

4. Setze $x^{(k+1)} = x^{(k)} + \sigma_k s^{(k)}$.

Es gilt folgender Konvergenzsatz.

Satz 6.2.2 Sei $F : \mathbb{R}^n \rightarrow \mathbb{R}^n$ stetig differenzierbar und $x^{(0)} \in \mathbb{R}^n$ beliebig. Ist $F'(x)$ invertierbar für alle x in der Niveaumenge

$$N_f(x^{(0)}) := \{y : f(y) \leq f(x^{(0)})\}, \quad f(x) = \|F(x)\|_2^2$$

und ist $N_f(x^{(0)})$ kompakt (also beschränkt und abgeschlossen), dann terminiert Algorithmus 5 mit Startpunkt $x^{(0)}$ entweder endlich oder erzeugt eine Folge $(x^{(k)}) \subset N_f(x^{(0)})$, für die gilt:

- i) $(x^{(k)})$ konvergiert gegen eine Lösung \bar{x} von (6.1).
- ii) Es gibt $l \geq 0$ mit $\sigma_k = 1$ für alle $k \geq l$. Das Verfahren geht also in das lokale Newton-Verfahren über und konvergiert superlinear bzw. quadratisch gegen \bar{x} .

Kapitel 7

Numerische Behandlung von Anfangswertproblemen gewöhnlicher Differentialgleichungen

7.1 Einführung

Viele Anwendungen aus Naturwissenschaft, Technik und Wirtschaft führen auf Anfangswertprobleme für gewöhnliche Differentialgleichungen.

Anfangswertproblem: Gegeben sei eine Funktion $f : [a, b] \times \mathbb{R}^n \rightarrow \mathbb{R}^n$ und ein Anfangswert $y_0 \in \mathbb{R}^n$. Gesucht ist eine Funktion $y : [a, b] \rightarrow \mathbb{R}^n$, deren Ableitung y' eine *gewöhnlichen Differentialgleichung* der Form

$$y'(t) = f(t, y(t)), \quad t \in [a, b]$$

erfüllt und die zudem der *Anfangsbedingung*

$$y(a) = y_0$$

genügt. Also kurz

$$\begin{array}{ll} (7.1) & y'(t) = f(t, y(t)), \quad t \in [a, b] \\ (7.2) & \text{(AWP)} \quad y(a) = y_0 \end{array}$$

In vielen Fällen bezeichnet t die Zeit, was die Bezeichnung Anfangswertproblem rechtfertigt.

Anwendungen: Bewegungsgleichungen (z.B. Fahrdynamik, Planetenbewegung), Reaktionskinetik, Schaltkreissimulation, etc.

Grundlegend für die Existenz und Eindeutigkeit einer Lösung von (AWP) ist der folgende

Satz 7.1.1 (Existenz- und Eindeigkeitssatz)

$f : [a, b] \times \mathbb{R}^n \rightarrow \mathbb{R}^n$ sei stetig. Ferner gebe es eine feste Zahl $L > 0$ mit

$$\|f(t, y) - f(t, z)\| \leq L\|y - z\| \quad \text{für alle } t \in [a, b] \text{ und } y, z \in \mathbb{R}^n \quad (\text{Lipschitz-Bedingung}).$$

Dann gilt:

a) (Picard/Lindelöf) Zu jedem $y_0 \in \mathbb{R}^n$ besitzt (AWP) genau eine Lösung $y \in C^1([a, b]; \mathbb{R}^n)$.

b) Sind y, z Lösungen zu den Anfangswerten $y(a) = y_0$ bzw. $z(a) = z_0$, dann gilt

$$(7.3) \quad \|y(t) - z(t)\| \leq e^{L(t-a)}\|y_0 - z_0\| \quad \forall t \in [a, b].$$

Für einen Beweis siehe z.B. Heuser [Heu89] oder Walter [Wa86]. Teil b) ist eine Folge des Lemmas von Gronwall.

Bemerkung: Teil b) besagt, dass die Lösung *stetig* vom Anfangswert y_0 abhängt.

7.1.1 Grundkonzept numerischer Verfahren

Zur numerischen Lösung von (AWP) zerlegen wir das Intervall $[a, b]$ in Teilintervalle:

$$t_j = a + jh, \quad j = 0, 1, \dots, N, \quad h = \frac{b-a}{N}.$$

Durch Integration von (AWP) erhält man mit der Abkürzung $y_j = y(t_j)$

$$(7.4) \quad y_{j+1} = y_j + \int_{t_j}^{t_{j+1}} y'(t) dt = y_j + \int_{t_j}^{t_{j+1}} f(t, y(t)) dt.$$

Das Integral rechts kann nicht exakt berechnet werden, da $y(t)$ unbekannt ist. Wir approximieren daher das Integral durch interpolatorische Quadratur und erhalten hieraus einen numerischen Algorithmus zur Berechnungen von Näherungen

$$u_j \approx y(t_j), \quad j = 1, \dots, N, \quad u_0 = y_0.$$

Den Fehler

$$e_j = y(t_j) - u_j$$

bezeichnet man als *Diskretisierungsfehler*.

7.1.2 Einige wichtige Verfahren

Approximiert man das Integral in (7.4) durch die Rechtecksregel, wobei wir das linke Intervallende als Stützpunkt verwenden, also

$$\int_{t_j}^{t_{j+1}} f(t, y(t)) dt \approx hf(t_j, y_j),$$

dann erhalten wir das

Explizite Euler-Verfahren:

$$(7.5) \quad \begin{aligned} u_0 &:= y_0 \\ u_{j+1} &:= u_j + hf(t_j, u_j), \quad j = 0, \dots, N-1. \end{aligned}$$

Verwenden wir zur Approximation des Integrals die Rechtecksregel mit dem rechten Randpunkt t_{j+1} als Stützstelle, dann erhalten wir das

Implizite Euler-Verfahren:

$$(7.6) \quad \begin{aligned} u_0 &:= y_0 \\ u_{j+1} &:= u_j + hf(t_{j+1}, u_{j+1}), \quad j = 0, \dots, N-1. \end{aligned}$$

Hierbei ist zu beachten, dass für jedes j die Gleichung nach u_{j+1} aufgelöst werden muss.

Approximiert man das Integral in (7.4) durch die Trapezregel, dann erhält man

$$u_{j+1} = u_j + \frac{h}{2} (f(t_j, u_j) + f(t_{j+1}, u_{j+1})).$$

Die rechte Seite hängt von u_{j+1} ab, das Verfahren ist also implizit. Ersetzt man rechts u_{j+1} durch den expliziten Euler-Schritt $u_{j+1} = u_j + hf(t_j, u_j)$, dann ergibt sich das

Verfahren von Heun, erstes Runge-Kutta-Verfahren 2. Ordnung: (Heun, 1900)

$$u_0 = y_0, \quad u_{j+1} = u_j + \frac{h}{2} (f(t_j, u_j) + f(t_{j+1}, u_j + hf(t_j, u_j))), \quad j = 0, \dots, N-1.$$

Das Verfahren kann auch geschrieben werden als

$$u_{j+1} = u_j + \frac{h}{2} (k_1 + k_2)$$

mit $k_1 = f(t_j, u_j)$, $k_2 = f(t_{j+1}, u_j + hk_1)$.

Approximieren wir das Integral durch die Mittelpunktsregel und $u_{j+1/2}$ durch den Euler-Schritt $u_j + h/2f(t_j, u_j)$, dann ergibt sich das

Modifizierte Euler-Verfahren, zweites Runge-Kutta-Verfahren 2. Ordnung: (Runge, 1895)

$$u_0 = y_0, \quad u_{j+1} = u_j + hf(t_j + h/2, u_j + h/2f(t_j, u_j)), \quad j = 0, \dots, N - 1.$$

Das Verfahren kann auch geschrieben werden als

$$u_{j+1} = u_j + hk_2$$

mit $k_1 = f(t_j, u_j)$, $k_2 = f(t_j + h/2, u_j + h/2k_1)$.

Wenden wir schließlich die Simpson-Regel an und ersetzen $u_{j+1/2}$, u_{j+1} geeignet durch Taylorentwicklungen, dann ergibt sich das sehr genaue und beliebte

Klassische Runge-Kutta-Verfahren 4. Ordnung (RK4)

$$\begin{aligned} u_0 &= y_0 \\ u_{j+1} &= u_j + \frac{h}{6}(k_1 + 2k_2 + 2k_3 + k_4), \quad j = 0, \dots, N - 1 \\ \text{mit } k_1 &= f(t_j, u_j) \\ k_2 &= f(t_j + h/2, u_j + h/2k_1) \\ k_3 &= f(t_j + h/2, u_j + h/2k_2) \\ k_4 &= f(t_{j+1}, u_j + hk_3) \end{aligned}$$

7.1.3 Konvergenz und Konsistenz

Wir wollen nun die vorgestellten Verfahren auf ihre praktische Brauchbarkeit und Genauigkeit hin untersuchen. Die Verfahren lassen sich in der allgemeinen Form

$$(7.7) \quad \begin{aligned} u_0 &= y_0 \\ u_{j+1} &= u_j + h\phi(t_j, h; u_j, u_{j+1}), \quad j = 0, \dots, N - 1, \end{aligned}$$

schreiben,

Definition 7.1.2 Die Funktion $\phi(t, h; u, v)$ in (7.7) heißt Verfahrensfunktion. Hängt ϕ nicht von v ab, dann heißt das Verfahren explizit, sonst implizit.

Die Größe

$$\begin{aligned} \tau(t, h) &= \frac{1}{h}(y(t+h) - y(t) - h\phi(t, h; y(t), y(t+h))), \quad h > 0, \quad t \in [a, b-h], \\ &= 1/h \times \text{Defekt bei Einsetzen der Lösung in das Verfahren} \end{aligned}$$

heißt der lokale Abbruchfehler oder Konsistenzfehler des Verfahrens (7.7) für (AWP) an der Stelle t .

Definition 7.1.3 Das Verfahren (7.7) heißt zu (AWP) konsistent von der Ordnung p , falls es Konstanten $C > 0$ und $\bar{h} > 0$ gibt mit

$$\|\tau(t, h)\| \leq Ch^p \quad \text{für alle } 0 < h \leq \bar{h} \text{ und alle } t \in [a, b - h].$$

Das Verfahren (7.7) heißt stabil, falls eine Konstante $K > 0$ existiert mit

$$\|\phi(t, h; u, v) - \phi(t, h; \tilde{u}, \tilde{v})\| \leq K (\|u - \tilde{u}\| + \|v - \tilde{v}\|) \quad \text{für alle } t \in [a, b] \text{ } u, v, \tilde{u}, \tilde{v} \in \mathbb{R}^n.$$

Das Verfahren (7.7) heißt konvergent von der Ordnung p , falls mit Konstanten $M > 0, H > 0$ gilt

$$\|e_j\| = \|y(t_j) - u_j\| \leq Mh^p, \quad \text{für } j = 0, \dots, N \text{ und alle } h = \frac{b-a}{N} \leq H.$$

Bespiel: Explizites Euler-Verfahren Das Euler-Verfahren hat Konsistenzordnung 1.

