

Rundungsfehler und Maschinengenauigkeit

Numerische Stabilität

Für einen Computer sind z.B. Additionen nicht assoziativ:

$$(a + b) + c \neq a + (b + c)$$

Absoluter und relativer Fehler

Es seien

x der exakte Wert und $\tilde{x}$ ein approximativer Wert.

Dann heissen

$$|\tilde{x} - x| \text{ absoluter Fehler und } \left| \frac{\tilde{x} - x}{x} \right| \text{ relativer Fehler.}$$

Relative Fehler sind aussagekräftiger.

Grösster absoluter Fehler ist die Mitte zwischen den letzten beiden Maschinenzahlen (an beiden Enden).

Rundungsprinzipien

1. Rounding to nearest
2. Rounding away from 0 (wenn genau in der Mitte zweier Maschinenzahlen)

Maschinengenauigkeit

Maximaler Relativer Rundungsfehler (= Obere Schranke)

Durch Runden einer reellen Zahl x auf eine Maschinenzahl $\tilde{x}$.

$$\left| \frac{\tilde{x} - x}{x} \right| \leq \frac{B}{2} \cdot B^{-n} \quad \begin{array}{l} n = \text{Anzahl Mantissestellen} \\ B = \text{Basis} \end{array}$$

Maschinenepsilon ϵ

$$\epsilon := \frac{B}{2} \cdot B^{-n} = \frac{1}{2} \cdot B^{1-n}$$

ϵ ist die grösste positive Maschinenzahl x , für welche auf dem Rechner gilt:
 $1 + x = 1$ für $x < \epsilon$ und $1 + x > 1$ für $x \geq \epsilon$

ϵ ist die kleinste positive Maschinenzahl x , für die auf dem Rechner gilt:
 $1 + \epsilon \neq 1$

Bsp: $M = \{\pm 0.m_1 m_2 \cdot 10^{e_1} \mid m_1, m_2, e_1 \in \{0, 1, \dots, 9\}, m_1 \neq 0\} \cup \{0\}$
 $\epsilon = 0.05$ ($= 10/2 \cdot 10^{-2}$)

$x = 0.04$ ist kleiner als ϵ , wird auf 1 gerundet:

$$1 + 0.04 = 1.04 = 0.104 \cdot 10^1, \text{ gerundet auf } 0.10 \cdot 10^1 = 1$$

$x = 0.06$ ist grösser als ϵ , wird nicht auf 1 gerundet:

$$1 + 0.06 = 1.06 = 0.106 \cdot 10^1, \text{ gerundet auf } 0.11 \cdot 10^1 = 1.1$$

Gleitpunktarithmetik

Bsp. Addition und Multiplikation mit Basis 10 und 2-stellige Mantisse
 $\epsilon = 0.05$

• Addition von $x = 1350$ und $y = 245$

Exaktes Ergebnis: $x + y = 1595$

Approximatives Ergebnis auf Maschine:

$$\begin{array}{l} 1350 \rightarrow 0.135 \cdot 10^4 \rightarrow 0.14 \cdot 10^4 \rightarrow 0.140 \cdot 10^4 \\ 245 \rightarrow 0.245 \cdot 10^3 \rightarrow 0.25 \cdot 10^3 \rightarrow 0.025 \cdot 10^4 \end{array}$$

1. Normieren 2. Runden 3. Exponenten angleichen

$$\rightarrow 0.165 \cdot 10^4 \rightarrow 0.17 \cdot 10^4 \rightarrow 1700$$

4. Addieren 5. Runden 6. Denormieren

$$\text{Relativer Fehler: } \left| \frac{1700 - 1595}{1595} \right| = \frac{105}{1595} \approx 0.066 = 6.6\%$$

• Multiplikation von $x = 1350$ und $y = 245$

Exaktes Ergebnis: $x \cdot y = 330750$

Approximatives Ergebnis auf Maschine:

$$\begin{array}{l} 1350 \rightarrow 0.135 \cdot 10^4 \rightarrow 0.14 \cdot 10^4 \text{ Multi-} \\ 245 \rightarrow 0.245 \cdot 10^3 \rightarrow 0.25 \cdot 10^3 \text{ plizieren} \\ \rightarrow 0.35 \cdot 10^6 \rightarrow 350000 \end{array}$$

4. Normieren 5. Denormieren

$$\text{Relativer Fehler: } \left| \frac{350000 - 330750}{330750} \right| = \frac{19250}{330750} \approx 0.058 = 5.8\%$$

Auslöschung

Bei Subtraktion von fast gleich grossen Zahlen, die nahe beieinander liegen, kann ein grosser relativer Fehler auftreten.

Fehlerfortpflanzung

Funktionsauswertung

Näherung für den Absoluten Fehler

$$\left| f(\tilde{x}) - f(x) \right| \approx \left| f'(x) \right| \cdot \left| \tilde{x} - x \right|$$

absoluter Fehler von $f(x)$

absoluter Fehler von x

Näherung für den Relativen Fehler

$$\frac{\left| f(\tilde{x}) - f(x) \right|}{\left| f(x) \right|} \approx \frac{\left| f'(x) \right| \cdot \left| x \right|}{\left| f(x) \right|} \cdot \frac{\left| \tilde{x} - x \right|}{\left| x \right|}$$

relativer Fehler von $f(x)$

Konditionszahl K

relativer Fehler von x

Konditionszahl K

Fehlervortpflanzung

Verhältnis relativer Outputfehler zu relativer Inputfehler.

Gibt näherungsweise an, um wieviel sich der

relative Fehler von x vergrössert bei einer Funktionsauswertung $f(x)$.

Relativer Fehler von x pflanzt sich näherungsweise mit der Konditionszahl fort.

$$K(x) := \frac{\left| f'(x) \right| \cdot \left| x \right|}{\left| f(x) \right|} \approx \frac{1}{\left| \frac{\tilde{x} - x}{x} \right|} \cdot \frac{\left| f(\tilde{x}) - f(x) \right|}{\left| f(x) \right|}$$

$$\frac{\left| f(\tilde{x}) - f(x) \right|}{\left| f(x) \right|} \approx K(x) \cdot \frac{\left| \tilde{x} - x \right|}{\left| x \right|} \quad \frac{\left| \tilde{x} - x \right|}{\left| x \right|} \approx \frac{1}{K(x)} \cdot \frac{\left| f(\tilde{x}) - f(x) \right|}{\left| f(x) \right|}$$

Mit welchem absoluten Fehler $\tilde{x}$ höchstens behaftet sein darf, damit der relative Fehler von $f(x)$ höchstens ϵ beträgt.

$$\left| \tilde{x} - x \right| \leq \frac{\epsilon}{K(x)} \cdot x \quad \epsilon = \text{Maximaler relativer Fehler}$$

Maximaler relativer Fehler = $K \cdot \epsilon$

Bsp $f(x) = x^n$

$$K(x) = \left| \frac{f'(x) \cdot x}{f(x)} \right| = \left| \frac{n \cdot x^{n-1} \cdot x}{x^n} \right| = |n|$$

Für grosse Exponenten n wird der relative Fehler stark vergrössert. Der relative hängt nicht von x ab.

x^n ist gut konditioniert für $n \in [-10, 10]$

Beispiel Sinusfunktion $f(x) = \sin(x)$ mit x im Bogenmass


$$K(x) = \left| \frac{f'(x) \cdot x}{f(x)} \right| = \left| \frac{\cos(x) \cdot x}{\sin(x)} \right|$$

$\sin(x)$ ist im Bereich $0 < x < 2\pi$

gut konditioniert für $0 < x < 2.86$

und $3.48 < x < 5.76$

sonst schlecht konditioniert



Gute / schlechte Konditionierung

$K(x) \leq 10$ heisst $f(x)$ gut konditioniert,
 $K(x) > 10$ heisst $f(x)$ schlecht konditioniert.

$K(x) < 1$ wird der relative Fehler kleiner,
 $K(x) = 1$ bleibt der relative Fehler gleich,
 $1 < K(x) \leq 10$ wird der relative Fehler leicht grösser,
 $K(x) > 10$ wird der relative Fehler stark grösser.

Ist die Kondition sehr schlecht (z.B. hat eine Polstelle), kann eine Auslöschung trotz algebraischer Umformung an dieser Stelle nicht vermieden werden. Grosse Fehler bei schlechter Konditionierung sind demzufolge unvermeidlich.

Absoluter Fehlerfaktor

Absoluter Fehler von x : pflanzt sich näherungsweise mit dem Faktor $f'(x)$ fort

$|f'(x)| < 1$ absoluter Fehler wird kleiner

$|f'(x)| > 1$ absoluter Fehler wird grösser

$$f'(x) \approx \frac{f(\tilde{x}) - f(x)}{\tilde{x} - x}$$

Fixpunktgleichung $x = F(x)$


Numerisches Bestimmung von Nullstellen

Allg. Gleichung Nullstellengleichung Fixpunktgleichung

$$\frac{3}{x} = 8 - x^2 \quad x^2 + \frac{3}{x} - 8 = 0 \quad \frac{x^3 + 3}{8} = x$$

$$x^3 - 8x + 3 = 0 \quad \sqrt[3]{8x - 3} = x$$

alle äquivalent



Fixpunktgleichung $F(x) = x$

Für eine nichtlineare Gleichung.

Zu jedem Fixpunktproblem gibt es ein äquivalentes Nullstellenproblem.

Die Funktion F bildet die Punkte x auf sich selbst ab. Einfach und effizient.

Vorgehen: Nullstellengleichung umformen nach $F(x) = x$

Fixpunktiteration

$$x_{n+1} = F(x_n): \quad x_0, x_1 = F(x_0), x_2 = F(x_1), x_{n+1} = F(x_n)$$

Konvergenz: Fixpunkt $\bar{x}$ ist anziehend wenn

$$|F'(\bar{x})| < 1 \quad x_n \text{ bzw. die Fixpunktiteration konvergiert gegen } \bar{x}, \text{ falls der Startwert } x_0 \text{ nahe genug bei } \bar{x} \text{ liegt.}$$

Differenz: Fixpunkt $\bar{x}$ ist abstossend wenn

$$|F'(\bar{x})| > 1 \quad x_n \text{ bzw. Fixpunktiteration divergiert.}$$

Kriterium: Fixpunkte mit Steigung betragsmäßig > 1 sind abstossend. D.h. nicht alle Fixpunkte können mit Fixpunktiteration bestimmt werden.

Beispiel

$$I = \mathbb{R}, \quad F(x) = \frac{x^3 + 3}{8}$$


$$x_0 = -2.5$$

$$x_1 = F(x_0) = \frac{(-2.5)^3 + 3}{8} \approx -1.578$$

$$x_2 = F(x_1) \approx \frac{(-1.578)^3 + 3}{8} \approx -0.446$$


$$x_3 = F(x_2) \approx \frac{(-0.446)^3 + 3}{8} \approx 0.375$$

usw.



def fixpunktiteration(F, x0, n):

```
x = np.zeros(n+1)
x[0] = x0
for i in range(1, n+1):
    x[i] = F(x[i-1])
return x
```



Achtung, für gerade Wurzeln: $\pm\sqrt[n]{...}$

Eine Funktion f ist differenzierbar, wenn es eine Ableitung f' gibt über einem gegebenen Intervall (Definitionsbereich). D.h. gibt es einen Grenzwert an einer Stelle x_0 im Intervall.

Banachsche Fixpunktsatz

Kriterien für die Existenz und Eindeutigkeit von Fixpunkten und deren Fehlerabschätzungen.

