol{\pi}$$

Der PageRank-Vektor $\boldsymbol{\pi}$ ist der Eigenvektor zum Eigenwert 1!

Berechnung:

- Starte mit beliebigem $\boldsymbol{\pi}^{(0)}$
- Iteriere: $\boldsymbol{\pi}^{(k+1)} = G \cdot \boldsymbol{\pi}^{(k)}$
- Konvergiert zum dominanten Eigenvektor

Merke: PageRank = Markov-Kette = Eigenvektor-Problem — alles dasselbe!