Nachweis: Sei $f \in C^1([a, b] \times \mathbb{R}^n; \mathbb{R}^n)$ und y Lösung von $y' = f(t, y)$. Dann ist $y' \in C^1([a, b]; \mathbb{R}^n)$, also $y \in C^2([a, b]; \mathbb{R}^n)$ und Taylorentwicklung liefert komponentenweise mit einem $\xi_i \in [0, 1]$

$$y(t+h) = y(t) + y'(t)h + \frac{1}{2}(y''(t+\xi_i h))_{1 \leq i \leq n} h^2 = y(t) + f(t, y(t))h + \frac{1}{2}(y''_i(t+\xi_i h))_{1 \leq i \leq n} h^2.$$

Also ergibt sich

$$\begin{aligned} \|\tau(t, h)\| &= \left\| \frac{1}{h}(y(t+h) - y(t) - hf(t, y(t))) \right\| = \frac{1}{2} \|(y''_i(t + \xi_i h))_{1 \leq i \leq n}\| h \\ &\leq \frac{1}{2} \left(\sup_{s \in [a, b]} \|y''(s)\| \right) h. \end{aligned}$$

Damit hat das Euler-Verfahren Konsistenzordnung 1. \square

| Verfahren | Konsistenzordnung |
|-------------|-------------------|
| Expl. Euler | 1 |
| Impl. Euler | 1 |
| Heun | 2 |
| Mod. Euler | 2 |
| RK4 | 4 |

7.1.4 Ein Konvergenzsatz

Wir beweisen nun einen grundlegenden Konvergenzsatz für explizite Einschrittverfahren.

Satz 7.1.4 Sei $y \in C^1([a, b]; \mathbb{R}^n)$ Lösung von (AWP). Das Verfahren (7.7) sei konsistent von der Ordnung p und stabil. Dann ist das Verfahren konvergent von der Ordnung p . Genauer gibt es $H > 0$, so dass für den globalen Diskretisierungsfehler gilt

$$\|e_j\| = \|y(t_j) - u_j\| \leq \frac{e^{4K|t_j-a|} - 1}{4K} 2Ch^p \quad \text{für } j = 0, \dots, N \text{ und alle } h = \frac{b-a}{N} \leq H.$$

Beweis: (für Interessierte) Setze

$$y_j = y(t_j), \quad e_j = y_j - u_j, \quad j = 0, \dots, N.$$

Dann gilt für $j = 0, \dots, N - 1$ nach Definition des Verfahrens (7.7) und des lokalen Diskretisierungsfehlers

$$\begin{aligned} u_{j+1} &= u_j + h\phi(t_j, h; u_j, u_{j+1}), \\ y_{j+1} &= y_j + h\phi(t_j, h; y_j, y_{j+1}) + h\tau(t_j, h). \end{aligned}$$

Subtraktion der ersten von der zweiten Gleichung ergibt

$$e_{j+1} = e_j + h(\phi(t_j, h; y_j, y_{j+1}) - \phi(t_j, h; u_j, u_{j+1})) + h\tau(t_j, h).$$

Sei nun $0 < h = (b - a)/N \leq \bar{h}$ Wegen $t_j \in [a, b - h]$ liefert die Konsistenzbedingung $\|\tau(t_j, h)\| \leq Ch^p$. Zusammen mit der Stabilität des Verfahrens erhalten wir daher mit der Dreiecksungleichung

$$\|e_{j+1}\| \leq (1 + hK)\|e_j\| + hK\|e_{j+1}\| + hCh^p$$

Wähle nun $0 < H \leq \bar{h}$ so klein, dass gilt $HK \leq 1/2$. Dann ergibt sich für alle $0 < h = (b - a)/N \leq H$

$$\|e_{j+1}\| \leq \frac{1 + hK}{1 - hK}\|e_j\| + h2Ch^p \leq (1 + h4K)\|e_j\| + h2Ch^p$$

Das nachfolgende Lemma liefert nun wegen $e_0 = 0$

$$\|e_{j+1}\| \leq \frac{e^{4K|t_{j+1}-a|} - 1}{4K} 2Ch^p.$$

Damit ist der Satz bewiesen. \square

Wir benötigen zur Vervollständigung des Beweises noch das folgende *diskrete Gronwall-Lemma* zur Abschätzung der Fehlerakkumulation.

Lemma 7.1.5 Für Zahlen $L > 0$, $a_j \geq 0$, $h_j > 0$ und $b \geq 0$ sei

$$a_{j+1} \leq (1 + h_j L)a_j + h_j b, \quad j = 0, 1, \dots, n - 1.$$

Dann gilt

$$a_j \leq \frac{e^{Lt_j} - 1}{L} b + e^{Lt_j} a_0 \quad \text{mit } t_j := \sum_{i=0}^{j-1} h_i.$$

Beweis: (für Interessierte) Für $j = 0$ ist die Behauptung klar. Der Induktionsschritt $j \rightarrow j + 1$ ergibt sich aus

$$\begin{aligned} a_{j+1} &\leq \underbrace{(1 + h_j L)}_{\leq e^{h_j L}} \left(\frac{e^{L t_j} - 1}{L} b + e^{L t_j} a_0 \right) + h_j b \\ &\leq \left(\frac{e^{L(t_j+h_j)} - 1 - h_j L}{L} + h_j \right) b + e^{L(t_j+h_j)} a_0 \\ &= \frac{e^{L t_{j+1}} - 1}{L} b + e^{L t_{j+1}} a_0 \end{aligned}$$

□

7.1.5 Explizite Runge-Kutta-Verfahren

Verfahren hoher Konsistenzordnung kann man durch eine Verallgemeinerung des Ansatzes beim RK4-Verfahren gewinnen:

r-stufiges explizite Runge-Kutta-Verfahren:

Hier wählt man die Verfahrensfunktion

$$(7.8) \quad \begin{aligned} k_i &= f \left(t + \gamma_i h, u + h \sum_{j=1}^{i-1} \alpha_{ij} k_j \right), \quad i = 1, \dots, r, \\ \phi(t, h; u) &= \sum_{i=1}^r \beta_i k_i. \end{aligned}$$

Hierbei heißt $k_i = k_i(t, u, h)$ die *i-te Stufe*. Zur kompakten Beschreibung von expliziten Runge-Kutta-Verfahren notiert man die Koeffizienten in einem Tableau, dem sogenannten

Butcher-Schema:

| | | | | | |
|------------|---------------|---------------|----------|------------------|-----------|
| γ_1 | 0 | | | | |
| γ_2 | α_{21} | 0 | | | |
| γ_3 | α_{31} | α_{32} | 0 | | |
| \vdots | \vdots | \vdots | \ddots | \ddots | |
| γ_r | α_{r1} | \cdots | \cdots | $\alpha_{r,r-1}$ | 0 |
| | β_1 | β_2 | \cdots | β_{r-1} | β_r |

Beispiele für Butcher-Schemata:

Explizites Euler-Verfahren: Modifiziertes Euler-Verfahren: Verfahren von Heun:

$$\begin{array}{c|c} 0 & 0 \\ \hline & 1 \end{array}$$

$$\begin{array}{c|cc} 0 & 0 & \\ \hline 1/2 & 1/2 & 0 \\ & 0 & 1 \end{array}$$

$$\begin{array}{c|cc} 0 & 0 & \\ \hline 1 & 1 & 0 \\ & 1/2 & 1/2 \end{array}$$

Mit diesem Ansatz kann man Verfahren beliebiger Konsistenzordnung p erzeugen. Man muss hierzu die Stufenzahl r groß genug wählen. Taylorentwicklung des lokalen Abbruchfehlers liefert dann Gleichungen für die Koeffizienten.

Durch Taylorentwicklung läßt sich der folgende Satz beweisen.

Satz 7.1.6 *Betrachte ein Runge-Kutta Verfahren (7.7) mit Verfahrensfunktion (7.8) mit*

$$\gamma_i = \sum_{j=1}^r \alpha_{ij} \quad i = 1, \dots, r.$$

Es besitzt genau dann für jede rechte Seite $f \in C^p([a, b] \times \mathbb{R})$ die Konsistenzordnung $p = 1$, falls die Koeffizienten der Gleichung

$$\sum_{i=1}^r \beta_i = 1$$

genügen; genau dann die Konsistenzordnung $p = 2$, falls die Koeffizienten zusätzlich der Gleichung

$$\sum_{i=1}^r \beta_i \gamma_i = 1/2$$

genügen; genau dann die Konsistenzordnung $p = 3$, falls die Koeffizienten zusätzlich den Gleichungen

$$\begin{aligned} \sum_{i=1}^r \beta_i \gamma_i^2 &= 1/3 \\ \sum_{i,j=1}^r \beta_i \alpha_{ij} \gamma_j &= 1/6 \end{aligned}$$

genügen; genau dann die Konsistenzordnung $p = 4$, falls die Koeffizienten zusätzlich den Gleichungen

$$\begin{aligned} \sum_{i=1}^r \beta_i \gamma_i^3 &= 1/4 \\ \sum_{i,j=1}^r \beta_i \gamma_i \alpha_{ij} \gamma_j &= 1/8 \\ \sum_{i,j=1}^r \beta_i \alpha_{ij} \gamma_j^2 &= 1/12 \\ \sum_{i,j,k=1}^r \beta_i \alpha_{ij} \alpha_{jk} \gamma_k &= 1/24 \end{aligned}$$

genügen.

Beweis: Siehe zum Beispiel Deuffhard und Bornemann [DB02]. \square

7.2 Steife Differentialgleichungen

In zahlreichen Anwendungen (z.B. beim Ablauf chemischer Reaktionen), aber auch bei Semidiskretisierung partieller Differentialgleichungen, treten *steife Systeme* auf. Obwohl es sich auch um Anfangswertprobleme handelt, erzwingen sie bei vielen – aber nicht bei allen – Verfahren inakzeptabel kleine Schrittweiten h , um eine genaue Lösung zu erhalten.

Ausgangspunkt ist ein Anfangswertproblem für ein System n gewöhnlicher Differentialgleichungen:

$$\text{(AWPn)} \quad \begin{aligned} y'(t) &= f(t, y(t)), & t \in [a, b] \\ y(a) &= y_0 \end{aligned}$$

mit $f : [a, b] \times \mathbb{R}^n \rightarrow \mathbb{R}^n$, $y_0 \in \mathbb{R}^n$.

Der Begriff "steifes System" ist in der Literatur nicht ganz einheitlich definiert. Der wesentlich Punkt ist, dass die Lösung zusammengesetzt ist aus einem langsam veränderlichen Teil (der meist abklingt) und einer Störung, die im Allgemeinen sehr schnell gedämpft wird.

Wir betrachten den Spezialfall, dass (AWPn) linear ist:

$$\text{(LAWPn)} \quad \begin{aligned} y'(t) &= Ay(t) + b, & t \in [a, b] \\ y(a) &= y_0 \end{aligned}$$

mit einer Matrix $A \in \mathbb{R}^{n,n}$ und einem Vektor $b \in \mathbb{R}^n$.