Voraussetzungen: (siehe Grafik unten zur Verdeutlichung)

- $F : [a, b] \rightarrow [a, b]$ (d.h. F bildet $[a, b]$ auf sich selber ab)
- Ableitung durchgehend < 1 , d.h. $\alpha < 1$

Lipschitz-Konstante α

= Betragsmäßig grösster Wert der Ableitung F'


$$\alpha = \max |F'(x_0)| \quad \text{mit } x_0 \in [a, b]$$

$$|F(x) - F(y)| \leq \alpha |x - y| \quad \text{für alle } x, y \in [a, b]$$

$$\frac{|F(x) - F(y)|}{|x - y|} \leq \alpha \quad \text{Steigung} \leq \alpha$$

Wenn $0 < \alpha < 1$ (Steigung ist durchgehend < 1), dann gilt:

- F hat genau einen Fixpunkt $\bar{x}$ in $[a, b]$
- Die Fixpunktiteration konvergiert gegen $\bar{x}$ für alle Startwerte $x_0 \in [a, b]$
- Es gelten die Fehlerabschätzungen



$$\alpha = \max_{0.5 \leq x \leq 1.5} |F'(x)| = |F'(0.5)| = \frac{1}{2\sqrt{0.5}} \approx 0.707$$

Weil $\alpha < 1$ ist gilt laut dem Banachschen Fixpunktsatz:

- $F(x) = \sqrt{x}$ besitzt genau einen Fixpunkt in $[0.5, 1.5]$,

Fehlerabschätzung

x_n = n-te Iteration, Max. absoluter Fehler (ϵ)

$$|x_n - \bar{x}| \leq \frac{\alpha^n}{1 - \alpha} |x_1 - x_0| \quad \text{a-priori Abschätzung}$$

Basierend auf den ersten beiden Iterationen x_0 und x_1

Für (sehr grobe) Abschätzung im Voraus.

$$|x_n - \bar{x}| \leq \frac{\alpha}{1 - \alpha} |x_n - x_{n-1}| \quad \text{a-posteriori Abschätzung}$$

Basierend auf den letzten beiden Iterationen x_{n-1} und x_n

Zur Überprüfung im Nachhinein.

Absoluter Fehler $|x_n - \bar{x}|$

Mindestanzahl Iterationen n

(Beispiel weiter unten)

$$n = \frac{\ln\left(\frac{\epsilon(1-\alpha)}{|x_1 - x_0|}\right)}{\ln(\alpha)} \quad \epsilon = \text{Max. absoluter Fehler}$$

def n_apriori(x0, x1, e, a):

```
return np.log(e * (1 - a) / np.abs(x1 - x0)) / np.log(a)
```

- Wie viele Iterationen n sind nötig, damit startend mit $x_0 = 1.44$ der absolute Fehler von x_n als Näherung von $\bar{x} = 1$ kleiner als 10^{-6} ist?

Abschätzung von n mit a-priori-Fehlerabschätzungsformel:

$$|x_n - \bar{x}| \leq \frac{\alpha^n}{1 - \alpha} |x_1 - x_0| = 10^{-6}$$

$$\Rightarrow \alpha^n = \frac{10^{-6} \cdot (1 - \alpha)}{|x_1 - x_0|} \Rightarrow n = \frac{\log\left(\frac{10^{-6} \cdot (1 - 0.707)}{0.24}\right)}{\log(1 - 0.707)} \approx 35$$

Newton-Verfahren

Tangentenverfahren von Newton. **Numerisches Bestimmung von Nullstellen.**


Newton-Verfahren

Vorteil gegenüber Fixpunktiteration: konvergiert fast **immer** (außer $f(x_0) = 0$ oder f schneidet Abzisse nie, Bsp. $x \cdot e^x$ für $x_0 < -1$).
Nachteil: Funktion muss differenzierbar sein.

Funktion f muss auf **Nullstellenform** gebracht werden.

$$x_{n+1} = x_n - \frac{f(x_n)}{f'(x_n)}$$

```
def newton(f, df, x0, n):
    x = np.zeros(n+1)
    x[0] = x0
    for i in range(1, n+1):
        x[i] = x[i-1] - f(x[i-1])/df(x[i-1])
    return x
```



Vereinfachtes Newton-Verfahren

Es wird immer die Startableitung $f'(x_0)$ verwendet.
Konvergiert dafür langsamer.

$$x_{n+1} = x_n - \frac{f(x_n)}{f'(x_0)}$$


```
def newton_vereinfacht(f, dfx0, x0, n):
    x = np.zeros(n+1)
    x[0] = x0
    for i in range(1, n+1):
        x[i] = x[i-1] - f(x[i-1])/dfx0
    return x
```

Konvergenzkriterium

Die Nullstelle $\bar{x}$, der Startwert und alle Iterierten $x_1, x_2, \dots$ in einem Intervall $[a, b]$ liegen, so dass:

$$\left| \frac{f(x) \cdot f''(x)}{[f'(x)]^2} \right| < 1 \quad \text{für alle } x \text{ aus } [a, b]$$


dann **konvergiert** das Newton-Verfahren **garantiert**. Konvergiert auch oft, ohne, dass diese Bedingung zutrifft!



Sekantenverfahren

Keine Ableitung nötig. Es wird der Schnittpunkt von Sekanten durch jeweils zwei Punkte $(x_0, f(x_0))$ und $(x_1, f(x_1))$ mit der x-Achse berechnet.
Benötigt zwei Startwerte.

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



```
def sekantenverfahren(f, x0, x1, n):
    x = np.array([x0, x1])
    for i in range(2, n+1):
        x0 = x[i-2]
        x1 = x[i-1]
        f1 = f(x1)
        x = np.append(x, x1 - (x1 - x0) / (f1 - f(x0)) * f1)
    return x
```

```
def sekantenverfahren_tol(f, x0, x1, tol):
    x = np.array([x0, x1])
    while f(x1 + tol) * f(x1 - tol) >= 0:
        x0 = x[i-2]
        x1 = x[i-1]
        f1 = f(x1)
        x1 = x1 - (x1 - x0) / (f1 - f(x0)) * f1
        x = np.append(x, x1)
    return x
```

Konvergenzgeschwindigkeit

Konvergenzordnung q

Mass für die Konvergenz-Geschwindigkeit.

Für einfache Nullstellen konvergiert

Vereinfachte Newton-Verfahren, linear $q = 1$ mit $c < 1$ (langsamstes)
< Sekantenverfahren $q = (1 + \sqrt{5}) / 2 = 1.618\dots$
< Newton-Verfahren, quadratisch $q = 2$ (schnellstes)

$$|x_{n+1} - \bar{x}| \leq C \cdot |x_n - \bar{x}|^q$$

$$C = \frac{1}{2} \cdot \left| \frac{f''(\bar{x})}{f'(\bar{x})} \right|$$

Falls $q = 1$ verlangt man noch $c < 1$.

Bsp:

$$\begin{array}{ccc} |x_1 - \bar{x}| & |x_2 - \bar{x}| & |x_3 - \bar{x}| \\ 0.5 & 0.05 & 0.005 \\ \cdot \frac{1}{10} & \cdot \frac{1}{10} & \cdot \frac{1}{10} \\ C = \frac{1}{10} & q = 1 \end{array}$$

$$\begin{array}{ccc} |x_1 - \bar{x}| & |x_2 - \bar{x}| & |x_3 - \bar{x}| \\ 0.25 & 0.0025 & 0.000025 \\ = 0.5^2 & = 0.05^2 & = 0.005^2 \\ \cdot \frac{1}{10} & \cdot \frac{1}{10} & \cdot \frac{1}{10} \\ C = \frac{1}{10} & q = 2 \end{array}$$

Fehlerabschätzungskriterium

Achtung: **Nur für Nullstellenform.**

Kriterium: Wenn $f(a) \cdot f(b) < 0$ (= Vorzeichenwechsel), dann besitzt f mindestens eine Nullstelle $\bar{x}$ im Intervall $[a, b]$.

Wenn $f(x_n - \epsilon) \cdot f(x_n + \epsilon) < 0$ dann gilt $|x_n - \bar{x}| < \epsilon$


```
def newton(f, df, x0, epsilon):
    x = x0
    while f(x - epsilon)*f(x + epsilon) > 0:
        x = x - f(x)/df(x)
    return x
```

```
def f(x): return x**3 - 8*x + 3
def df(x): return 3*x**2 - 8.
epsilon = 1.e-8
```

```
x0 = -2.
xquer = newton(f, df, x0, epsilon)
print('%9.8f' % xquer) # -3.00000000
```

```
x0 = 0.
xzweiquer = newton(f, df, x0, epsilon)
print('%9.8f' % xzweiquer) # 0.38196601
```

```
x0 = 2.
xdreiquer = newton(f, df, x0, epsilon)
print('%9.8f' % xdreiquer) # 2.61803400
```



Semilog und loglog

Semilog: Der Graph einer Exponentialfunktion $f(x) = c \cdot a^x$ in einem Koordinatensystem mit **logarithmischer y-Achse** ist eine Gerade.
`plt.semilog(x, y)`

Loglog: Der Graph einer Potenzfunktion $f(x) = c \cdot x^a$ ist eine Gerade, wenn man **beide Koordinatenachsen logarithmisch** wählt.
`plt.loglog(x, y)`

$$y = \ln(f(x))$$

$$x \cdot \ln(a) + \ln(c)$$

$$\text{Semilog: } \ln(c \cdot a^x) = \ln(c) + \ln(a^x) = x \cdot \ln(a) + \ln(c)$$

$$\text{Loglog: } \ln(c \cdot x^a) = \ln(c) + \ln(x^a) = \ln(x) \cdot a + \ln(c)$$

$$(i) \ 10^5 \cdot (2e)^{-\frac{x}{700}} = 10^5 \cdot \left((2e)^{-\frac{1}{700}} \right)^x \rightarrow \text{Steigung } \log((2e)^{-\frac{1}{700}})$$

$$\text{Achsenabschnitt } \log(10^5)$$

$$(ii) \ \frac{5}{2\sqrt{2x}} = 5 \cdot (2x)^{-\frac{1}{2}} = 5 \cdot 2^{-\frac{1}{2}} \cdot x^{-\frac{1}{2}} \rightarrow \text{Steigung } -\frac{1}{2}$$

$$\text{Achsenabschnitt } \log(5 \cdot 2^{-\frac{1}{2}})$$

Lineare Gleichungssysteme (LGS)

Reguläres LGS $a_{n1}x_1 + a_{n2}x_2 + a_{n3}x_3 + \dots + a_{nn}x_n = b_n$

Anzahl Gleichungen = Anzahl Unbekannte (= quadratische Matrix)

$A \cdot x = b$ ist genau dann **regulär** wenn $\det(A) \neq 0 \rightarrow$ LGS hat **genau 1 Lösung**

Vektor-Matrix Form $A \cdot x = b$

$$\begin{pmatrix} a_{11} & a_{12} & \dots & a_{1n} \\ a_{21} & a_{22} & \dots & a_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ a_{n1} & a_{n2} & \dots & a_{nn} \end{pmatrix} \cdot \begin{pmatrix} x_1 \\ x_2 \\ \vdots \\ x_n \end{pmatrix} = \begin{pmatrix} b_1 \\ b_2 \\ \vdots \\ b_n \end{pmatrix}$$

$A \in \mathbb{R}^{n \times n} \quad x \in \mathbb{R}^n \quad b \in \mathbb{R}^n$

$$\begin{array}{rcl} 20a + 10b & = & 150 \\ 50a + 30b + 20c & = & 470 \\ 200a + 150b + 100c & = & 2150 \end{array} \rightarrow \begin{pmatrix} 20 & 10 & 0 & | & 150 \\ 50 & 30 & 20 & | & 470 \\ 200 & 150 & 100 & | & 2150 \end{pmatrix}$$

Determinante einer Koeffizientenmatrix (Dreiecksmatrix):

$$\det(A) = (-1)^z \cdot a_{11} \cdot a_{22} \cdot \dots \cdot a_{nn} \quad z = \text{Anzahl Zeilentausch}$$

Eine $\det(A)$ zu berechnen ist **auffändiger**, als eine Lösung zu berechnen.