Sei zudem $A \in \mathbb{R}^{n,n}$ diagonalisierbar mit zugehörigen Eigenwerten λ_i sowie Eigenvektoren v_i . Mit einer partikulären Lösung y_P ist dann die allgemeine Lösung von der Form

$$y(t) = y_H(t) + y_P(t), \quad y_H(t) = \sum_{i=1}^n C_i e^{\lambda_i t} v_i.$$

Ist nun $\text{Re}(\lambda_i) < 0$ für $i = 1, \dots, n$, so gilt

$$\lim_{t \rightarrow \infty} y_H(t) \rightarrow 0,$$

alle Lösungen nähern sich also y_P an. Hierbei klingen die Summanden in y_H mit $\text{Re}(\lambda_i) \ll -1$ sehr schnell und Summanden mit $\text{Re}(\lambda_i) \ll -1$ deutlich langsamer ab. Gibt es Eigenwerte mit $\text{Re}(\lambda_i) \ll -1$ und Eigenwerte mit schwach negativem Realteil, so nennt man das System *steif*.

Beispiel: Betrachte zum Beispiel das Problem

$$y' = Ay, \quad y(0) = y_0 := \begin{pmatrix} C_1 + C_2 \\ C_1 - C_2 \end{pmatrix}$$

mit $C_1, C_2 \in \mathbb{R}$ und

$$A = \begin{pmatrix} \frac{\lambda_1 + \lambda_2}{2} & \frac{\lambda_1 - \lambda_2}{2} \\ \frac{\lambda_1 - \lambda_2}{2} & \frac{\lambda_1 + \lambda_2}{2} \end{pmatrix}.$$

A hat die Eigenwerte λ_1, λ_2 mit zugehörigen Eigenvektoren $\begin{pmatrix} 1 \\ 1 \end{pmatrix}$ bzw. $\begin{pmatrix} 1 \\ -1 \end{pmatrix}$. Ist zum Beispiel $\lambda_1 = -1$ und $\lambda_2 = -1000$, dann lautet die Lösung

$$y(t) = C_1 \begin{pmatrix} 1 \\ 1 \end{pmatrix} e^{-t} + C_2 \begin{pmatrix} 1 \\ -1 \end{pmatrix} e^{-1000t}.$$

Der zweite Term spielt nach kürzester Zeit so gut wie keine Rolle mehr. Der erste Term ist bestimmend und konvergiert für $t \rightarrow \infty$ ebenfalls gegen 0. Von einem geeigneten Integrationsverfahren wird man erwarten, dass es ohne große Einschränkungen an die Schrittweite Näherungen u_j liefert mit

$$\lim_{j \rightarrow \infty} u_j = 0.$$

Betrachten wir jedoch zum Beispiel die Anwendung des expliziten Euler-Verfahrens, so ergibt sich mit $u_0 = y_0 = C_1 \begin{pmatrix} 1 \\ 1 \end{pmatrix} + C_2 \begin{pmatrix} 1 \\ -1 \end{pmatrix}$

$$u_1 = (I + hA)u_0 = C_1(1 + h\lambda_1) \begin{pmatrix} 1 \\ 1 \end{pmatrix} + C_2(1 + h\lambda_2) \begin{pmatrix} 1 \\ -1 \end{pmatrix}$$

und nun induktiv

$$u_j = C_1(1 + h\lambda_1)^j \begin{pmatrix} 1 \\ 1 \end{pmatrix} + C_2(1 + h\lambda_2)^j \begin{pmatrix} 1 \\ -1 \end{pmatrix}.$$

Ist $C_2 \neq 0$, so müssen wir $|1 + h\lambda_2| < 1$, also $-h\lambda_2 = 1000h < 2$ wählen, damit gilt $\lim_{j \rightarrow \infty} u_j = 0$. Ein geeignetes Verfahren sollte dies möglichst für alle $h > 0$ sicherstellen. \square

Das Euler-Verfahren benötigt also sehr kleine Schrittweiten, obwohl sich die Lösung kaum ändert. Man nennt die Differentialgleichung dann *steif*. Die formale Definition ist uneinheitlich. Folgende Definition ist am weitesten verbreitet.

Definition 7.2.1 Ein Anfangswertproblem (LAWPn) heißt *steif*, wenn A Eigenwerte mit $\operatorname{Re}(\lambda_i) \ll -1$ und Eigenwerte λ_i mit schwach negativem Realteil besitzt.

Wir kommen nun zur numerischen Behandlung steifer Differentialgleichungen. Die homogene Lösung des Systems (LAWPn) ist für diagonalisierbares A zusammengesetzt aus Linearkombinationen der Funktionen $e^{\lambda_i t} v_i$. Um Verfahren für steife Differentialgleichungen zu bewerten und zu analysieren, betrachtet man nach Dahlquist (1963) die

Modellgleichung

$$(7.9) \quad y' = \lambda y, \quad y(0) = 1, \quad \text{mit } \lambda \in \mathbb{C}, \operatorname{Re}(\lambda) < 0.$$

Die Lösung ist

$$y(t) = e^{\lambda t}$$

und wegen $\operatorname{Re}(\lambda) < 0$ gilt

$$(7.10) \quad \lim_{t \rightarrow \infty} y(t) = 0.$$

Die Lösung fällt also je nach Größe von $|\operatorname{Re}(\lambda)|$ sehr unterschiedlich stark ab. Damit ein Verfahren gut für steife Differentialgleichungen geeignet ist, hat sich folgende Anforderung bewährt:

Forderung: Die numerische gewonnene Näherungslösung von (7.9) soll die Eigenschaften von der Lösung $y(t) = e^{\lambda t}$, also insbesondere (7.10), möglichst gut widerspiegeln.

Dies motiviert folgende

Definition 7.2.2 (A-stabil (absolut stabil), L-stabil)

Ein Verfahren heißt

- a) absolut stabil (A-stabil), wenn seine Anwendung auf das Modellproblem (7.9) für jede Schrittweite $h > 0$ eine Folge $\{u_j\}_{j \in \mathbb{N}_0}$ produziert mit

$$|u_{j+1}| \leq |u_j| \quad \forall j \geq 0.$$

- b) L-stabil, wenn es A-stabil ist und zudem gilt

$$\lim_{j \rightarrow \infty} u_j = 0.$$

Bei vielen Einschrittverfahren gilt bei Anwendung auf das Modellproblem (7.9) die Beziehung

$$u_{j+1} = R(q)u_j \quad \text{mit } q = \lambda h$$

und einer Funktion $R : D \rightarrow \mathbb{C}$, $0 \in D \subset \mathbb{C}$.

Definition 7.2.3 Man nennt R die Stabilitätsfunktion des Einschrittverfahrens. Die Menge

$$S = \{q \in \mathbb{C} : |R(q)| < 1\}.$$

heißt Stabilitätsgebiet des Einschrittverfahrens.

Offensichtlich gilt

$$\text{A-stabil} \iff |R(q)| \leq 1 \quad \forall q \in \mathbb{C}, \operatorname{Re}(q) < 0.$$

$$\text{L-stabil} \iff |R(q)| < 1 \quad \forall q \in \mathbb{C}, \operatorname{Re}(q) < 0 \iff S \supset \{q \in \mathbb{C} : \operatorname{Re}(q) < 0\}.$$

7.2.1 Stabilitätsgebiete einiger Verfahren

Explizites Euler-Verfahren

Anwendung des expliziten Euler-Verfahrens auf das Modellproblem (7.9) ergibt

$$u_{j+1} = u_j + h\lambda u_j = (1 + \lambda h)u_j,$$

die Stabilitätsfunktion ist daher $R(q) = 1 + q$. Das Stabilitätsgebiet ist also

$$S = \{q \in \mathbb{C} : |1 + q| < 1\}.$$

Bemerkung: Man kann leicht zeigen, dass alle expliziten Runge-Kutta-Verfahren nicht A-stabil sind!

Implizites Euler-Verfahren

Das implizite Euler-Verfahren liefert für das Modellproblem (7.9)

$$u_{j+1} = u_j + h\lambda u_{j+1}$$

und somit

$$u_{j+1} = \frac{1}{1 - \lambda h} u_j.$$

Dies ergibt die Stabilitätsfunktion $R(q) = \frac{1}{1-q}$, $q \neq 1$, und das Stabilitätsgebiet

$$S = \{q \in \mathbb{C} : |1 - q| > 1\} \supset \{q \in \mathbb{C} : \operatorname{Re}(q) < 0\}.$$

Das implizite Euler-Verfahren ist also A-stabil, sogar L-stabil!

Implizite Trapezregel

Die Verfahrensgleichung lautet

$$u_{j+1} = u_j + \frac{h}{2}(f(u_j) + f(u_{j+1})).$$

Wir erhalten für das Modellproblem (7.9)

$$u_{j+1} = u_j + \frac{h}{2}\lambda(u_j + u_{j+1})$$

und somit

$$u_{j+1} = \frac{1 + \lambda h/2}{1 - \lambda h/2} u_j.$$

Daher gilt $R(q) = \frac{1+q/2}{1-q/2}$, $q \neq 2$, und das Stabilitätsgebiet ist

$$S = \{q \in \mathbb{C} : |1 + q/2| < |1 - q/2|\} = \{q \in \mathbb{C} : \operatorname{Re}(q) < 0\}.$$

Implizite Runge-Kutta-Verfahren

Besonders gut geeignet für steife Differentialgleichungen sind implizite Runge-Kutta-Verfahren.

Implizite Runge-Kutta-Verfahren erhält man durch Butcher-Schemata, bei denen die Koeffizienten α_{ij} keine strikte untere Dreiecksmatrix bilden. Die Verfahrensgleichung ist gegeben durch

$$(7.11) \quad k_i = f \left(t + \gamma_i h, u + h \sum_{l=1}^r \alpha_{il} k_l \right), \quad i = 1, \dots, r,$$

$$\phi(t, h; u) = \sum_{i=1}^r \beta_i k_i.$$

(beachte die Summation bis r anstelle $i - 1$). Ein implizites Runge-Kutta-Verfahren ist ein explizites Einschrittverfahren, lediglich die Stufen k_i sind als Lösung eines nichtlinearen Gleichungssystems gegeben. Man kann nun die Koeffizienten α_{ij} , β_i , γ_i tatsächlich so wählen, dass ein L-stabiles Verfahren der Ordnung $p = 2r$ entsteht.

Kapitel 8

Numerische Behandlung von Randwertproblemen für gewöhnliche Differentialgleichungen

8.1 Einleitung

Eine Vielzahl von Anwendungen führt auf Randwertprobleme, einer Verallgemeinerung von Anfangswertaufgaben. Wir betrachten hier lediglich Randwertprobleme 2. Ordnung, die allgemein von folgender Form sind:

Randwertproblem 2. Ordnung: Gesucht ist eine stetig differenzierbare Funktion $y : [a, b] \rightarrow \mathbb{R}$ mit

$$(8.1) \quad y''(t) = f(t, y(t), y'(t)), \quad t \in [a, b]$$

(RWP)

$$(8.2) \quad R(a, y(a), y'(a)) = 0, \quad \tilde{R}(b, y(b), y'(b)) = 0$$

wobei $a < b$, $f : [a, b] \times \mathbb{R} \times \mathbb{R} \rightarrow \mathbb{R}$ und $R, \tilde{R} : [a, b] \times \mathbb{R} \times \mathbb{R} \rightarrow \mathbb{R}$.

Es kommen also zu der Differentialgleichung 2. Ordnung noch zwei Randbedingungen an den Intervallrändern dazu.

Die Frage der Existenz- und Eindeutigkeit von Lösungen solcher Randwertprobleme ist wesentlich verwickelter als für Anfangswertprobleme. Wir gehen hierauf aber nicht näher ein.

Zur numerischen Behandlung von (RWP) betrachten wir zwei Verfahrensklassen: *Differenzenverfahren* und *Variationsverfahren mit Finiten Elementen*.

Wir beschränken uns auf das sog. *lineare 1. Randwertproblem*

$$(8.3) \quad -y'' + q(t)y = g(t), \quad y(a) = \alpha, \quad y(b) = \beta.$$

Für $q, g \in C([a, b])$ mit $q \geq 0$ läßt sich zeigen, dass (8.3) eine eindeutige Lösung besitzt.

8.2 Differenzenverfahren

Die grundlegende Idee bei Differenzenverfahren besteht darin, die in einer Differentialgleichungen vorkommenden Ableitungen durch Differenzenquotienten zu ersetzen und dann die hierdurch entstehenden Gleichungen zu lösen.

Wir wollen das Vorgehen am Problem (8.3) erläutern. Zur Diskretisierung von (8.3) wählen wir ein äquidistantes Gitter

$$a = t_0 < t_1 < \dots < t_{n+1} = b, \quad t_j = a + jh, \quad h = \frac{b - a}{n + 1},$$

betrachten die Differentialgleichung nur an den Stellen t_j und ersetzen die Ableitung durch den Differenzenquotienten zweiter Ordnung

$$y''(t_j) = \frac{y(t_{j+1}) - 2y(t_j) + y(t_{j-1}))}{h^2} + \tau_j(y; h),$$

wobei im Falle $y \in C^4([a, b])$ für den Diskretisierungsfehler gilt (Nachweis durch Taylorentwicklung)

$$\tau_j(y; h) = O(h^2).$$

Damit sind $y_j = y(t_j)$ Lösung des Gleichungssystems

$$(8.4) \quad \begin{aligned} y_0 &= \alpha, \\ \frac{-y_{j+1} + 2y_j - y_{j-1}}{h^2} + q_j y_j &= g_j + \tau_j(y; h), \quad j = 1, \dots, n, \\ y_{n+1} &= \beta, \end{aligned}$$

wobei $q_j = q(t_j)$, $g_j = g(t_j)$. Mit den Vektoren

$$\bar{y} = \begin{pmatrix} y_1 \\ \vdots \\ y_n \end{pmatrix}, \quad c = \begin{pmatrix} g_1 + \frac{\alpha}{h^2} \\ g_2 \\ \vdots \\ g_{n-1} \\ g_n + \frac{\beta}{h^2} \end{pmatrix}, \quad \bar{\tau} = \begin{pmatrix} \tau_1(y; h) \\ \vdots \\ \tau_n(y; h) \end{pmatrix},$$

und der Tridiagonalmatrix

$$A = \frac{1}{h^2} \begin{pmatrix} 2 + q_1 h^2 & -1 & & & & \\ -1 & 2 + q_2 h^2 & -1 & & & \\ & & \ddots & \ddots & \ddots & \\ & & & -1 & 2 + q_{n-1} h^2 & -1 \\ & & & & -1 & 2 + q_n h^2 \end{pmatrix}$$

ist dann (8.4) äquivalent zum Gleichungssystem

$$A\bar{y} = c + \bar{\tau}.$$

Lassen wir den Fehlerterm $\bar{\tau}$ fort, so erhalten wir Näherungen $\bar{u} = (u_1, \dots, u_n)^T$ als Lösung von

$$(8.5) \quad A\bar{u} = c.$$

Man kann zeigen, dass A positiv definit ist, siehe zum Beispiel Stoer und Bulirsch [SB90]. Das Gleichungssystem hat daher eine eindeutige Lösung und kann wegen der Tridiagonalform in $O(n)$ Operationen gelöst werden. Ferner gilt der folgende Satz

Satz 8.2.1 *Das Randwertproblem (8.3) habe eine Lösung $y \in C^4([a, b])$ und es gelte $|y^{(4)}(t)| \leq M$, $t \in [a, b]$. Ferner sei $q(t) \geq 0$, $t \in [a, b]$. Dann gilt für die Lösung $\bar{u} = (u_1, \dots, u_n)^T$ von (8.5)*

$$|y(t_j) - u_j| \leq \frac{Mh^2}{24}(t_j - a)(b - t_j).$$

Beweis: Siehe zum Beispiel Stoer und Bulirsch [SB90] oder Plato [PI00]. \square

8.3 Variationsmethoden

Variationsmethoden (Finite-Elemente-Methoden) gehören insbesondere bei partiellen Differentialgleichungen zu den populärsten Methoden für Randwertaufgaben. Wir skizzieren hier nur die Grundidee am bereits behandelten Beispiel (der Einfachheit halber mit homogenen Randwerten)

$$(8.6) \quad -y''(t) + q(t)y(t) = g(t), \quad y(a) = 0, \quad y(b) = 0$$

mit $q, g \in C([a, b])$, $q \geq 0$. Sei

$$y \in C_0^2([a, b]) := \{z \in C^2([a, b]) : z(a) = z(b) = 0\}$$

die (klassische) Lösung von (8.6). Um eine Variationsformulierung von (8.6) zu erhalten, multiplizieren wir (8.6) mit einer beliebigen Testfunktion $v \in C_0^2([a, b])$ und integrieren über $[a, b]$. Dies liefert

$$(8.7) \quad \int_a^b (-y'' + qy)v \, dt = \int_a^b gv \, dt \quad \forall v \in C_0^2([a, b]).$$

Man überlegt sich leicht, dass für eine klassische Lösung $y \in C_0^2([a, b])$ (8.6) und (8.7) äquivalent sind. Nun ergibt sich aus (8.7) mit partieller Integration

$$\int_a^b g(t)v(t) \, dt = \int_a^b (-y''(t) + q(t)y(t))v(t) \, dt = -y'(t)v(t)|_a^b + \int_a^b (y'(t)v'(t) + q(t)y(t)v(t)) \, dt.$$

Wegen $v(a) = v(b) = 0$ erhalten wir also die Variationsformulierung

$$(8.8) \quad \int_a^b (y'(t)v'(t) + q(t)y(t)v(t)) dt = \int_a^b g(t)v(t) dt, \quad \forall v \in C_0^2([a, b]),$$

die für $y \in C_0^2([a, b])$ wiederum äquivalent ist zu (8.7) und somit zu (8.6). Die Formulierung (8.8) kann nun verwendet werden, um Lösungen auch in Situationen zu definieren, in denen keine klassische Lösung existiert: Wir betrachten den Raum

$$V = K_0^1([a, b]) := \{z \in C([a, b]) : z(a) = z(b) = 0, \quad z' \text{ ex. fast überall und } z' \in L^2(a, b)\},$$

wobei $L^2(a, b)$ der Raum der auf $]a, b[$ quadratintegrierbaren Funktionen ist. Dann macht (8.8) bereits Sinn für $y, v \in V$.

Bemerkung: V enthält z.B. stetige, stückweise differenzierbare Funktionen z mit $z(a) = z(b) = 0$.

Die *Variationsformulierung* (schwache Formulierung) ist nun:

Variationsformulierung:

Finde $y \in V$ mit

$$(8.9) \quad \int_a^b (y'(t)v'(t) + q(t)y(t)v(t)) dt = \int_a^b g(t)v(t) dt, \quad \forall v \in V.$$

Führen wir die symmetrischen Bilinearformen ein

$$(8.10) \quad \begin{aligned} \alpha(u, v) &:= \int_a^b (u'(t)v'(t) + q(t)u(t)v(t)) dt, \quad u, v \in V, \\ (u, v) &:= \int_a^b u(t)v(t) dt, \quad u, v \in V, \end{aligned}$$

dann können wir (8.9) kurz in der Form schreiben

$$\alpha(y, v) = (g, v), \quad \forall v \in V.$$

Man kann zeigen, dass (auch für $g \in L^2(a, b)$) eine eindeutige schwache Lösung $y \in V$ existiert. Sie ist die eindeutige klassische Lösung, falls diese existiert (für $q, g \in C([a, b])$, $q \geq 0$, ist das der Fall).

Die Variationsformulierung (8.10) gestattet eine einfache numerische Approximation: Beim *Ritz-Verfahren* wählt man einen *Finite-Elemente-Teilraum* $V_h \subset V$

Variationsverfahren mit Finiten Elementen:

Finde $u_h \in V_h$ mit

$$(8.11) \quad \alpha(u_h, v) = (g, v) \quad \forall v \in V_h.$$

Beispiel für einen Finite-Elemente-Raum:

Stetige stückweise lineare Funktionen (also lineare Splines) zu einem Gitter

$$\Delta = \{t_i : a = t_0 < t_1 < \dots < t_{n+1} = b\}, \quad t_{j+1} - t_j \leq h,$$

die in a und b verschwinden:

$$V_h = \{y \in S_{\Delta,1} : y(a) = y(b) = 0\}.$$

Eine Basis bilden dann die "Dachfunktionen" zu den inneren Knoten. \square

Ist nun $\{\phi_1, \dots, \phi_m\}$ eine Basis des Finite-Elemente-Raums V_h , dann muss (8.11) nur mit $v = \phi_i, i = 1, \dots, m$, getestet werden und Einsetzen des Ansatzes

$$u_h(t) = \sum_{j=1}^m u_j \phi_j(t)$$

mit Koeffizienten $u_j \in \mathbb{R}$ liefert das lineare Gleichungssystem

$$\sum_{j=1}^m u_j \underbrace{\alpha(\phi_j, \phi_i)}_{=: a_{ij}} = \underbrace{(g, \phi_i)}_{=: c_i}, \quad i = 1, \dots, m.$$

Mit der sogenannten *Steifigkeitsmatrix* $A = (a_{ij})$ und $c = (c_i)$ ergibt sich für $\bar{u} = (u_1, \dots, u_m)^T$ das symmetrische lineare Gleichungssystem

$$(8.12) \quad A\bar{u} = c.$$

Offensichtlich ist A positiv definit, da für $\bar{u} \neq 0$ gilt $u_h \neq 0$, also $u'_h \neq 0$ (beachte $u_h(0) = 0$) und somit

$$\bar{u}^T A\bar{u} = \sum_{i,j=1}^m \alpha(\phi_j, \phi_i) u_i u_j = \alpha(u_h, u_h) = \int_a^b ((u'_h)^2 + qu_h^2) dt \geq \int_a^b (u'_h)^2 dt > 0.$$

Das Gleichungssystem (8.12) ist also eindeutig lösbar.