Gauss-Verfahren

Zum lösen eines LGS $Ax = b$.

Für **höchstens hundert Unbekannte** reicht das Gauss-Verfahren aus.

Für grössere LGS werden iterative Verfahren verwendet (Fixpunktiteration).

In der Numerik werden nur folgende Äquivalenzumformungen verwendet:

— **Zeilen-Subtraktion**: Einer Zeile wird ein Vielfaches einer darüberliegenden Zeile subtrahiert.

— **Zeilenvertausch**: Zwei Zeilen werden miteinander vertauscht.

= Standardisierte Vorwärtselemination

Standardisierte Vorwärtselemination

Ziel ist die Matrix auf eine **rechtsobere Dreiecksmatrix** zu bringen, so dass dann einfach **Rückwärtssubstituiert** (Rückwaertseinsetzen) werden kann.

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

a_{ij} i = Zeilen j = Spalten

1. Ist $a_{ii} = 0$: Zeilenwechsel mit erster unterhalb liegenden Zeile mit führender Variable!

$$\begin{array}{ccc} \textcircled{0} & 1 & 2 \\ 0 & 2 & 3 \\ 2 & 1 & 2 \\ 4 & 2 & 6 \end{array} \xrightarrow{Z_1 \leftrightarrow Z_2} \begin{array}{ccc} \textcircled{2} & 1 & 2 \\ 0 & 2 & 3 \\ 0 & 1 & 2 \\ 4 & 2 & 6 \end{array}$$

2. Subtrahiere jeder unterhalb liegenden Zeilen das $\frac{a_{ji}}{a_{ii}}$ -fache der aktuellen Zeile:

$$\begin{array}{ccc} \textcircled{2} & 1 & 2 \\ 0 & 2 & 3 \\ 0 & 1 & 2 \\ 4 & 2 & 6 \end{array} \xrightarrow{Z_4 - \frac{4}{2} \cdot Z_1} \begin{array}{ccc} 2 & 1 & 2 \\ 0 & 2 & 3 \\ 0 & 1 & 2 \\ 0 & 0 & 2 \end{array}$$

3. Geht zu $a_{j+1,j+1}$ und wiederhole Verfahren.

$$\begin{array}{ccc} 2 & 1 & 2 \\ 0 & \textcircled{2} & 3 \\ 0 & 1 & 2 \\ 0 & 0 & 2 \end{array} \dots$$

Problem $\rightarrow$ Numerische Fehlerfortpflanzung

In jedem Eliminationsschritt vergrößert sich der absolute Fehler um den Faktor $\left| \frac{a_{ji}}{a_{ii}} \right|$. Wünschenswert wäre $\left| \frac{a_{ji}}{a_{ii}} \right| < 1$.

Zusätzlich wird mit jedem Rückwärtseinsetzen der relative Fehler verstärkt (Runden von Gleitpunktzahlen).

Spaltenpivotisierung

Pivot = Führende Variable

Minimiert numerische **Fehler** die durch Rückwärtseinsetzen und Gleitpunktoperationen entstehen.

1. Ermittle das **betragsmäßig größte** Element in der aktuellen Spalte und vertausche mit aktueller Zeile.

2/3. Wie Standardisierte Vorwärtselemination.

$$\begin{array}{ccc} \textcircled{2} & 4 & 8 & 3 \\ 0 & 1 & 2 & 3 \\ 2 & 4 & 6 & 8 \\ 4 & 2 & 6 & 2 \end{array} \xrightarrow{Z_1 \leftrightarrow Z_2} \begin{array}{ccc} \textcircled{4} & 2 & 6 & 2 \\ 0 & 1 & 2 & 3 \\ 2 & 4 & 6 & 8 \\ 2 & 4 & 8 & 3 \end{array} \xrightarrow{Z_3 - \frac{2}{4}Z_1, Z_4 - \frac{2}{4}Z_1} \begin{array}{ccc} \textcircled{4} & 2 & 6 & 2 \\ 0 & 1 & 2 & 3 \\ 0 & 3 & 3 & 7 \\ 2 & 4 & 8 & 3 \end{array} \xrightarrow{Z_4 - \frac{2}{4}Z_1} \begin{array}{ccc} \textcircled{4} & 2 & 6 & 2 \\ 0 & \textcircled{1} & 2 & 3 \\ 0 & 3 & 3 & 7 \\ 0 & 2 & 5 & 2 \end{array} \xrightarrow{Z_3 - 3Z_2, Z_4 - 2Z_2} \begin{array}{ccc} \textcircled{4} & 2 & 6 & 2 \\ 0 & 1 & 2 & 3 \\ 0 & 0 & -1 & -1 \\ 0 & 0 & -1 & -1 \end{array} \dots$$

```
def gauss(A,b):
    # Erweiterte Koeffizientenmatrix M = (A|b)
    M = np.c_[A,b].astype(float)
    n = np.size(b)
    for j in range(n): # Spaltenindex
        # Spaltenpivotisierung
        k = np.argmax(np.abs(M[j:n,j])) + j
        if k != j:
            M[[j,k],:] = M[[k,j],:]
        # Vorwaertselimination
        for i in range(j+1, n): # Zeilenindex
            M[i,j+1:] = M[i,j+1:] - M[i,j] / M[j,j] * M[j,j+1:]
            M[i,j] = 0
        # Rueckwaertseinsetzen
        x = np.zeros(n)
        for i in range(n-1, -1, -1):
            x[i] = (M[i,n] - np.dot(M[i,0:n], x)) / M[i,i]
    return M, x
```

Dreieckszerlegung

LR-Zerlegung

Wenn eine $n \times n$ -Matrix mit dem Gauss-Algorithmus **ohne Spaltenpivotisierung** in eine rechtsobere Dreiecksmatrix gebracht werden kann. Dann gilt:

$$A = L \cdot R \quad A \cdot x = (L \cdot R) \cdot x = L \cdot (R \cdot x) = L \cdot y = b$$

R = rechtsobere Dreiecksmatrix

L = Vielfache der Zeilensubtraktionen (linksuntere Dreiecksmatrix)

Vorgehen

1. LR -Zerlegung:

2. $L \cdot y = b$ Vorwärts einsetzen:

$$\begin{array}{ccc} 2 & 1 & 0 \\ 4 & 0 & -1 \\ 2 & 3 & -1 \end{array} \xrightarrow{Z_2 - 2Z_1, Z_3 - Z_1} \begin{array}{ccc} 2 & 1 & 0 \\ 0 & -2 & -1 \\ 1 & 2 & -1 \end{array} \xrightarrow{Z_3 \leftrightarrow Z_2} \begin{array}{ccc} 2 & 1 & 0 \\ 1 & 2 & -1 \\ 0 & -2 & -1 \end{array} \xrightarrow{Z_2 - Z_1} \begin{array}{ccc} 2 & 1 & 0 \\ 0 & 1 & -2 \\ 0 & -2 & -1 \end{array} \xrightarrow{Z_3 + 2Z_2} \begin{array}{ccc} 2 & 1 & 0 \\ 0 & 1 & -2 \\ 0 & 0 & -5 \end{array}$$

$$\begin{array}{ccc} 2 & 1 & 0 \\ 0 & -2 & -1 \\ 1 & 2 & -1 \end{array} \xrightarrow{Z_3 - Z_2} \begin{array}{ccc} 2 & 1 & 0 \\ 0 & -2 & -1 \\ 1 & 0 & 0 \end{array} \xrightarrow{Z_1 - Z_3} \begin{array}{ccc} 1 & 0 & 0 \\ 0 & -2 & -1 \\ 1 & 0 & 0 \end{array} \xrightarrow{Z_1 - Z_3} \begin{array}{ccc} 0 & 0 & 0 \\ 0 & -2 & -1 \\ 1 & 0 & 0 \end{array}$$

$$\begin{array}{ccc} 2 & 1 & 0 \\ 0 & -2 & -1 \\ 1 & 0 & 0 \end{array} \xrightarrow{Z_1 - Z_3} \begin{array}{ccc} 1 & 0 & 0 \\ 0 & -2 & -1 \\ 1 & 0 & 0 \end{array} \xrightarrow{Z_1 - Z_3} \begin{array}{ccc} 0 & 0 & 0 \\ 0 & -2 & -1 \\ 1 & 0 & 0 \end{array} \xrightarrow{Z_1 - Z_3} \begin{array}{ccc} 0 & 0 & 0 \\ 0 & -2 & -1 \\ 1 & 0 & 0 \end{array}$$

PLR-Zerlegung

Wenn eine $n \times n$ -Matrix mit dem Gauss-Algorithmus **mit Spaltenpivotisierung** in eine rechtsobere Dreiecksmatrix gebracht werden kann. Dann gilt:

$$P \cdot A = L \cdot R$$

P : Permutationsmatrix (Einheitsmatrix mit Spalten in anderer Reihenfolge)

L : Achtung, Zeilentausch in L unterhalb der Diagonalen.

Vorgehen

1. PLR -Zerlegung

2. $P \cdot b$

$$\begin{array}{ccc} 2 & 1 & 0 \\ 4 & 0 & -1 \\ 2 & 3 & -1 \end{array} \xrightarrow{Z_1 \leftrightarrow Z_2} \begin{array}{ccc} 4 & 0 & -1 \\ 2 & 1 & 0 \\ 2 & 3 & -1 \end{array} \xrightarrow{Z_1 - Z_2, Z_3 - Z_2} \begin{array}{ccc} 2 & -1 & -1 \\ 2 & 1 & 0 \\ 0 & 2 & -1 \end{array} \xrightarrow{Z_1 + Z_2} \begin{array}{ccc} 4 & 0 & -1 \\ 2 & 1 & 0 \\ 0 & 2 & -1 \end{array} \xrightarrow{Z_1 - Z_2} \begin{array}{ccc} 2 & -1 & -1 \\ 2 & 1 & 0 \\ 0 & 2 & -1 \end{array} \xrightarrow{Z_1 - Z_2} \begin{array}{ccc} 0 & -2 & -2 \\ 2 & 1 & 0 \\ 0 & 2 & -1 \end{array} \xrightarrow{Z_1 + 2Z_2} \begin{array}{ccc} 0 & 0 & -2 \\ 2 & 1 & 0 \\ 0 & 2 & -1 \end{array} \xrightarrow{Z_3 - 2Z_2} \begin{array}{ccc} 0 & 0 & -2 \\ 2 & 1 & 0 \\ 0 & 0 & -3 \end{array}$$

$$\begin{array}{ccc} 2 & 1 & 0 \\ 4 & 0 & -1 \\ 2 & 3 & -1 \end{array} \xrightarrow{Z_1 \leftrightarrow Z_2} \begin{array}{ccc} 4 & 0 & -1 \\ 2 & 1 & 0 \\ 2 & 3 & -1 \end{array} \xrightarrow{Z_1 - Z_2, Z_3 - Z_2} \begin{array}{ccc} 2 & -1 & -1 \\ 2 & 1 & 0 \\ 0 & 2 & -1 \end{array} \xrightarrow{Z_1 + Z_2} \begin{array}{ccc} 4 & 0 & -1 \\ 2 & 1 & 0 \\ 0 & 2 & -1 \end{array} \xrightarrow{Z_1 - Z_2} \begin{array}{ccc} 2 & -1 & -1 \\ 2 & 1 & 0 \\ 0 & 2 & -1 \end{array} \xrightarrow{Z_1 - Z_2} \begin{array}{ccc} 0 & -2 & -2 \\ 2 & 1 & 0 \\ 0 & 2 & -1 \end{array} \xrightarrow{Z_1 + 2Z_2} \begin{array}{ccc} 0 & 0 & -2 \\ 2 & 1 & 0 \\ 0 & 2 & -1 \end{array} \xrightarrow{Z_3 - 2Z_2} \begin{array}{ccc} 0 & 0 & -2 \\ 2 & 1 & 0 \\ 0 & 0 & -3 \end{array}$$