In der Regel wählt man den Ansatzraum so, dass Basisfunktionen $\{\phi_1, \dots, \phi_m\}$ mit einem Träger von wenigen Gitterpunkten existieren (z.B. B-Splines). Die Steifigkeitsmatrix ist dann dünn besetzt (bei geeigneter Anordnung der Basis eine Bandmatrix) und das Gleichungssystem (8.12) in $O(m)$ Operationen auflösbar.

Kapitel 9

Numerische Behandlung von Randwertproblemen für partielle Differentialgleichungen

9.1 Elliptische Randwertprobleme

Viele physikalische Zustände (z.B. stationäre Temperaturverteilung, elektrostatische Potentiale, usw.) werden durch elliptische partielle Differentialgleichungen mit zusätzlichen Randbedingungen beschrieben. Da analytische Lösungsmethoden oft nicht angewendet werden können, benötigt man numerische Verfahren. Wie bei Randwertproblemen gewöhnlicher Differentialgleichungen kann man *Differenzenverfahren* sowie *Finite-Elemente-Methoden* anwenden.

Wir beschränken uns hier auf die

Zweidimensionale Poisson-Gleichung mit Dirichlet-Randbedingungen:

Sei $G \subset \mathbb{R}^2$ ein offenes (zusammenhängendes) Gebiet mit stückweise glattem Rand ∂G . Wir suchen eine Lösung $u : G \rightarrow \mathbb{R}$ mit

$$(9.1) \quad \begin{aligned} -\Delta u(x) &:= - \left(\frac{\partial^2 u}{\partial x_1^2}(x) + \frac{\partial^2 u}{\partial x_2^2}(x) \right) = f(x), & \text{für } x \in G, \\ u(x) &= g(x), & \text{für } x \in \partial G. \end{aligned}$$

Für hinreichend oft differenzierbare Funktionen $f, g : \bar{G} \rightarrow \mathbb{R}$ existiert genau eine Lösung des Problems. Im folgenden soll dies stets angenommen werden.

Wir werden im folgenden homogene Randwerte $g \equiv 0$ betrachten, also

$$(9.2) \quad \begin{aligned} -\Delta u(x) &= f(x), & \text{für } x \in G, \\ u(x) &= 0, & \text{für } x \in \partial G. \end{aligned}$$

Denn u ist genau dann eine Lösung von (9.2), wenn $\tilde{u} = u - g$ eine Lösung von (9.2) zur modifizierten rechten Seite $\tilde{f} = f + \Delta g$ ist.

Die Poisson-Gleichung (9.2) beschreibt z.B. die stationäre Temperaturverteilung in einem Gebiet G bei einer Wärmequelle f , oder in 2D die Verformung einer elastischen Membran unter einer Kraft f , oder das elektrostatische Potential zu einer Ladungsdichte f bei vorgegebenem Potential am Rand.

9.1.1 Differenzenverfahren

Wir betrachten der Einfachheit halber die Poisson-Gleichung mit Dirichlet-Randbedingung auf dem Einheitsquadrat $G =]0, 1[\times]0, 1[$

$$(9.3) \quad \begin{aligned} -\Delta u(x) &= f(x) \quad \text{für } x \in G =]0, 1[\times]0, 1[, \\ u(x) &= 0 \quad \text{für } x \in \partial G. \end{aligned}$$

Es gibt verschiedene Möglichkeiten zur approximativen Lösung von (9.3). Wir betrachten zunächst Differenzenverfahren. Wie bei Randwertproblemen für gewöhnlich Differentialgleichungen gehen wir folgendermaßen vor:

1. Wir betrachten die Differentialgleichung nur auf einem Gitter $x_{ij} = (ih, jh)$, $1 \leq i, j \leq N$, $h = \frac{1}{N+1}$. Wir wählen die Bezeichnungen $u_{ij} = u(x_{ij})$.
2. Nun approximieren wir die partiellen Ableitungen durch Differenzenquotienten: Für $u \in C^4(G)$ gilt mit $u_{ij} = u(x_{ij})$

$$\begin{aligned} \frac{\partial^2 u}{\partial x_1^2}(x)(x_{ij}) &= \frac{u_{i+1,j} - 2u_{ij} + u_{i-1,j}}{h^2} + O(h^2), \\ \frac{\partial^2 u}{\partial x_2^2}(x)(x_{ij}) &= \frac{u_{i,j+1} - 2u_{ij} + u_{i,j-1}}{h^2} + O(h^2). \end{aligned}$$

Einsetzen in die Differentialgleichung ergibt nach Vernachlässigung der $O(h^2)$ -Terme ein System zur Bestimmung der Näherungslösung U_{ij} von $u(x_{ij})$.

Differenzenverfahren für die Poisson-Gleichung:

$$(9.4) \quad \begin{aligned} -\Delta_5 U_{ij} &:= -\frac{1}{h^2}(U_{i+1,j} + U_{i,j+1} + U_{i-1,j} + U_{i,j-1} - 4U_{ij}) = f(x_{ij}), \quad 1 \leq i, j \leq N, \\ U_{0,j} &= 0, \quad U_{N+1,j} = 0, \quad U_{i,0} = 0, \quad U_{i,N+1} = 0, \quad 1 \leq i, j \leq N. \end{aligned}$$

Somit ergibt (9.4) N^2 lineare Gleichungen für die N^2 Unbekannten U_{ij} , $1 \leq i, j \leq N$.

9.1.2 Finite-Elemente-Methoden

Hat das Gebiet $G \subset \mathbb{R}^2$ eine unregelmäßige Gestalt, dann sind Differenzenverfahren recht unhandlich. In diesem Fall bietet es sich an, eine Variationmethode mit Finiten Elementen zu verwenden. Wir betrachten die Poisson-Gleichung mit Dirichlet-Randbedingung

$$(9.5) \quad \begin{aligned} -\Delta u(x) &= f(x) \quad \text{für } x \in G, \\ u(x) &= 0 \quad \text{für } x \in \partial G. \end{aligned}$$

Wie im Fall gewöhnlicher Differentialgleichungen gehen wir zunächst zu einer schwachen Formulierung über: Wir nehmen zunächst die Existenz einer klassischen Lösung

$$u \in C_0^2(\bar{G}) := \{z \in C^2(\bar{G}) : z|_{\partial G} = 0\}$$

an. Multiplikation mit einer beliebigen Testfunktion $v \in C_0^2(\bar{G})$ und Integration über G liefert dann

$$(9.6) \quad \int_G (-\Delta u(x)v(x)) dx = \int_G f(x)v(x) dx \quad \forall v \in C_0^2(\bar{G}).$$

Man zeigt leicht, dass (9.5) und (9.6) für Funktionen $u \in C_0^2(\bar{G})$ äquivalent sind.

Wir benutzen nun die Bezeichnung:

$$u_{x_i} := \frac{\partial u}{\partial x_i}, u_{x_i x_j} := \frac{\partial^2 u}{\partial x_i \partial x_j}.$$

Nun gilt für beliebige $v \in C_0^1(\bar{G})$, $w \in C^1(\bar{G})$ die *Greensche Formel* der partiellen Integration (Konsequenz des Gaußschen Integralsatzes)

$$\int_G w_{x_j} v dx = - \int_G w v_{x_j} dx,$$

wobei wegen $v|_{\partial G} = 0$ kein Randintegral auftritt. Verwendung dieser Formel im ersten Term von (9.6) ergibt

$$(9.7) \quad \int_G \underbrace{(u_{x_1}(x)v_{x_1}(x) + u_{x_2}(x)v_{x_2}(x))}_{=\nabla u(x)^T \nabla v(x)} dx = \int_G f(x)v(x) dx \quad \forall v \in C_0^2(\bar{G}).$$

Für $u \in C_0^2(\bar{G})$ sind (9.5) und (9.7) äquivalent.

Die Variationsformulierung (9.7) macht bereits Sinn für

$$u, v \in V := K_0^1(G) = \{z : G \rightarrow \mathbb{R} : z_{x_i} \text{ ex. fast überall und sind quadratintegrierbar, } z|_{\partial G} = 0\}.$$

Die *Variationsformulierung* (schwache Formulierung) ist nun:

Variationsformulierung: Finde $u \in V$ mit

$$(9.8) \quad \int_G ((u_{x_1}(x)v_{x_1}(x) + u_{x_2}(x)v_{x_2}(x))) dx = \int_G f(x)v(x) dx \quad \forall v \in V,$$

Eine Lösung $u \in V$ von (9.8) heißt *schwache Lösung* von (9.5). Man kann zeigen, dass (9.8) eine eindeutige Lösung $u \in V$ besitzt. Sie ist die eindeutige klassische Lösung von (9.5), falls diese existiert.

Führen wir die symmetrischen Bilinearformen ein

$$\alpha(u, v) := \int_G ((u_{x_1}(x)v_{x_1}(x) + u_{x_2}(x)v_{x_2}(x))) dx, \quad u, v \in V,$$

$$(u, v) := \int_G u(x) v(x) dx$$

dann können wir (9.8) kurz in der Form schreiben

$$(9.8) \quad \alpha(u, v) = (f, v), \quad \forall v \in V.$$

Wiederum liefert (9.8) eine gute Basis für die Konstruktion numerischer Verfahren:

Finite-Elemente-Methode: Sei $V_h \subset V$ ein endlichdimensionaler *Finite-Elemente-Teilraum*. Finde $u_h \in V_h$ mit

$$(9.9) \quad \alpha(u_h, v) = (f, v) \quad \forall v \in V_h.$$

Genau wie in Abschnitt 8.3 liefert (9.9) nach Wahl einer Basis von V_h ein lineares Gleichungssystem: Ist $\{\phi_1, \dots, \phi_m\}$ eine Basis des Finite-Elemente-Raums V_h , dann muss (9.9) nur mit $v = \phi_i, i = 1, \dots, m$, getestet werden und Einsetzen des Ansatzes

$$u_h(x) = \sum_{j=1}^m u_j \phi_j(x)$$

mit Koeffizienten $u_j \in \mathbb{R}$ liefert das lineare Gleichungssystem

$$\sum_{j=1}^m u_j \underbrace{\alpha(\phi_j, \phi_i)}_{=: a_{ij}} = \underbrace{(f, \phi_i)}_{=: c_i}, \quad i = 1, \dots, m.$$

Mit der sogenannten *Steifigkeitsmatrix* $A = (a_{ij})$ und $c = (c_i)$ ergibt sich für $\bar{u} = (u_1, \dots, u_m)^T$ das symmetrische lineare Gleichungssystem

$$(9.10) \quad A\bar{u} = c.$$

A ist offensichtlich symmetrisch und auch positiv definit.