$$\begin{array}{ccc} 2 & 1 & 0 \\ 4 & 0 & -1 \\ 2 & 3 & -1 \end{array} \xrightarrow{Z_1 \leftrightarrow Z_2} \begin{array}{ccc} 4 & 0 & -1 \\ 2 & 1 & 0 \\ 2 & 3 & -1 \end{array} \xrightarrow{Z_1 - Z_2, Z_3 - Z_2} \begin{array}{ccc} 2 & -1 & -1 \\ 2 & 1 & 0 \\ 0 & 2 & -1 \end{array} \xrightarrow{Z_1 + Z_2} \begin{array}{ccc} 4 & 0 & -1 \\ 2 & 1 & 0 \\ 0 & 2 & -1 \end{array} \xrightarrow{Z_1 - Z_2} \begin{array}{ccc} 2 & -1 & -1 \\ 2 & 1 & 0 \\ 0 & 2 & -1 \end{array} \xrightarrow{Z_1 - Z_2} \begin{array}{ccc} 0 & -2 & -2 \\ 2 & 1 & 0 \\ 0 & 2 & -1 \end{array} \xrightarrow{Z_1 + 2Z_2} \begin{array}{ccc} 0 & 0 & -2 \\ 2 & 1 & 0 \\ 0 & 2 & -1 \end{array} \xrightarrow{Z_3 - 2Z_2} \begin{array}{ccc} 0 & 0 & -2 \\ 2 & 1 & 0 \\ 0 & 0 & -3 \end{array}$$

$$\begin{array}{ccc} 2 & 1 & 0 \\ 4 & 0 & -1 \\ 2 & 3 & -1 \end{array} \xrightarrow{Z_1 \leftrightarrow Z_2} \begin{array}{ccc} 4 & 0 & -1 \\ 2 & 1 & 0 \\ 2 & 3 & -1 \end{array} \xrightarrow{Z_1 - Z_2, Z_3 - Z_2} \begin{array}{ccc} 2 & -1 & -1 \\ 2 & 1 & 0 \\ 0 & 2 & -1 \end{array} \xrightarrow{Z_1 + Z_2} \begin{array}{ccc} 4 & 0 & -1 \\ 2 & 1 & 0 \\ 0 & 2 & -1 \end{array} \xrightarrow{Z_1 - Z_2} \begin{array}{ccc} 2 & -1 & -1 \\ 2 & 1 & 0 \\ 0 & 2 & -1 \end{array} \xrightarrow{Z_1 - Z_2} \begin{array}{ccc} 0 & -2 & -2 \\ 2 & 1 & 0 \\ 0 & 2 & -1 \end{array} \xrightarrow{Z_1 + 2Z_2} \begin{array}{ccc} 0 & 0 & -2 \\ 2 & 1 & 0 \\ 0 & 2 & -1 \end{array} \xrightarrow{Z_3 - 2Z_2} \begin{array}{ccc} 0 & 0 & -2 \\ 2 & 1 & 0 \\ 0 & 0 & -3 \end{array}$$

QR-Zerlegung

$$A = Q \cdot R$$

$$R \cdot x = Q^T \cdot b \leftarrow \text{Durch Rückwärtseinsetzen lösbar}$$

Zerlegung mit Housholder-Verfahren

$$A_1 = \begin{bmatrix} 2 & 2 & -1 \\ 1 & -1 & 0 \\ 2 & 0 & 1 \end{bmatrix}$$

1. Iteration ($i=1$)

$$R = A_1 = \begin{bmatrix} 2 & 2 & -1 \\ 1 & -1 & 0 \\ 2 & 0 & 1 \end{bmatrix}, \quad a_1 = \begin{bmatrix} 2 \\ 1 \\ 2 \end{bmatrix}$$

$$v_1 = a_1 + \text{sign}(a_{11}) \cdot |a_1| \cdot e_1 = \begin{bmatrix} 2 \\ 1 \\ 2 \end{bmatrix} + (1) \cdot 3 \cdot \begin{bmatrix} 1 \\ 0 \\ 0 \end{bmatrix} = \begin{bmatrix} 5 \\ 1 \\ 2 \end{bmatrix}$$

$$u_1 = \frac{v_1}{|v_1|} = \frac{1}{\sqrt{30}} \begin{bmatrix} 5 \\ 1 \\ 2 \end{bmatrix} \quad \begin{array}{l} u \text{ ist } v \text{ normiert, d.h.} \\ u \text{ notfalls normieren: } \tilde{u} = \frac{u}{|u|} \end{array}$$

$$H_1 = I_3 - 2 \cdot u_1 \cdot u_1^T = \begin{bmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{bmatrix} - 2 \cdot \frac{1}{\sqrt{30}} \begin{bmatrix} 5 \\ 1 \\ 2 \end{bmatrix} \cdot \frac{1}{\sqrt{30}} \begin{bmatrix} 5 & 1 & 2 \end{bmatrix}$$

$$Q_1 = H_1 = \begin{bmatrix} -2/3 & -1/3 & -2/3 \\ -1/3 & 1/3 & -1/3 \\ -1/3 & -1/3 & 1/3 \end{bmatrix} \quad \text{Spiegelmatrix}$$

$$R_{\text{neu}} = Q_1 \cdot R_{\text{alt}} = \begin{bmatrix} -3 & -1 & 0 \\ 0 & -4/5 & 1/5 \\ 0 & -6/5 & 1/5 \end{bmatrix} \quad \begin{array}{l} \text{Spiegelung von } A, \\ \text{so dass } a_{1y} \text{ und } a_{1z} \\ \text{auf der x-Achse liegen.} \end{array}$$

$$Q_{\text{neu}} = Q_1^T = \begin{bmatrix} -2/3 & -1/3 & -2/3 \\ -1/3 & 1/3 & -1/3 \\ -1/3 & -1/3 & 1/3 \end{bmatrix}$$

2. (und letzte) Iteration ($i=2$)

$$A_2 = \begin{bmatrix} 0 & -1 & 0 \\ 0 & -4/5 & 1/5 \\ 0 & -6/5 & 1/5 \end{bmatrix} = \begin{bmatrix} -4/5 & 1/5 \\ -6/5 & 1/5 \end{bmatrix}, \quad a_2 = \begin{bmatrix} -4/5 \\ -6/5 \end{bmatrix}$$

... wie 1. Iteration

$$Q_2 = \begin{bmatrix} I_1 & 0 \\ 0 & H_2 \end{bmatrix} = \begin{bmatrix} 1 & 0 & 0 \\ 0 & -4/5 & -3/5 \\ 0 & -3/5 & 4/5 \end{bmatrix}$$

$$R_{\text{neu}} = Q_2 \cdot R_{\text{alt}} = \begin{bmatrix} -3 & -1 & 0 \\ 0 & 2 & -1 \\ 0 & 0 & 1 \end{bmatrix} \quad \begin{array}{l} R = Q_1 \cdot A_1 \cdot Q_2 \cdot Q_n \\ = Q_n \cdot Q_2 \cdot Q_1 \cdot A_1 \end{array}$$

$$Q_{\text{neu}} = Q_{\text{alt}} \cdot Q_2^T = \begin{bmatrix} -2/3 & 2/3 & -1/3 \\ -1/3 & -2/3 & -1/3 \\ -1/3 & -1/3 & 1/3 \end{bmatrix} \quad \begin{array}{l} Q = Q_1^T \cdot Q_2^T \cdot Q_n \\ = Q_1^{-1} \cdot Q_2^{-1} \cdot Q_n \\ = (Q_1 \cdot Q_2 \cdot Q_n)^{-1} \end{array}$$


- $n-1$ Iterationsschritte für eine $n \times n$ -Matrix
- Verfahren ergibt immer die gleiche QR-Zerlegung (QR-Zerl. ist eindeutig)
- Verfahren **kann immer durchgeführt** werden
- Benötigt doppelt so viele Punktoperationen wie für die LR-Zerlegung, kann dafür aber numerisch stabiler sein.
- Bestimmung von Eigenwerten von Matrizen.

$Q, R = \text{np.linalg.qr}(A)$
 $x = \text{np.linalg.solve}(R, Q.T @ b)$

```
def qr(A):
    n = np.shape(A)[0]
    R = np.copy(A)
    Q = np.eye(n)
    for i in np.arange(0, n-1):
        a = R[i:, i]
        e = np.zeros(n-i)
        e[0] = 1
        v = a + np.sign(a[0]) * np.linalg.norm(a) * e
        u = v / np.linalg.norm(v)
        H = np.eye(n-i) - 2 * np.outer(u, u)
        Qi = np.eye(n)
        Qi[i:n, i:n] = H
        R = Qi @ R
        Q = Q @ Qi.T
    return Q, R
```

Eigenschaften von Q

- Q ist **regulär** = besitzt eine **Inverse** (d.h. $\det(Q) \neq 0$ und Q ist eine $n \times n$ -Matrix) $Q^T \cdot Q = I_n$
- Zusätzlich ist Q eine **Orthogonalmatrix**: Die **Inverse** einer orthogonalen Matrix ist **gleichzeitig ihre Transponierte**. $Q^{-1} = Q^T$
- Die Spalten-Vektoren sind **normiert** und stehen **paarweise senkrecht**:



- Orthogonale Matrizen (= Rotationsmatrix) beschreiben **Drehungen** und **Spiegelungen** oder Kombinationen daraus. Durch Multiplikation mit einer orthogonalen Matrix, Q können Vektoren gedreht oder gespiegelt werden.


$Q = \begin{pmatrix} \cos \alpha & -\sin \alpha \\ \sin \alpha & \cos \alpha \end{pmatrix}$ ist eine Orthogonalmatrix und dreht einen Vektor um den Winkel α (relativ zum Ursprung)

- Alle Vektoren (Spalten) in einer orthogonalen Matrix stehen alle **senkrecht** zueinander (= linear unabhängige Basisvektoren).
- Orthogonale Matrizen sind gut konditioniert: $Q \cdot x$ und $Q \cdot \tilde{x}$ liegen nahe beieinander: Fehler von $Q \cdot x$ und $Q \cdot \tilde{x}$ ist gleich dem Fehler von x und $\tilde{x}$.

Housholder-Matrizen

Orthogonale Matrix, Transformationsmatrix

= **Householdertransformation**: Beschreibt eine **Spiegelung** an einer zu **v senkrechten Geraden** oder **Hyperebene** (Ebene im 3-dimensionalen Raum) durch den Ursprung:



v ist die Winkelhalbierende zwischen a und x-Achse und Normalenvektor der Spiegelgeraden oder Hyperebene.

Die Housholder-Matrizen H benutzen um eine $n \times n$ -Matrix schrittweise auf eine rechts-obere Dreiecksform zu bringen.

Zum nachrechnen muss die erste Spalte unterhalb der Diagonalen von A zu Null werden, wenn man H mit A multipliziert. Der erste Spaltenvektoren wurde so rotiert, dass alle Komponenten auf der x-Achse liegen.

$$H_1 \cdot A = \begin{pmatrix} * & * & * & * \\ 0 & & & \\ 0 & & A_2 & \\ 0 & & & \end{pmatrix}$$

Vektor- und Matrixnormen

Grössenmasse für Vektoren und Matrizen können unterschiedlich gemessen werden.

Vektornormen

$$\begin{aligned}\|x\|_1 &= |x_1| + \dots + |x_n| && \mathbf{1\text{-Norm}} \text{ (Summennorm)} \\ \|x\|_2 &= \sqrt{x_1^2 + \dots + x_n^2} && \mathbf{2\text{-Norm}} \text{ (Euklidische Norm)} \\ \|x\|_\infty &= \max\{|x_1|, \dots, |x_n|\} && \mathbf{\infty\text{-Norm}} \text{ (Maximumnorm)}\end{aligned}$$

Matrixnormen

1-Norm (Spaltensummennorm), einzelne Spalten summieren $\Downarrow$

$$\|A\|_1 = \max\{|c_{11}| + \dots + |c_{n1}|, \dots, |c_{1n}| + \dots + |c_{nn}|\}$$

2-Norm (Spektralnrm):

$$\|A\|_2 = \max\{\sqrt{|\lambda|} \mid \lambda \text{ ist Eigenwert von } A^T A\} = \sqrt{\rho(A^T A)}$$

∞ -Norm (Zeilensummennorm), einzelne Zeilen summieren $\Downarrow$

$$\|A\|_\infty = \max\{|c_{11}| + \dots + |c_{1n}|, \dots, |c_{n1}| + \dots + |c_{nn}|\}$$

```
np.linalg.norm(x, 1)
np.linalg.norm(x, 2)
np.linalg.norm(x, np.inf)
```

Eigenschaften

$$\left. \begin{aligned}\|x\| &\geq 0 \text{ und } \|x\| = 0 \iff x = 0 \\ \|\lambda x\| &= |\lambda| \cdot \|x\| \quad \lambda \text{ ist eine reelle Zahl.} \\ \|x + y\| &\leq \|x\| + \|y\| \text{ "Dreiecksungleichung"} \\ \|Ax\|_i &\leq \|A\|_i \cdot \|x\|_i \quad (i = 1, 2, \infty) \\ \|W \cdot (u + v)\| &\leq \|W\| \cdot (\|u\| + \|v\|)\end{aligned} \right\} \text{ Gilt auch für Matrizen.}$$

Fehlerrechnung und Aufwandabschätzung

Fehlerfortpflanzung und -abschätzung für **LGS**: $A\tilde{x} = \tilde{b} = b + \Delta b$

Abschätzung wenn nur Vektor b fehlerbehaftet ist: $A\tilde{x} = \tilde{b}$

Maximaler absoluter Fehler von $\tilde{x}$ (rechte Seite ist zu berechnen)

$$\|x - \tilde{x}\| \leq \|A^{-1}\| \cdot \|b - \tilde{b}\|$$

Maximaler relativer Fehler von $\tilde{x}$ (rechte Seite ist zu berechnen)

$$\frac{\|x - \tilde{x}\|}{\|x\|} \leq \|A\| \cdot \|A^{-1}\| \cdot \frac{\|b - \tilde{b}\|}{\|b\|} \quad \text{falls } \|b\| \neq 0$$

Konditionszahl der Matrix A bzgl. der verwendeten Norm.
= Faktor, mit der sich der Fehler verstärkt:

$$\text{cond}(A) = \|A\| \cdot \|A^{-1}\|$$

Schlecht konditioniert: Ist die Konditionszahl gross (>10), können sich kleine Fehler im Vektor b zu grossen Fehlern im Ergebnis x verstärken.

```
np.linalg.cond(A, np.inf)
```

Abschätzung wenn Matrix A und Vektor b fehlerbehaftet sind: $\tilde{A}\tilde{x} = \tilde{b}$

Maximaler relativer Fehler von $\tilde{x}$

$$\frac{\|x - \tilde{x}\|}{\|x\|} \leq \frac{\text{cond}(A)}{1 - \text{cond}(A) \cdot \frac{\|A - \tilde{A}\|}{\|A\|}} \cdot \left(\frac{\|A - \tilde{A}\|}{\|A\|} + \frac{\|b - \tilde{b}\|}{\|b\|} \right)$$

Weiter sei:

$$\text{cond}(A) \cdot \frac{\|A - \tilde{A}\|}{\|A\|} < 1$$

Aufwandabschätzung

Grundrechenoperationen / Floating Point Operations (Flops):

n = Anzahl Unbekannte / Matrix-Grösse

$$\text{Gauss-Elimination: } \frac{2}{3}n^3 + \frac{5}{2}n^2 - \frac{13}{6}n$$

$$\text{LR-Zerlegung: } \frac{2}{3}n^3 + \frac{7}{2}n^2 - \frac{13}{6}n$$

$$\text{QR-Zerlegung: } \frac{5}{3}n^3 + 4n^2 + \frac{7}{3}n - 7$$

QR-Zerlegung beansprucht etwas mehr als doppelt so viel Zeit wie die Gauss-Elimination bzw. die LR-Zerlegung.

Ein GHz-Prozessor kann 10^9 Flops/Sekunde ausführen.

Vergleich zu iterativen Lösungsverfahren: Vorteil: Iterativen Lösungsverfahren haben deutlich kleineren Rechenaufwand, nur n^2 statt n^3 Flops.
Nachteil: Liefert nur Näherungslösungen und manchmal keine Konvergenz.

Jacobi-Verfahren

Auch **Gesamtschrittverfahren** genannt.

Altes **iteratives Lösungsverfahren** eines LGS. Aufwand n^2 Flops.

Liefert nur Näherungslösungen und haben manchmal keine Konvergenz.

Komponenten werden gleichzeitig berechnet.

Kann parallel berechnet werden.

Idee: LGS in **Fixpunktform** bringen:

$$A \cdot x = b \rightarrow x^{k+1} = Bx^{(k)} + c = F(x^k)$$

Vorgehen:

$$A = \begin{pmatrix} a_{11} & a_{12} & a_{13} \\ a_{21} & a_{22} & a_{23} \\ a_{31} & a_{32} & a_{33} \end{pmatrix} \quad b = \begin{pmatrix} b_1 \\ b_2 \\ b_3 \end{pmatrix}$$

$$D = \begin{pmatrix} a_{11} & 0 & 0 \\ 0 & a_{22} & 0 \\ 0 & 0 & a_{33} \end{pmatrix}, L = \begin{pmatrix} 0 & 0 & 0 \\ a_{21} & 0 & 0 \\ a_{31} & a_{32} & 0 \end{pmatrix}, R = \begin{pmatrix} 0 & a_{12} & a_{13} \\ 0 & 0 & a_{23} \\ 0 & 0 & 0 \end{pmatrix}$$

Diagonalelemente von D dürfen nicht 0 sein $\rightarrow$ Zeilen tauschen!

$$\begin{aligned}x^{k+1} &= -D^{-1} \cdot (L + R) \cdot x^k + D^{-1} \cdot b \\ &= B \cdot x^k + c \\ &= F(x^k)\end{aligned}$$

x^0 = Startvektor

$$\begin{aligned}\underline{D} \cdot \underline{x}^{(k+1)} &= -\underline{L} \cdot \underline{x}^{(k)} - \underline{R} \cdot \underline{x}^{(k)} + \underline{b} \\ \underline{D} \cdot \underline{x}^{(k+1)} &= -(\underline{L} + \underline{R}) \cdot \underline{x}^{(k)} + \underline{b} \\ \underline{x}^{(k+1)} &= \underline{D}^{-1} \cdot (-(\underline{L} + \underline{R}) \cdot \underline{x}^{(k)} + \underline{b}) \\ \underline{x}^{(k+1)} &= -\underline{D}^{-1} \cdot (\underline{L} + \underline{R}) \cdot \underline{x}^{(k)} + \underline{D}^{-1} \cdot \underline{b}\end{aligned}$$

Inverse von D

a, b , oder c dürfen nicht 0 sein $\rightarrow$ Zeilen tauschen!

$$D = \begin{pmatrix} a & 0 & 0 \\ 0 & b & 0 \\ 0 & 0 & c \end{pmatrix}, \quad D^{-1} = \begin{pmatrix} \frac{1}{a} & 0 & 0 \\ 0 & \frac{1}{b} & 0 \\ 0 & 0 & \frac{1}{c} \end{pmatrix}$$

```
def jaccobi_fast(A, b, x0, k):
    d = np.diag(A); D = np.diag(d)
    LplusR = A - D
    Dinvs = 1. / d
    c = Dinvs * b
    n = np.shape(A)[0]; B = np.zeros((n, n))
    for i in range(n): B[i,i] = -Dinvs * LplusR[i,i]
    for j in range(k): x0 = B @ x0 + c
    return x0
```


Gauss-Seidel-Verfahren

Auch **Einzelschrittverfahren** genannt.

Altes iteratives Lösungsverfahren eines LGS.
Konvergiert schneller als Jacobi-Verfahren. Allerdings wird das Jacobi-Verfahren in der Praxis bevorzugt.

Komponenten werden einzeln berechnet.

Idee: LGS in **Fixpunktform** bringen:

$$\begin{aligned}x^{k+1} &= -(D+L)^{-1} \cdot R \cdot x^k + (D+L)^{-1} \cdot b \\&= B \cdot x^k + c \\&= F(x^k)\end{aligned}$$

$$\begin{aligned}\underline{D} \cdot \underline{x}^{(k+1)} &= -\underline{L} \cdot \underline{x}^{(k+1)} - \underline{R} \cdot \underline{x}^{(k)} + \underline{b} \\ \underline{D} \cdot \underline{x}^{(k+1)} + \underline{L} \cdot \underline{x}^{(k+1)} &= -\underline{R} \cdot \underline{x}^{(k)} + \underline{b} \\ (\underline{D} + \underline{L}) \cdot \underline{x}^{(k+1)} &= -\underline{R} \cdot \underline{x}^{(k)} + \underline{b} \\ \underline{x}^{(k+1)} &= (\underline{D} + \underline{L})^{-1} \cdot (-\underline{R} \cdot \underline{x}^{(k)} + \underline{b}) \\ \underline{x}^{(k+1)} &= -(\underline{D} + \underline{L})^{-1} \cdot \underline{R} \cdot \underline{x}^{(k)} + (\underline{D} + \underline{L})^{-1} \cdot \underline{b}\end{aligned}$$

```
def gauss_seidel(A, b, x0, k):
    d = np.diag(A)
    D = np.diag(d)
    R = np.triu(A) - D
    LplusD = A - R
    LplusDinv = np.linalg.inv(LplusD)
    B = -LplusDinv @ R
    c = LplusDinv @ b
    for j in range(k): x0 = B @ x0 + c
    return x0
```

Bsp. mit Unbekannter

$$A = \begin{pmatrix} 1 & \varepsilon \\ \varepsilon & -1 \end{pmatrix}, \quad b = \begin{pmatrix} 1 \\ 1 \end{pmatrix}, \quad x^{(0)} = \begin{pmatrix} 1 \\ -1 \end{pmatrix}$$

Jacobi

$$\begin{aligned}x^{(1)} &= -\begin{pmatrix} 1 & 0 \\ 0 & -1 \end{pmatrix} \cdot \begin{pmatrix} 0 & \varepsilon \\ \varepsilon & 0 \end{pmatrix} \cdot \begin{pmatrix} 1 \\ -1 \end{pmatrix} + \begin{pmatrix} 1 & 0 \\ 0 & -1 \end{pmatrix} \cdot \begin{pmatrix} 1 \\ 1 \end{pmatrix} \\ &\quad \underline{D}^{-1} \quad \underline{L+R} \quad \underline{x}^{(0)} \quad \underline{D}^{-1} \quad \underline{b} \\ &= \begin{pmatrix} \varepsilon \\ \varepsilon \end{pmatrix} + \begin{pmatrix} 1 \\ -1 \end{pmatrix} = \begin{pmatrix} \varepsilon + 1 \\ \varepsilon - 1 \end{pmatrix}\end{aligned}$$

Gauss-Seidel

$$\begin{aligned}(\underline{D} + \underline{L})^{-1} &= \begin{pmatrix} 1 & 0 \\ \varepsilon & -1 \end{pmatrix}^{-1} = \frac{1}{-1} \begin{pmatrix} -1 & 0 \\ -\varepsilon & 1 \end{pmatrix} = \begin{pmatrix} 1 & 0 \\ \varepsilon & -1 \end{pmatrix} \\ x^{(1)} &= -\begin{pmatrix} 1 & 0 \\ \varepsilon & -1 \end{pmatrix} \cdot \begin{pmatrix} 0 & \varepsilon \\ \varepsilon & 0 \end{pmatrix} \cdot \begin{pmatrix} 1 \\ -1 \end{pmatrix} + \begin{pmatrix} 1 & 0 \\ \varepsilon & -1 \end{pmatrix} \cdot \begin{pmatrix} 1 \\ 1 \end{pmatrix} \\ &\quad (\underline{D} + \underline{L})^{-1} \quad \underline{R} \quad \underline{x}^{(0)} \quad (\underline{D} + \underline{L})^{-1} \quad \underline{b} \\ &= \begin{pmatrix} \varepsilon \\ \varepsilon^2 \end{pmatrix} + \begin{pmatrix} 1 \\ \varepsilon - 1 \end{pmatrix} = \begin{pmatrix} \varepsilon + 1 \\ \varepsilon^2 + \varepsilon - 1 \end{pmatrix}\end{aligned}$$

Konvergenz (Jacobi und Gauss-Seidel)

Fixpunktiteration für ein LGS.