Beispiel für einen Finite-Elemente-Teilraum: In der Regel wählt man den Ansatzraum V_h als Finite-Elemente-Raum bestehend aus stückweisen Polynomen über einer regulären Trangulation $\mathcal{T} = \{T_0, \dots, T_N\}$ von \bar{G} :

Definition 9.1.2 Sei \bar{G} polygonal berandet. Eine Menge $\mathcal{T} = \{T_j : j = 0, \dots, N\}$ von abgeschlossenen Dreiecken T_j heißt zulässige Triangulierung von \bar{G} , wenn gilt:

$$a) \bar{G} = \bigcup_{j=0}^N T_j.$$

b) $T_j \cap T_k$ ist leer, ein gemeinsamer Eckpunkt oder eine gemeinsame vollständige Seite.

Die Menge $\{P_1, \dots, P_n\}$ der Ecken aller T_j heißt die Knotenmenge der Triangulation.

Eine Finite-Elemente-Teilraum der Ordnung l ist dann definiert durch

$$V_h = \{z \in C(\bar{G}) : z|_{T_j} \text{ Polynom vom Grad } l, z|_{\partial G} = 0\}$$

mit festem l . Für $l = 1$ ergeben sich stückweise lineare stetige Funktionen. Für Finite-Elemente-Räume lassen sich problemlos Basisfunktionen mit kleinem Träger wählen, die Steifigkeitsmatrix ist dann dünn besetzt, hat aber wie bei Differenzenverfahren für $n \geq 2$ erhebliche Bandbreite. Daher verwendet man zur Lösung von (9.10) iterative Löser.

9.2 Ergänzung: Parabolische Randwertprobleme

Als einfaches Modellproblem betrachten wir die Wärmeleitungsgleichung

$$u_t(t, x) - \Delta u(t, x) = f(t, x), \quad \forall (t, x) \in]0, T[\times G$$

zusammen mit der Anfangsbedingung

$$u(0, x) = u_0(x) \quad \forall x \in G$$

und der Randbedingung

$$u(t, x) = 0 \quad \forall (t, x) \in]0, T[\times \partial G.$$

Eine gängige Technik zur numerischen Diskretisierung ist die sogenannte *Linienmethode*: Wir diskretisieren zunächst für festes t bezüglich x zum Beispiel durch ein Differenzenverfahren oder eine Finite-Elemente-Methode. Dies führt auf eine gewöhnliche Differentialgleichung der Form

$$\bar{u}_t(t) = -A(t)\bar{u}(t) + c(t).$$

Diese gewöhnliche Differentialgleichung ist im allgemeinen steif und kann nun mit geeigneten Verfahren numerisch gelöst werden, siehe Abschnitt 7.2.

Kapitel 10

Verfahren zur Eigenwert- und Eigenvektorberechnung

10.1 Eigenwertprobleme

In vielen technischen und physikalischen Problemen, etwa bei der Untersuchung des Schwingungsverhaltens von mechanischen oder elektrischen Systemen, ist es von Bedeutung, die Eigenwerte und Eigenvektoren einer Matrix $A \in \mathbb{C}^{n,n}$ zu bestimmen.

10.1.1 Grundlagen

Definition 10.1.1 Eine Zahl $\lambda \in \mathbb{C}$ heißt Eigenwert einer Matrix $A \in \mathbb{C}^{n,n}$, wenn es einen Vektor $x \in \mathbb{C}^n$, $x \neq 0$ gibt mit

$$Ax = \lambda x.$$

Jeder solche Vektor $x \in \mathbb{C}^n$ heißt (Rechts-)Eigenvektor zum Eigenwert λ . Die Menge $\sigma(A)$ aller Eigenwerte von A heißt Spektrum von A . \square

Der Unterraum

$$\text{Eig}_A(\lambda) := \{x \in \mathbb{C}^n : (A - \lambda I)x = 0\}$$

ist der *Eigenraum* von A zum Eigenwert λ . Seine Dimension

$$\gamma(\lambda) := \dim \text{Eig}_A(\lambda) = n - \text{Rang}(A - \lambda I)$$

ist die *geometrische Vielfachheit* von λ und gibt die Maximalzahl linear unabhängiger Eigenvektoren zu λ an.

Offensichtlich ist λ genau dann Eigenwert von A , wenn gilt

$$\chi(\lambda) := \det(A - \lambda I) = 0,$$

also wenn λ Nullstelle des *charakteristischen Polynoms* $\chi(\mu)$ von A ist. χ ist ein Polynom n -ten Grades und hat die Form

$$\chi(\mu) = (-1)^n \mu^n + (-1)^{n-1} \mu^{n-1} \text{spur}(A) + \dots + \det(A).$$

Sind $\lambda_1, \dots, \lambda_k$ die verschiedenen Nullstellen von χ (d.h. die verschiedenen Eigenwerte von A) mit Vielfachheiten $\nu_i, i = 1, \dots, k$, so gilt $\nu_1 + \dots + \nu_k = n$ und χ hat die Linearfaktorzerlegung

$$\chi(\mu) = (-1)^n (\mu - \lambda_1)^{\nu_1} \dots (\mu - \lambda_k)^{\nu_k}.$$

Man nennt $\nu(\lambda_i) = \nu_i$ die *algebraische Vielfachheit* von λ_i . Es ist nicht schwer zu zeigen, dass immer gilt

$$\gamma(\lambda_i) \leq \nu(\lambda_i).$$

Wir fassen einige grundlegende Eigenschaften von Eigenwerten und Eigenvektoren zusammen:

Proposition 10.1.2 Sei $A \in \mathbb{C}^{n,n}$ ein beliebig. Dann gilt:

- Ist λ Eigenwert von A , so ist λ Eigenwert von A^T und $\bar{\lambda}$ Eigenwert von $A^H := \bar{A}^T$.
- Für jede nichtsinguläre Matrix $T \in \mathbb{C}^{n,n}$ hat die zu A ähnliche Matrix $B := T^{-1}AT$ dasselbe charakteristische Polynom und dieselben Eigenwerte wie A . Ist x Eigenvektor von A , so ist $y := T^{-1}x$ Eigenvektor von B .
- Ist A hermitesch, also $A^H = A$ mit $A^H := \bar{A}^T$, dann hat A lauter reelle Eigenwerte. Ist A unitär, also $A^H = A^{-1}$, so gilt $|\lambda| = 1$ für jeden Eigenwert λ .

Eine Matrix $A \in \mathbb{C}^{n,n}$ heißt *diagonalisierbar*, wenn sie n linear unabhängige Eigenvektoren x_1, \dots, x_n besitzt. Die zugehörige Matrix $T := (x_1, \dots, x_n)$ ist dann invertierbar und mit den Eigenwerten λ_i zu x_i gilt

$$T^{-1}AT = \text{diag}(\lambda_1, \dots, \lambda_n) =: D.$$

Tatsächlich haben wir

$$AT = (\lambda_1 x_1, \dots, \lambda_n x_n) = TD.$$

Eine wichtige Rolle spielen *hermitesche Matrizen* $A \in \mathbb{C}^{n,n}$, d.h. $A^H = A$, und mithin *reelle symmetrische Matrizen*. Man kann recht einfach zeigen, dass eine hermitesche Matrix $A \in \mathbb{C}^{n,n}$, immer *diagonalisierbar* ist mit einer *unitären* Matrix $T = U$, also

$$U^{-1}AU = D, \quad U^H = U^{-1}.$$

Ist $A = A^T$ reell, dann kann $U \in \mathbb{R}^{n,n}$ orthogonal gewählt werden, also

$$U^{-1}AU = D, \quad U^T = U^{-1}.$$

Die wichtigsten Verfahren zur Berechnung von Eigenwerten und Eigenvektoren einer Matrix A nehmen zunächst eine Reihe von Ähnlichkeitstransformationen

$$A^{(0)} := A, \quad A^{(k+1)} := T_k^{-1} A^{(k)} T_k, \quad k = 0, 1, \dots$$

vor, um A in eine Matrix einfacherer Gestalt zu transformieren, deren Eigenwerte und Eigenvektoren leichter zu bestimmen sind.

10.1.2 Grundkonzepte numerischer Verfahren

Die im folgenden besprochenen numerischen Verfahren zur Berechnung von Eigenwerten und Eigenvektoren lassen sich in zwei Klassen einordnen. Die eine beruht auf der Vektoriteration, die andere auf der Anwendung von Ähnlichkeitstransformationen.

Vektoriteration

Bei der ersten Klasse von Verfahren handelt es sich um Vektoriterationen, die allgemein von der Form sind

$$x^{(k+1)} = \frac{Bx^{(k)}}{\|Bx^{(k)}\|}, \quad k = 0, 1, \dots$$

mit einem Startvektor $x^{(0)}$, einer Iterationsmatrix B und einer Vektornorm $\|\cdot\|$.

Ähnlichkeitstransformation auf einfachere Gestalt

Nach Proposition 10.1.2 bleiben die Eigenwerte einer Matrix A bei einer Ähnlichkeitstransformation $B = T^{-1}AT$ unverändert und aus einem Eigenvektor y von B erhält man durch $x = Ty$ einen Eigenvektor der Ausgangsmatrix A .

Es liegt daher nahe, A durch Ähnlichkeitstransformationen

$$(10.1) \quad A^{(0)} := A \rightarrow A^{(1)} \rightarrow \dots, \quad A^{(k+1)} = T_k^{-1} A^{(k)} T_k$$

in eine einfachere Form zu überführen, für die die Bestimmung von Eigenwerten und Eigenvektoren einfacher ist. Wir betrachten hier nur das QR-Verfahren, das eines der schnellsten Verfahren zur Lösung von Eigenwertproblemen darstellt.

QR-Verfahren: Beim QR-Verfahren wird durch Anwendung unitärer Matrizen T_i erreicht, dass die Elemente von $A^{(k)}$ im strikten unteren Dreieck gegen null konvergieren. Die Diagonaleinträge von $A^{(k)}$ konvergieren wiederum gegen die Eigenwerte von A .

10.1.3 Störungstheorie für Eigenwertprobleme

Bei oberen oder unteren Dreiecksmatrizen sind die Eigenwerte nichts anderes als die Diagonalelemente. Wir haben bereits angedeutet, dass das QR-Verfahren durch Ähnlichkeitstransformationen den Außerdiagonalteil bzw. das strikte untere Dreieck reduzieren. Störungsergebnisse für Eigenwerte liefern unter anderem Schranken, wie gut die Diagonalelemente mit den Eigenwerten übereinstimmen.

Wir haben das folgende fundamentale Resultat.

Satz 10.1.3 *Bezeichnet $\lambda_i(A)$, $i = 1, \dots, n$, die nach Betrag aufsteigend angeordneten Eigenwerte einer Matrix $A \in \mathbb{C}^{n,n}$, dann sind die Abbildungen*

$$A \in \mathbb{C}^{n,n} \mapsto \lambda_i(A), \quad i = 1, \dots, n$$

stetig. Eigenwerte hängen also stetig von der Matrix ab.