Fixpunktiteration

$$x^{(n+1)} = Bx^{(n)} + c = F(x^{(n)})$$

Für **Jacobi** (Gesamtschrittverfahren)

$$B = -D^{-1}(L + R) \quad c = D^{-1} \cdot b$$

Für **Gauss-Seidel** (Einzelschrittverfahren)

$$B = -(D + L)^{-1}R \quad c = (D + L)^{-1} \cdot b$$

Konvergenz gegen $\bar{x}$

1. Diagonaldominante Matrix

Falls A **diagonaldominant** ist, **konvergiert** das **Jacobi** (Gesamtschrittverfahren) und auch das **Gauss-Seidel** (Einzelschrittverfahren) für $Ax = b$.

Es gibt nicht diagonaldominante Matrizen, für die die Verfahren dennoch konvergieren. Das notwendige Kriterium für Konvergenz ist, dass der Spektralradius $\rho(B) < 1$.

Diagonaldominant, falls **eines** der **beiden** Kriterien gilt:

- In jeder **Zeile oder Spalte** ist das Diagonalelement betragsmässig grösser als die Summe der Beträge aller anderen Elemente der **Zeile oder Spalte**.

Bsp:

$$A = \begin{bmatrix} 4 & -1 & 1 \\ -2 & 5 & 1 \\ 1 & -2 & 5 \end{bmatrix} \rightarrow \begin{bmatrix} 4 > |-1| + |1| & \checkmark \\ 5 > |-2| + |1| & \checkmark \\ 5 > |1| + |-2| & \checkmark \end{bmatrix} \text{ diagonaldominant}$$

Wenn Diagonaldominanz nicht zutrifft, muss **zusätzlich Fixpunktsatz** überprüft werden:

2. Fixpunktsatz

- $\bar{x}$ anziehender Fixpunkt, falls $\|B\| < 1$
d.h. $F(x)$ besitzt **genau einen** Fixpunktvektor $\bar{x}$.
- $\bar{x}$ abstossender Fixpunkt, falls $\|B\| > 1$
d.h. $F(x)$ besitzt **genau einen** Fixpunktvektor $\bar{x}$.

B ist Ableitungsmatrix von F .

Vorgehen:

1. Ist $\bar{x}$ ein Fixpunktvektor von F ?

Es muss gelten: $B \cdot \underline{x} + \underline{c} = \underline{x}$

2. Ist $\bar{x}$ anziehend oder abstossend?

Anziehend wenn $\|B\| < 1$, sonst abstossend.

Fehlerabschätzungen

Der Abstand von $x^{(k)}$ zu x_{Fixpunkt} kann abgeschätzt werden durch:

(n) = n -te Iteration, n = Exponent

$$\|x^{(n)} - \bar{x}\| \leq \frac{\|B\|^n}{1 - \|B\|} \|x^{(1)} - x^{(0)}\| \quad \text{a-priori}$$

Basierend auf den **ersten** beiden Iterationen x_0 und x_1
Für (sehr grobe) **Abschätzung** im Voraus.



$$\|x^{(n)} - \bar{x}\| \leq \frac{\|B\|}{1 - \|B\|} \|x^{(n)} - x^{(n-1)}\| \quad \text{a-posteriori}$$

Basierend auf den **letzten** beiden Iterationen x_{n-1} und x_n
Zur **Überprüfung** im Nachhinein.

Mindestanzahl Iterationen n

$$\begin{aligned}n &= \left\lceil \log_{\|B\|} \left(\frac{\varepsilon(1 - \|B\|)}{\|x^{(1)} - x^{(0)}\|} \right) \right\rceil \\ &= \left\lceil \log \left(\frac{\varepsilon(1 - \|B\|)}{\|x^{(1)} - x^{(0)}\|} \right) \cdot \frac{1}{\log \|B\|} \right\rceil\end{aligned}$$

Komplexe Zahlen



Realteil $\operatorname{Re}(z) = x$
Imaginärteil $\operatorname{Im}(z) = y$

$$|z| = \sqrt{x^2 + y^2} = \sqrt{z \cdot \bar{z}}$$

$$i = \sqrt{-1}$$

$$i^2 = -1$$

$$i^3 = -\sqrt{-1}$$

$$i^4 = 1$$

$$i^5 = i$$

...

$$-i = e^{-i\frac{\pi}{2}} = e^{i\frac{3}{2}\pi}$$

$$i = e^{i\frac{\pi}{2}}$$

$$-1 = e^{i\pi}$$

$$1 = e^{i0}$$

$$1+i = \sqrt{2} \cdot e^{i\frac{\pi}{4}}$$

$$1-i = \sqrt{2} \cdot e^{i\frac{7}{4}\pi} = \sqrt{2} \cdot e^{-i\frac{1}{4}\pi}$$

$$-1+i = \sqrt{2} \cdot e^{i\frac{3}{4}\pi}$$

$$-1-i = \sqrt{2} \cdot e^{i\frac{5}{4}\pi} = \sqrt{2} \cdot e^{-i\frac{3}{4}\pi}$$

$$x = \sqrt{-16} = \sqrt{16 \cdot (-1)} = \sqrt{16} \cdot \sqrt{-1} = 4i$$

$$x^2 + 1 = 0 \Rightarrow x^2 = -1 \Rightarrow x = \sqrt{-1} = i$$

Darstellungsformen

Normalform (x, y)

$$z = x + yi \leftrightarrow P_z = (x, y)$$

$$\bar{z} = x - yi \quad \text{Konjugation}$$

Polarform (r, φ)

Trigonometrische Form

$$z = r(\cos \varphi + \sin \varphi \cdot i) = r \cdot \cos \varphi + r \cdot \sin \varphi \cdot i$$

Exponentialform

$$z = r \cdot e^{i\varphi} = r(\cos \varphi + \sin \varphi \cdot i) \quad e^{i\pi} = -1$$

$$z^n = (r \cdot e^{i\varphi})^n = r^n \cdot e^{in\varphi} = r^n(\cos(n\varphi) + \sin(n\varphi) \cdot i)$$

Normalform (x, y) → Polarform (r, φ)

$$z = (x + yi) \quad r = |z| = \sqrt{x^2 + y^2} \quad \varphi = \begin{cases} \arctan\left(\frac{y}{x}\right) & \text{für } x \geq 0 \\ \arctan\left(\frac{y}{x}\right) + \pi & \text{für } x < 0 \end{cases}$$

Polarform (r, φ) → Normalform (x, y)

$$z = r \cdot e^{i\varphi} \quad x = r \cdot \cos \varphi \quad y = r \cdot \sin \varphi$$

Grundrechenoperationen

Multiplizieren

Am einfachsten in **Exponentialform**

Multiplizieren heisst: Ihre **Winkel addieren** und ihre **Längen multiplizieren**.
Multiplizieren mit $(0 + i)$ rotiert $\frac{1}{2}\pi$.

$$z_1 \cdot z_2 = (x_1 + yi) \cdot (x_2 + yi) = \begin{pmatrix} x_1 & -y_1 \\ y_1 & x_1 \end{pmatrix} \cdot \begin{pmatrix} x_2 \\ y_2 \end{pmatrix}$$

$$= (x_1 x_2 - y_1 y_2) + (x_1 y_2 + x_2 y_1) i$$

$$z_1 \cdot z_2 = r_1 e^{i\varphi_1} \cdot r_2 e^{i\varphi_2} = r_1 r_2 e^{i(\varphi_1 + \varphi_2)}$$

Addieren / Subtrahieren

Immer in der **Normalform**

$$z_1 \pm z_2 = (x_1 + yi) \pm (x_2 + yi) = (x_1 \pm x_2) + (y_1 \pm y_2) i$$

Dividieren

Am einfachsten in **Exponentialform**

$$\frac{z_1}{z_2} = \frac{z_1 \cdot \bar{z}_2}{z_2 \cdot \bar{z}_2} = \frac{(x_1 + yi) \cdot (x_2 - yi)}{(x_2 + yi) \cdot (x_2 - yi)}$$

$$= \frac{(x_1 x_2 + y_1 y_2) + (x_2 y_1 - x_1 y_2) i}{x_2^2 + y_2^2}$$

$$\frac{z_1}{z_2} = \frac{r_1 e^{i\varphi_1}}{r_2 e^{i\varphi_2}} = \frac{r_1}{r_2} e^{i(\varphi_1 - \varphi_2)}$$

Potenzieren

Immer in der **Exponentialform**

$$z^n = (r \cdot e^{i\varphi})^n = r^n \cdot e^{in\varphi} = r^n(\cos(n\varphi) + \sin(n\varphi) \cdot i)$$

$$z_1^n = z_2^n \Rightarrow z_1 = \sqrt[n]{z_2} = z_2^{\frac{1}{n}}$$


Radizieren (Wurzelziehen)

Eine komplexe Zahl mit Exponentialform $w = r \cdot e^{i\varphi}$ besitzt n Wurzeln.
 n = Wurzelexponent, z_k = Wurzel von w , k = Laufindex

$$z_k = r_k \cdot e^{i\varphi_k}$$

$$r_k = \sqrt[n]{r} \quad \varphi_k = \frac{\varphi + k \cdot 2\pi}{n} \quad k = 0, 1, 2, \dots, n-1$$

Die n Wurzeln $z_0, z_1, \dots, z_{n-1}$ bilden in der komplexen Zahlenebene die Ecken einer regelmässigen n -Ecks:



Polynomialgleichung

Ein **Polynom n -ten Grades mit komplexen Koeffizienten** besitzt **genau n Lösungen**. (Im Gegensatz ein Polynom mit reellen Koeffizienten besitzt höchstens n reelle Lösungen).