Beweis: Siehe zum Beispiel Werner [We92]. \square

Ein wichtiges Einschließungskriterium für Eigenwerte erhält man durch die *Gershgorin-Kreise*:

Satz 10.1.4 *Es sei $A = (a_{ij}) \in \mathbb{C}^{n,n}$ beliebig.*

a) *Es gilt*

$$\sigma(A) \subset \bigcup_{i=1}^n K_i$$

mit den Gershgorin-Kreisen

$$K_i := \left\{ \mu \in \mathbb{C} : |\mu - a_{ii}| \leq \sum_{\substack{j=1 \\ j \neq i}}^n |a_{ij}| \right\}, \quad i = 1, \dots, n.$$

b) *Ist die Vereinigung G_1 von k Gershgorin-Kreisen disjunkt von der Vereinigung G_2 der restlichen $n - k$ Gershgorin-Kreise, dann enthält G_1 genau k Eigenwerte und G_2 genau $n - k$ Eigenwerte von A .*

Das folgende Resultat gilt für diagonalisierbare Matrizen:

Satz 10.1.5 (Bauer/Fike)

Es sei $A \in \mathbb{C}^{n,n}$ diagonalisierbar, also

$$T^{-1}AT = \text{diag}(\lambda_1, \dots, \lambda_n) =: D.$$

Dann gilt für jede Matrix $\Delta A \in \mathbb{C}^{n,n}$

$$\forall \mu \in \sigma(A + \Delta A) : \min_{i=1,\dots,n} |\mu - \lambda_i| \leq \text{cond}_2(T) \|\Delta A\|_2.$$

Hierbei ist $\|\cdot\|_2$ die von der euklidischen Norm induzierte Matrix-Norm und $\text{cond}_2(T) := \|T\|_2 \|T^{-1}\|_2$ die zugehörige Kondition von T .

Bemerkung: Ist A hermitesch, so kann T unitär gewählt werden und es gilt $\text{cond}_2(T) = 1$.

10.2 Die Vektoriteration

10.2.1 Definition und Eigenschaften der Vektoriteration

Definition 10.2.1 Für eine Matrix $B \in \mathbb{C}^{n,n}$ ist die zugehörige Vektoriteration gegeben durch

$$(10.2) \quad z^{(k+1)} = \frac{1}{\|Bz^{(k)}\|} Bz^{(k)}, \quad k = 0, 1, \dots$$

mit einem Startvektor $z^{(0)} \in \mathbb{C}^n \setminus \{0\}$.

Bei geeigneter Wahl von B ergeben sich hieraus Näherungen $z^{(k)}$ für einen Eigenvektor zu einem Eigenwert λ . Eine Eigenwertnäherung für λ erhalten wir dann durch den Rayleigh-quotienten

$$R(z^{(k)}, B) = \frac{(z^{(k)})^H B z^{(k)}}{(z^{(k)})^H z^{(k)}}.$$

Wir untersuchen die grundlegenden Eigenschaften für eine diagonalisierbare Matrix B mit Eigenwerten $\lambda_1, \dots, \lambda_n$. Wir sagen, dass ein Vektor $x \in \mathbb{C}^n$ einen Anteil in $\text{Eig}_B(\lambda_i)$ hat, falls in der eindeutigen Darstellung

$$x = u + v, \quad u \in \text{Eig}_B(\lambda_i), \quad v \in \bigoplus_{\lambda_j \neq \lambda_i} \text{Eig}_B(\lambda_j)$$

gilt $u \neq 0$. u ist der Anteil von x in $\text{Eig}_B(\lambda_i)$.

Satz 10.2.2 Es sei $B \in \mathbb{C}^{n,n}$ diagonalisierbar mit Eigenwerten $\lambda_1, \dots, \lambda_n$,

$$\lambda_1 = \dots = \lambda_r, \quad |\lambda_r| > |\lambda_{r+1}| \geq \dots \geq |\lambda_n|$$

mit $r < n$. Falls der Startvektor $z^{(0)}$ einen Anteil in $\text{Eig}_B(\lambda_1)$ besitzt, gilt für die Vektoriteration (10.2)

$$R(z^{(k)}, B) = \frac{(z^{(k)})^H B z^{(k)}}{(z^{(k)})^H z^{(k)}} = \lambda_1 + O(q^k) \quad \text{für } k \rightarrow \infty, \quad q = \frac{|\lambda_{r+1}|}{|\lambda_1|} < 1.$$

Zudem gilt

$$z^{(k)} = \frac{\lambda_1^k}{|\lambda_1|^k} \frac{x_1}{\|x_1\|} + O(q^k)$$

mit einer beliebigen Vektornorm $\|\cdot\|$, wobei x_1 den Anteil von $z^{(0)}$ in $\text{Eig}_B(\lambda_1)$ bezeichnet.

Beweis: Wir können genausogut die nicht normierte Folge $\tilde{z}^{(k+1)} = B\tilde{z}^{(k)}$, $\tilde{z}^{(0)} = z^{(0)}$ betrachten. Es gilt dann $z^{(k)} = \tilde{z}^{(k)} / \|\tilde{z}^{(k)}\|$.

Es gibt eine Darstellung der Form $z^{(0)} = x_1 + \sum_{j=r+1}^n x_j$ mit $x_j \in \text{Eig}_B(\lambda_j)$, $x_1 \neq 0$. Einsetzen in $\tilde{z}^{(k+1)} = B\tilde{z}^{(k)}$ ergibt

$$(10.3) \quad \tilde{z}^{(k)} = B^k z^{(0)} = \lambda_1^k x_1 + \sum_{j=r+1}^n \lambda_j^k x_j = \lambda_1^k \left(x_1 + \sum_{j=r+1}^n \left(\frac{\lambda_j}{\lambda_1} \right)^k x_j \right), \quad k \geq 0.$$

Dies liefert

$$z^{(k)} = \lambda_1^k (x_1 + O(q^k))$$

und somit

$$\begin{aligned} (\tilde{z}^{(k)})^H B \tilde{z}^{(k)} &= (\tilde{z}^{(k)})^H \tilde{z}^{(k+1)} = \bar{\lambda}_1^k \lambda_1^{k+1} (x_1 + O(q^k))^H (x_1 + O(q^k)) \\ &= \lambda_1 |\lambda_1|^{2k} (\|x_1\|_2^2 + O(q^k)) \\ (\tilde{z}^{(k)})^H \tilde{z}^{(k)} &= \bar{\lambda}_1^k \lambda_1^k (x_1 + O(q^k))^H (x_1 + O(q^k)) = |\lambda_1|^{2k} (\|x_1\|_2^2 + O(q^k)). \end{aligned}$$

Wir erhalten

$$R(z^{(k)}, B) = R(\tilde{z}^{(k)}, B) = \lambda_1 \frac{\|x_1\|_2^2 + O(q^k)}{\|x_1\|_2^2 + O(q^k)} = \lambda_1 + O(q^k).$$

Analog haben wir

$$z^{(k)} = \frac{\tilde{z}^{(k)}}{\|\tilde{z}^{(k)}\|} = \frac{\lambda_1^k (x_1 + O(q^k))}{|\lambda_1|^k (\|x_1\| + O(q^k))} = \frac{\lambda_1^k}{|\lambda_1|^k} \frac{x_1}{\|x_1\|} + O(q^k)$$

□

Bemerkung: Selbst wenn $z^{(0)}$ keinen Anteil in $\text{Eig}_B(\lambda_1)$ hat, was bei "genügend allgemeiner" Wahl vom $z^{(0)}$ unwahrscheinlich ist, so stellt sich in der Praxis diese Situation durch den Einfluß von Rundungsfehlern ein. □

Im Falle hermitescher Matrizen erhält man lineare Konvergenzrate q^2 des Rayleigh-Quotienten gegen λ_1 .

Satz 10.2.3 Sei $B \in \mathbb{C}^{n,n}$ hermitesch. Dann gilt unter den Voraussetzungen von Satz 10.2.2 für den Rayleigh-Quotienten die Konvergenzaussage

$$R(z^{(k)}, B) = \frac{(z^{(k)})^H B z^{(k)}}{(z^{(k)})^H z^{(k)}} = \lambda_1 + O(q^{2k}) \quad \text{für } k \rightarrow \infty \text{ mit } q = \frac{|\lambda_{r+1}|}{|\lambda_1|} < 1.$$

10.2.2 Die Vektoriterationen nach v. Mises und Wielandt

Sei $A \in \mathbb{C}^{n,n}$ gegeben. Unterschiedliche Varianten der Vektoriteration entstehen durch die Wahl der Iterationsmatrix B .

Einfache Vektoriteration nach von Mises

Die einfache Vektoriteration erhält man durch die naheliegende Wahl $B = A$. Die Konvergenzeigenschaften können dann unmittelbar Satz 10.2.2 bzw. 10.2.3 entnommen werden.

Inverse Vektoriteration von Wielandt

Offensichtliche Nachteile der Vektoriteration sind die langsame Konvergenz bei schlechter Trennung der Eigenwerte und die Einschränkung auf die Bestimmung des betragsmäßig größten Eigenwerts. Dies kann durch die inverse Vektoriteration von Wielandt vermieden werden. Man braucht hierzu eine gute Näherung μ eines Eigenwerts λ_j , so dass

$$|\lambda_j - \mu| \ll |\lambda_i - \mu|, \quad \text{für } \lambda_i \neq \lambda_j.$$

Dann hat für $\mu \neq \lambda_j$ die Matrix $B = (A - \mu I)^{-1}$ die Eigenwerte

$$\mu_i = \frac{1}{\lambda_i - \mu},$$

wobei $|\mu_j| \gg |\mu_i|$ für alle $\mu_i \neq \mu_j$. Ferner ist x_j genau dann Eigenvektor von B zum Eigenwert μ_j , wenn x_j Eigenvektor von A zum Eigenwert λ_j ist.

Die zugehörige inverse Iteration von Wielandt lautet dann

$$z^{(k+1)} = \frac{\hat{z}^{(k+1)}}{\|\hat{z}^{(k+1)}\|} \quad \text{mit } \hat{z}^{(k+1)} = (A - \mu I)^{-1} z^{(k)}.$$

In der Praxis bestimmt man nicht $(A - \mu I)^{-1}$, sondern implementiert die Iteration in der Form

$$\text{Löse } (A - \mu I)\hat{z}^{(k+1)} = z^{(k)} \quad \text{und setze } z^{(k+1)} = \frac{\hat{z}^{(k+1)}}{\|\hat{z}^{(k+1)}\|}.$$

Die inverse Iteration von Wielandt hat dann im Falle

$$q := \max_{1 \leq i \leq n, i \neq j} \frac{|\lambda_j - \mu|}{|\lambda_i - \mu|} < 1$$

nach Satz 10.2.2 die Konvergenzeigenschaften

$$R(z^{(k)}, (A - \mu I)^{-1}) = \frac{(z^{(k)})^H z^{(k+1)}}{(z^{(k)})^H z^{(k)}} = \frac{1}{\lambda_j - \mu} + O(q^k),$$

$$z^{(k)} = \frac{|\lambda_j - \mu|^k}{(\lambda_j - \mu)^k} \frac{x_j}{\|x_j\|} + O(q^k),$$

wobei x_j den Anteil von $z^{(0)}$ in $\text{Eig}_A(\lambda_j) = \text{Eig}_{(A-\mu I)^{-1}}(1/(\lambda_j - \mu))$ bezeichnet. Ist A zudem hermitesch, so erfüllt der Rayleigh-Quotient nach Satz 10.2.3

$$R(z^{(k)}, (A - \mu I)^{-1}) = \frac{(z^{(k)})^H z^{(k+1)}}{(z^{(k)})^H z^{(k)}} = \frac{1}{\lambda_j - \mu} + O(q^{2k}).$$

10.3 Das QR-Verfahren

Das im folgenden beschriebene QR-Verfahren von Francis bildet die Basis sehr leistungsfähiger Verfahren zur Eigenwert- und Eigenvektorberechnung. Ausgehend von einer Matrix $A^{(1)} = A \in \mathbb{C}^{n,n}$ führt man beim QR-Verfahren unitäre Ähnlichkeitstransformationen folgender Form durch:

Algorithmus 6 QR-Verfahren

Sei $A \in \mathbb{C}^{n,n}$ eine gegebene Matrix.