Ein Polynom vom Grad n lässt sich wie im Reellen in Linearfaktoren zerlegen mit den Nullstellen z_i , Bsp:

$$P(z) = z^3 - z^2 + 4z - 4 \rightarrow P(z) = (z-1)(z-2i)(z+2i)$$

Das Polynom hat also eine reelle Nullstelle $z_1 = 1$ und zwei zueinander komplex konjugiert Nullstellen $z_2 = 2i$ und $z_3 = -2i$

$$p(z) = z^2 + \underbrace{(-4+i)}_b \cdot z + \underbrace{(5-5i)}_c \quad a = (1+0i) = 1$$


Mitternachtsformel

$$z_{1,2} = \frac{-b \pm \sqrt{b^2 - 4ac}}{2a}$$

Kreisteilungsgleichung (kein Modulstoff)

$z^n = 1$ hat in $\mathbb{C}$ genau n Lösungen.

$$z_k = e^{ik\frac{2\pi}{n}} \quad k = 0, 1, 2, \dots, n-1$$



Eigenwerte und Eigenvektoren

Definition $A \cdot x = \lambda \cdot x$

Vektor x (in $\mathbb{R}^2$) liegt nach der Transformation auf der selben Linie.

A eine reelle $n \times n$ -Matrix, A = Transformationsmatrix
 x ein reeller oder komplexer n -Vektor verschieden vom Nullvektor 0 , n -gleichungen
 λ eine reelle oder komplexe Zahl.
Dann heisst x Eigenvektor zum Eigenwert λ von A ,
wenn gilt: $A \cdot x = \lambda \cdot x$ $Ax = x \rightarrow x = \text{Fixvektor}, \lambda = 1$

Spur / trace (engl)

Die Summe der Eigenwerte ist gleich der Summe der Diagonalelemente von A .

$$\text{tr} A = a_{11} + a_{22} + \dots + a_{nn} = \lambda_1 + \lambda_2 + \dots + \lambda_n$$

Charakteristisches Polynoms $p(\lambda)$

Zum bestimmen von Eigenwerten $\lambda_i \rightarrow 1. \text{ Schritt}$

Die Eigenwerte von A sind die Nullstellen des Polynoms.

A hat genau n Eigenwerte, von denen manche mehrfach vorliegen können.

$$\lambda \text{ ist Eigenwert von } A \iff \det(A - \lambda I_n) = 0$$

$$A = \begin{pmatrix} a_{11} & a_{12} \\ a_{21} & a_{22} \end{pmatrix} \Rightarrow A - \lambda I_2 = \begin{pmatrix} a_{11} - \lambda & a_{12} \\ a_{21} & a_{22} - \lambda \end{pmatrix}$$

$$p(\lambda) = \det(A - \lambda I_n) = (a_{11} - \lambda)(a_{22} - \lambda) - a_{12}a_{21}$$

Für eine Dreiecksmatrix gilt:

$$A - \lambda I_n = \begin{pmatrix} a_{11} - \lambda & a_{12} & \dots & a_{1n} \\ 0 & a_{22} - \lambda & \dots & a_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & a_{nn} - \lambda \end{pmatrix}$$

$$p(\lambda) = \det(A - \lambda I_n) = (a_{11} - \lambda)(a_{22} - \lambda) \dots (a_{nn} - \lambda)$$

Die Diagonalelemente einer Dreiecksmatrix A sind deren Eigenwerte.

Falls A eine Diagonalmatrix ist, dann sind die Diagonalelemente zusätzlich die Nullstellen des charakteristischen Polynoms = Algebraische Vielfachheit

Bsp. Eigenwerte λ_i bestimmen:

$$A = \begin{pmatrix} 2 & 5 \\ -1 & -2 \end{pmatrix}$$

$$p(\lambda) = \det \begin{pmatrix} 2 - \lambda & 5 \\ -1 & -2 - \lambda \end{pmatrix} = (2 - \lambda)(-2 - \lambda) - 5 \cdot (-1) \\ = \lambda^2 + 1 = 0 \Rightarrow \lambda_{1,2} = \pm \sqrt{-1} = \pm i$$

Algebraische Vielfachheit von $\lambda = 2$

Eigenraum

Zum bestimmen von Eigenvektoren $\rightarrow 2. \text{ Schritt}$

= Lineare Hülle (Erzeugnis, Spann) der Eigenvektoren zu einem bestimmten Eigenwert.

Der Eigenraum des Eigenwertes λ ist die Lösungsmenge des homogenen linearen Gleichungssystems:

$$(A - \lambda I_n)x = 0$$

Eine nicht-triviale (d.h. von 0 verschiedene) Lösung, wenn:

$$\text{Rg}(A - \lambda I_n) < n$$

- Rang = Anzahl linear unabhängiger Zeilenvektoren (führende Variablen)
- Die Dimension eines Vektorraumes ist die Anzahl seiner Basisvektoren.
- Basis(-vektoren) = linear unabhängige Vektoren eines Vektorraumes, mit denen sich jeder andere Vektor des Raumes eindeutig als Linearkombination darstellen lässt.

Bsp. Eigenvektor zu $\lambda_1 = +i$

Homogene Gleichungssystem lösen:

$$(A - \lambda_1 I_2)x = \begin{pmatrix} 2 - i & 5 \\ -1 & -2 - i \end{pmatrix} \begin{pmatrix} x_1 \\ x_2 \end{pmatrix} = \begin{pmatrix} 0 \\ 0 \end{pmatrix}$$

bzw.

$$(A - \lambda_1 I_2 | 0) = \left(\begin{array}{cc|c} 2-i & 5 & 0 \\ -1 & -2-i & 0 \end{array} \right)$$

Varia

Die Eigenvektoren einer symmetrischen Matrix sind parallel (orthogonal) zueinander.

Geometrische Vielfachheit von λ

= Dimension des Eigenraumes eines EW λ .

= Anzahl der linear unabhängigen Eigenvektoren zum Eigenwert λ .

$$n - \text{Rg}(A - \lambda I_n)$$

n = Anzahl Spalten/Zeilen einer $n \times n$ Matrix.

Rg = Anzahl Führende Variablen

Geometrische und algebraische Vielfachheit eines Eigenwertes müssen nicht gleich sein. Aber: **geom. Vielfachheit** $\leq$ **algeb. Vielfachheit**

Algebraische Vielfachheit von λ

Die Vielfachheit (Anzahl gleiche Nullstellen), mit der λ als Nullstelle des charakteristischen Polynoms von A auftritt. Bsp:

$$p(\lambda) = \lambda \cdot (\lambda - 3) \cdot (\lambda - 3)$$

$\lambda = 0$ ist EW von A mit algebr. Vielfachheit 1

$\lambda = 3$ ist EW von A mit algebr. Vielfachheit 2 (doppelte Nullstelle)

Spektrum $\sigma(A)$

Menge aller Eigenwerte von A .

Eigenschaften

Hat man zwei Eigenvektoren x und y zum selben Eigenwert λ einer Matrix A , so ist $x + y$ und auch jedes Vielfache von x ebenfalls ein Eigenvektor zum Eigenwert λ :

$$A(x + y) = Ax + Ay = \lambda x + \lambda y = \lambda(x + y)$$

$$A(\mu x) = \mu Ax = \mu \lambda x = \lambda \mu x$$

$$\det A = \lambda_1 \cdot \lambda_2 \cdot \dots \cdot \lambda_n$$

Für reelle quadratische Matrix A gilt:

- Zu jedem Eigenwert von A gibt es unendlich viele Eigenvektoren
- Der Eigenraum zu einem Eigenwert λ von A besteht genau aus allen Eigenvektoren zum Eigenwert λ und dem Nullvektor.

Spektralradius und Spektralnorm (2-Norm)

Spektralradius: Betragsmässig grösster Eigenwert von A .

$$\rho(A) = \max\{|\lambda| \mid \lambda \text{ ist ein Eigenwert von } A \in \mathbb{R}^{n \times n}\}$$

Spektralnorm (2-Norm):

$$\|A\|_2 = \sqrt{\rho(A^T A)}$$

Vektoriteration / von-Mises-Iteration (engl. Power Method)

Verfahren zum berechnen des Spektralradius und den zugehörigen betragsmässig grössten Eigenvektor einer diagonalisierbaren Matrix A .

Not as numerically stable as SVD (Principal Component Analysis).

$$v^{(k+1)} = \frac{Av^{(k)}}{\|Av^{(k)}\|_2} \quad \text{Eigenvektor}$$

$$\lambda^{(k+1)} = \frac{(v^{(k)})^T Av^{(k)}}{(v^{(k)})^T v^{(k)}} \quad \text{Eigenwert}$$

```
def vektoriteration(A, v, n, norm=2):  
    for i in range(n):  
        ew = v.T @ A @ v / (v.T @ v)  
        v = A @ v / np.linalg.norm(A @ v, norm)  
    return v, ew
```

Eigenwerte und Eigenvektoren bestimmen

1. Eigenwerte: $\det(A - \lambda I_n) = 0$
2. Eigenvektoren: $(A - \lambda I_n)x = 0$

$$A = \begin{pmatrix} a & 1 & 0 \\ 1 & a & 2 \\ 0 & 2 & a \end{pmatrix} \quad \det(A - \lambda I_n) = 0$$

$$\Rightarrow \begin{vmatrix} a-\lambda & 1 & 0 \\ 1 & a-\lambda & 2 \\ 0 & 2 & a-\lambda \end{vmatrix} = (a-\lambda)^3 - 5(a-\lambda) = 0$$

$$\Rightarrow \underbrace{(a-\lambda)}_{=0 \text{ Fall 1}} \underbrace{((a-\lambda)^2 - 5)}_{=0 \text{ Fall 2}} = 0$$

$$\text{Fall 1: } \lambda_1 = a$$

$$\text{Fall 2: } \underbrace{(a-\lambda)^2}_{15} - 5 = \underbrace{(a-\lambda)}_{15} \underbrace{(a-\lambda)}_{15} - 5 = 0$$

$$\lambda_{2,3} = a \pm \sqrt{5}$$

$$\underline{\underline{d(A) = \{a, a + \sqrt{5}, a - \sqrt{5}\}}}$$

$$A = \begin{pmatrix} 2 & 5 \\ -1 & -2 \end{pmatrix}$$

$$1. \text{ EW: } \det(A - \lambda I) = 0$$

$$(2-\lambda)(-2-\lambda) - (-1)5 = 0 \Rightarrow \lambda^2 + 1 = 0$$

$$\Rightarrow \lambda^2 = -1 \Rightarrow \lambda = \pm \sqrt{-1} \Rightarrow \underline{\lambda_{1,2} = \pm i}$$

$$2. \text{ EV: } (A - \lambda I)x = 0$$

$$\bullet \lambda_1 = -i$$

$$\left(\begin{array}{cc|c} 2+i & 5 & 0 \\ -1 & -2+i & 0 \end{array} \right) \xrightarrow{z_2 - \frac{z_1}{2+i} z_1} \left(\begin{array}{cc|c} 2+i & 5 & 0 \\ 0 & -2+i-5 \frac{-1}{2+i} & 0 \end{array} \right)$$

$$= \left(\begin{array}{cc|c} 2+i & 5 & 0 \\ 0 & 0 & 0 \end{array} \right) \quad x_2 = a$$

$$x_1 = \frac{-5a}{2+i} = \frac{-5a}{2+i} \frac{(2-i)}{(2-i)} = \frac{-10a + 5ai}{4 - 2i + 2i - i^2} = \frac{-10a + 5ai}{5} = a(-2+i)$$

$$z_1 = \underline{\underline{a \begin{pmatrix} -2+i \\ 1 \end{pmatrix}}} \quad \text{EV zum EW } \lambda = -i$$

Eigenraum λ_1 mit $a \in \mathbb{C}$

$$\bullet \lambda_2 = i \quad (\text{Ähnliches Verfahren})$$

$$z_2 = \underline{\underline{a \begin{pmatrix} -2-i \\ 1 \end{pmatrix}}} = \underline{\underline{z_1^*}} \quad \text{EV zum EW } \lambda = i$$

$$\text{Geometrische Vielfachheit: } n - \text{Rg}(A - \lambda I) = 2 - 1 = 1$$

$$\text{Eigenraum } E_{\lambda_1} = \{z \mid z = a \begin{pmatrix} -2+i \\ 1 \end{pmatrix}, a \in \mathbb{C}\}$$

Numerische Berechnung von λ und Eigenvektoren

Diagonalisierbarkeit / Ähnliche Matrizen

$$B = T^{-1}AT, \quad A = TBT^{-1} = T^{-1}BT$$

B und A heißen zueinander ähnlich. T ist eine reguläre Matrix. Die Gleichung ist von Rechts nach Links zu lesen.

Ist B zusätzlich eine **Diagonalmatrix**, so ist A **diagonalisierbar**, d.h. A lässt sich mittels eines **Basiswechsels** (also der Konjugation mit einer regulären Matrix T) in eine Diagonalmatrix B transformieren, d.h. B ist A in der **neuen Basis**. B ist **eindeutig bestimmbar** (die Werte ändern sich nicht bei anderen T). T hingegen ist nicht eindeutig.

Eigenwerte und Eigenvektoren

1. B und A sind **zueinander ähnlich**:

B und A haben **dieselben Eigenwerte**

(inkl. gleiche algebraischen und geometrischen Vielfachheit)

Ist B eine **Dreiecksmatrix**:

Diagonalelemente von B sind EW von A . (Siehe Matrix unten)

2. x ist EV zum EW λ von $B \rightarrow Tx$ ist EV zum EW λ von A

$$Bx = \lambda x \rightarrow ATx = \lambda Tx$$

3. A ist **diagonalisierbar** / B ist eine **Diagonalmatrix**:

– **Diagonalelemente von B sind EW von A .**

– Die **Spalten von T** sind linear unabhängige **EV von A** zu den **EW von B** .

$$\begin{matrix} B & T^{-1} & T \\ \begin{pmatrix} 1 & 0 \\ 0 & 3 \end{pmatrix} & = \begin{pmatrix} 5 & 9 \\ 2 & 4 \end{pmatrix} \cdot A \cdot \begin{pmatrix} 2 & -4.5 \\ -1 & 2.5 \end{pmatrix} \end{matrix}$$

A ist diagonalisierbar (weil B eine Diagonalmatrix ist), somit:

Eigenwerte von A : $\lambda_1 = 1, \lambda_2 = 3$

Eigenvektoren von A : $v_1 = (2, -1)$ zum λ_1 und $v_2 = (-4.5, 2.5)$ zum λ_2

Matrix T bestimmen

$$A = \begin{pmatrix} 5 & -2 \\ -2 & 2 \end{pmatrix} \text{ hat EW } \lambda_1 = 6, \lambda_2 = 1 \text{ und zugehörige EV } x_1 = \begin{pmatrix} 2 \\ 1 \end{pmatrix}, x_2 = \begin{pmatrix} -1 \\ -2 \end{pmatrix}.$$

A ist **diagonalisierbar**, somit gilt $D = T^{-1}AT$ mit

$$D = \begin{pmatrix} \lambda_1 & 0 \\ 0 & \lambda_2 \end{pmatrix} = \begin{pmatrix} 6 & 0 \\ 0 & 1 \end{pmatrix}, \quad T = \begin{pmatrix} x_1 & x_2 \end{pmatrix} = \begin{pmatrix} 2 & -1 \\ 1 & -2 \end{pmatrix}$$

$$D = \text{np.linalg.inv}(T) @ A @ T$$

QR-Verfahren

Numerische **Berechnung des betragsmässig grössten EW (domanter EW)** und **zugehörigen EV**. Ziel: Rechtsober Dreiecksmatrix A.

Diagonalelemente von $A^{(k)}$ sind dann genau die **EW von A**.

$$A_{i+1} = R_i \cdot Q_i \quad \text{wobei} \quad A_i = Q_i \cdot R_i$$

```
def qr_eigen(A, n):
    for i in range(n):
        Q, R = np.linalg.qr(A)
        A = R @ Q
    return A
```

Initialisierung

Schritt

Ausserdem gilt:

$$\begin{aligned} A^{(0)} &= A & A^{(k+1)} &= R^{(k)} \cdot Q^{(k)} & A^{(k)} &= Q^{(k)} \cdot R^{(k)} \\ P^{(0)} &= I_n & P^{(k+1)} &= P^{(k)} \cdot Q^{(k)} & A^{(k+1)} &= (Q^{(k)})^T \cdot A^{(k)} \cdot Q^{(k)} \\ & & & & Q^{-1} &= Q^T \end{aligned}$$

$A^{(k)}$ konvergiert gegen eine reelle Matrix.

$$A^{(\infty)} = \begin{bmatrix} \text{Reelle Eigenwerte} & & \\ & \text{Komplexe Eigenwerte} & \\ & & \ddots \end{bmatrix}$$

«Perfekte» obere Dreiecksmatrix:

Wenn **alle EW von A betragsmässig verschieden** sind $\rightarrow$ keine 2 x 2 Blöcke.
Bsp. Verfahren liefert keine Dreiecksmatrix:

$$A = \begin{pmatrix} -0.1072 & -2.5543 & -0.6586 \\ 2.3955 & 1.1072 & -0.2575 \\ 0 & 0 & 1 \end{pmatrix}$$

$$p(\lambda) = (-0.1072 - \lambda)(1.1072 - \lambda) - (-2.5543)(2.3955) \approx \lambda^2 - 1\lambda + 6$$

$$\lambda_{1,2} = 0.5 \pm 2.3979i \quad \lambda_3 = a_{33} = 1$$

Wenn **A eine symmetrische Matrix (Diagonalmatrix)** ist ($A^T = A$),
dann sind alle EW reell und die **Spalten der Matrix P zugehörige EV** von A
der Länge 1. Matrix P ist normiert.

Singuläre Matrix: $\det(A) = 0$, non-invertible

Regulär Matrix: $\det(A) \neq 0$, invertable

Inverse Matrix A^{-1}

Eine Inverse **existiert nur** wenn $\det(A) \neq 0$
und nur für **quadratische** Matrizen.

$$A \cdot A^{-1} = A^{-1} \cdot A = I_n$$

Für 2x2-Matrizen

$$A^{-1} = \frac{1}{\det(A)} \begin{pmatrix} d & -b \\ -c & a \end{pmatrix} = \frac{1}{ad-bc} \begin{pmatrix} d & -b \\ -c & a \end{pmatrix} \quad \begin{pmatrix} a & b \\ c & d \end{pmatrix}$$

Für $n \times n$ -Matrizen

$$\begin{pmatrix} \frac{1}{2} & 0 & -1 \\ 1 & -1 & 0 \\ -7 & 3 & 3 \end{pmatrix} \begin{pmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{pmatrix} \xrightarrow{\text{Auf erweiterte ZSF bringen}} \begin{pmatrix} 1 & 0 & 0 & -\frac{1}{2} & 0 & 0 \\ 0 & 1 & 0 & 0 & -1 & 0 \\ 0 & 0 & 1 & 0 & 0 & 1 \end{pmatrix}$$

$$A^{-1} = \begin{pmatrix} -\frac{1}{2} & 0 & 0 \\ 0 & -1 & 0 \\ 0 & 0 & 1 \end{pmatrix} = -\frac{1}{5} \begin{pmatrix} 6 & 6 & 2 \\ 6 & 11 & 2 \\ 8 & 3 & 1 \end{pmatrix}$$

Inverse einer Diagonalmatrix = Kehrwerte der Diagonalelemente

$$D = \begin{pmatrix} a & 0 & 0 \\ 0 & b & 0 \\ 0 & 0 & c \end{pmatrix}, \quad D^{-1} = \begin{pmatrix} \frac{1}{a} & 0 & 0 \\ 0 & \frac{1}{b} & 0 \\ 0 & 0 & \frac{1}{c} \end{pmatrix}$$

Eigenschaften einer Dreiecksmatrix (obere oder untere)

- Die Determinante ist das Produkt ihrer Hauptdiagonalelemente.
- Die Eigenwerte sind die Elemente der Hauptdiagonalen.

Determinante

Koeffizientenmatrix (Dreiecksmatrix)

Determinante ist gleich dem **Produkt der Hauptdiagonalelemente**:


$$\begin{vmatrix} 4 & 8 & 0 & -2 \\ 0 & 1 & 1 & 4 \\ 0 & 0 & 12 & 1 \\ 0 & 0 & 0 & -3 \end{vmatrix} = (-1)^z \cdot 4 \cdot 1 \cdot 12 \cdot (-3)$$

$$\det(A) = (-1)^z \cdot a_{11} \cdot a_{22} \cdot \dots \cdot a_{nn} \quad z = \text{Anzahl Zeilentausch}$$

3-reihige Determinante berechnen

$[\vec{a} \quad \vec{b} \quad \vec{c}]$ (Spatprodukt / Regel von Sarrus)

Der Betrag der Determinante einer 3x3 Matrix A
(Spatprodukt) ist gleich dem **Volumen** des Spats.



$$[\vec{a} \quad \vec{b} \quad \vec{c}] = \begin{vmatrix} a_x & b_x & c_x \\ a_y & b_y & c_y \\ a_z & b_z & c_z \end{vmatrix} = a_x b_y c_z + a_z b_x c_y + a_y b_z c_x - a_z b_y c_x - a_x b_z c_y - a_y b_x c_z$$

$$= a_x(b_y c_z - b_z c_y) + a_y(b_z c_x - b_x c_z) + a_z(b_x c_y - b_y c_x)$$

n-reihige Determinante

Vorzeichenfaktor wird nach
der Schachbrettregel bestimmt

+	-	+	-
-	+	-	+
+	-	+	-
-	+	-	+

Bei jedem **Zeilen- oder Spaltenwechsel** ändert sich das **Vorzeichen** der Determinante.

Bsp:

3. Zeile - 4 (2. Zeile)

Entwicklung nach der 4. Spalte

$$\begin{vmatrix} 2 & 1 & 3 & 0 \\ 4 & 0 & 2 & 1 \\ 1 & 3 & -1 & 4 \\ -1 & 3 & 2 & 0 \end{vmatrix} = \begin{vmatrix} 2 & 1 & 3 \\ 4 & 0 & 2 \\ -15 & 3 & -9 \end{vmatrix} \begin{vmatrix} 2 & 1 & 3 \\ -15 & 3 & -9 \end{vmatrix} = \begin{vmatrix} 2 & 1 & 3 \\ -15 & 3 & -9 \end{vmatrix} = \begin{vmatrix} 2 & 1 & 3 \\ -15 & 3 & -9 \end{vmatrix}$$

2. Zeile + 1. Zeile und

3. Zeile - 3(1. Zeile)

Entwicklung nach der 2. Spalte

$$= -3 \begin{vmatrix} 2 & 1 & 3 \\ 7 & 0 & 6 \\ -7 & 0 & -7 \end{vmatrix} = -3 \begin{vmatrix} 7 & 6 \\ -7 & -7 \end{vmatrix} = 3 \cdot (-7) \begin{vmatrix} 7 & 6 \\ 1 & 1 \end{vmatrix} = -21(7-6) = -21$$

$$A = \begin{pmatrix} 1 & 2 & -3 & 5 \\ 0 & 12 & 0 & 1 \\ 1 & 0 & -1 & 2 \\ -1 & 2 & 2 & 1 \end{pmatrix} \quad \det(A) = 12 \cdot \det(A_{22}) + \det(A_{24})$$

$$= 12 \begin{vmatrix} 1 & -3 & 5 \\ 1 & -1 & 2 \\ -1 & 2 & 1 \end{vmatrix} + \begin{vmatrix} 1 & 2 & -3 \\ 1 & 0 & -1 \\ -1 & 2 & 2 \end{vmatrix}$$