0. Setze $A^{(1)} := A$.

1. Für $l = 1, 2, \dots$: Berechne

$$(10.4) \quad \begin{aligned} A^{(l)} &:= Q_l R_l, & Q_l \in \mathbb{C}^{n,n} \text{ unitär, } & R_l \in \mathbb{C}^{n,n} \text{ obere Dreiecksmatrix,} \\ A^{(l+1)} &:= R_l Q_l. \end{aligned}$$

In jedem Schritt ist also die Berechnung einer QR-Zerlegung

$$A^{(l)} = Q_l R_l, \quad R_l \in \mathbb{C}^{n,n} \text{ obere Dreiecksmatrix, } \quad Q_l \in \mathbb{C}^{n,n} \text{ unitär, also } Q_l^H = Q_l^{-1}$$

erforderlich. Eine solche Zerlegung kann mit Hilfe des Householder-Verfahrens berechnet werden, das wir in 6.3.4 kurz beschreiben.

10.3.1 Grundlegende Eigenschaften des QR-Verfahrens

Wir beginnen mit der offensichtlichen Feststellung, dass (10.4) tatsächlich eine Folge unitär ähnlicher Matrizen $A^{(l)}$ erzeugt.

Lemma 10.3.1 *Es seien Q_l und R_l von Algorithmus 6 erzeugt. Dann gilt mit den Bezeichnungen $Q_{1\dots l} := Q_1 Q_2 \cdots Q_l$, $R_{l\dots 1} := R_l R_{l-1} \cdots R_1$*

$$A^{(l+1)} = Q_l^{-1} A^{(l)} Q_l = Q_{1\dots l}^{-1} A Q_{1\dots l}, \quad l = 1, 2, \dots$$

Beweis: Wegen (10.4) ist $R_l = Q_l^{-1}A^{(l)}$ und daher

$$A^{(l+1)} = R_l Q_l = Q_l^{-1}A^{(l)}Q_l.$$

Induktiv ergibt sich

$$A^{(l+1)} = Q_l^{-1} \cdots Q_1^{-1}A^{(1)}Q_1 \cdots Q_l = Q_{1\dots l}^{-1}AQ_{1\dots l}.$$

□

10.3.2 Konvergenz des QR-Verfahrens

Wir geben zunächst ein Resultat für Matrizen mit betragsmäßig getrennten Eigenwerten an. Unter gewissen Voraussetzungen konvergiert dann die vom QR-Verfahren generierte Folge $A^{(l)}$ nach unitärer Diagonalskalierung der Form $S_l^{-1}A^{(l)}S_l$ gegen eine obere Dreiecksmatrix U , wobei die Konvergenzgeschwindigkeit von der Trennung der Beträge der Eigenwerte abhängt.

Satz 10.3.2 Die Matrix $A \in \mathbb{C}^{n,n}$ sei regulär mit betragsmäßig getrennten Eigenwerten $\lambda_1, \dots, \lambda_n$,

$$|\lambda_1| > |\lambda_2| > \dots > |\lambda_n|.$$

Weiter seien v_1, \dots, v_n zugehörige Eigenvektoren und die Inverse der Matrix $T = (v_1, \dots, v_n)$ besitze ohne Zeilenvertauschung eine LR-Faktorisierung. Dann gilt für das in Algorithmus 6 angegebene QR-Verfahren

$$A^{(l)} = S_l U S_l^{-1} + O(q^{l-1}) \quad \text{für } l \rightarrow \infty, \quad q := \max_{j=1, \dots, n-1} \left| \frac{\lambda_{j+1}}{\lambda_j} \right|$$

mit einer oberen Dreiecksmatrix

$$U = \begin{pmatrix} \lambda_1 & * & \cdots & * \\ & \ddots & \ddots & \vdots \\ & & \ddots & * \\ & & & \lambda_n \end{pmatrix}$$

und unitären Phasenmatrizen $S_l = \text{diag}(\sigma_1^{(l)}, \dots, \sigma_n^{(l)})$, $|\sigma_i^{(l)}| = 1$. Insbesondere gilt mit den Diagonaleinträgen $a_{11}^{(l)}, \dots, a_{nn}^{(l)}$ von $A^{(l)}$

$$|a_{ii}^{(l)} - \lambda_i| = O(q^{l-1}).$$

Beweis: Siehe zum Beispiel Plato [PI00]. □

Bemerkungen:

- Hat T^{-1} lediglich eine LR -Faktorisierung mit Zeilenvertauschungen, dann konvergiert das QR -Verfahren nach wie vor, die Eigenwerte erscheinen in der Diagonale der Grenzmatrix U jedoch unter Umständen in anderer Reihenfolge.
- Sind nicht alle Eigenwerte betragsmäßig getrennt, also etwa

$$|\lambda_1| > \dots > |\lambda_r| = |\lambda_{r+1}| > \dots > |\lambda_n|,$$

was zum Beispiel eintritt, wenn eine reelle Matrix A konjugiert komplexe Eigenwerte hat, dann konvergiert $S_l^{-1}A^{(l)}S_l$ mit Phasenmatrizen S_l außerhalb des mit \times markierten Bereichs gegen eine Matrix der Form

$$\begin{pmatrix} \lambda_1 & \cdots & * & \times & \times & * & \cdots \\ & \ddots & \vdots & \vdots & \vdots & \vdots & \\ & & \lambda_{r-1} & \times & \times & * & \cdots \\ & & & \times & \times & * & \cdots \\ & & & \times & \times & * & \cdots \\ & & & & & \lambda_{r+2} & \\ & & & & & & \ddots \\ & & & & & & & \lambda_n \end{pmatrix}$$

Die Eigenwerte des Blocks $\begin{pmatrix} a_{r,r}^{(l)} & a_{r,r+1}^{(l)} \\ a_{r+1,r}^{(l)} & a_{r+1,r+1}^{(l)} \end{pmatrix}$ konvergieren gegen λ_r und λ_{r+1} .

- Die Konvergenz des QR -Verfahrens ist sehr langsam, wenn die Trennung der Eigenwerte schlecht ist. Die Konvergenz der letzten Zeile gegen $(0, \dots, 0, \lambda_n)$ kann durch *Shift*-Techniken entscheidend verbessert werden, auf die wir nun kurz eingehen.

10.3.3 Shift-Techniken

Eine genauere Analyse zeigt, dass die letzte Zeile von $A^{(l)}$ die Form hat $(O(|\lambda_n/\lambda_{n-1}|^{l-1}), a_{nn}^{(l)})$. Ist also $|\lambda_n| \ll |\lambda_{n-1}|$, dann konvergiert $a_{n,j}^{(l)}$, $1 \leq j < n$ sehr schnell gegen 0 und $a_{nn}^{(l)}$ sehr schnell gegen λ_n . Nach genauer Bestimmung von λ_n kann man dann mit dem $(n-1) \times (n-1)$ -Block von $A^{(l)}$ zur Bestimmung von λ_{n-1} fortfahren.

Um die Trennung von λ_n und λ_{n-1} zu verbessern, wendet man das QR -Verfahren in jedem Schritt auf $A^{(l)} - \mu_l I$ an mit $\mu_l \approx \lambda_n$ und korrigiert den Shift anschließend. Anstelle von (10.4) berechnet man also mit einem *Shift* $\mu_l \approx \lambda_n$

$$A^{(l)} - \mu_l I =: Q_l R_l, \quad Q_l \in \mathbb{C}^{n,n} \text{ unitär}, \quad R_l \in \mathbb{C}^{n,n} \text{ obere Dreiecksmatrix}, \\ A^{(l+1)} := R_l Q_l + \mu_l I.$$

Man prüft leicht nach, dass wieder gilt $A^{(l+1)} = Q_l^{-1} A^{(l)} Q_l$.

Verbreitete Shift-Strategie: Eine effiziente Shift-Strategie erhält man, wenn man μ_l als denjenigen Eigenwert von $\begin{pmatrix} a_{n-1,n-1}^{(l)} & a_{n-1,n}^{(l)} \\ a_{n,n-1}^{(l)} & a_{n,n}^{(l)} \end{pmatrix}$ wählt, der am nächsten bei $a_{n,n}^{(l)}$ liegt. Im Zweifelsfall wähle den mit positivem Imaginärteil.

Das QR-Verfahren mit Shift liefert recht schnell eine Matrix $A^{(l)}$, deren letzte Zeile auf hohe Genauigkeit mit $(0, \dots, 0, \lambda_n)$ übereinstimmt. Man wendet nun das QR-Verfahren mit Shift auf den oberen linken $(n-1) \times (n-1)$ -Block von $A^{(l)}$ zur Bestimmung von λ_{n-1} an und so fort.

Bemerkung: Das QR-Verfahren mit Shift gilt zur Zeit als eines der besten Iterationsverfahren zur Lösung des vollständigen Eigenwertproblems.

10.3.4 Berechnung einer QR-Zerlegung

Wir geben zum Abschluss ein numerisches Verfahren an zur Berechnung einer

QR-Zerlegung:

Für $B \in \mathbb{C}^{n,n}$ bestimme eine unitäre Matrix $Q \in \mathbb{C}^{n,n}$ und eine obere Dreiecksmatrix $R \in \mathbb{C}^{n,n}$ mit

$$(10.5) \quad B = QR.$$

Householder-Verfahren zur Berechnung einer QR-Zerlegung:

Beim Householder-Verfahren berechnet man (10.5) in $n-1$ Schritten:

Initialisierung:

$$B^{(0)} := B = \left(\begin{array}{c|cc} b^{(0)} & * & \dots \\ \hline & \vdots & \\ & * & \dots \end{array} \right)$$

Schritt 0: Bestimme eine unitäre Matrix T_0 (siehe (10.7), (10.8)) mit

$$B^{(1)} := T_0 B^{(0)} = \left(\begin{array}{c|cc} * & * & * & \dots \\ \hline 0 & * & * & \dots \\ \vdots & \vdots & \vdots & \\ 0 & * & * & \dots \end{array} \right) =: \left(\begin{array}{c|c|c} B_1^{(1)} & & B_2^{(1)} \\ \hline 0 & & \\ \vdots & b^{(1)} & B_3^{(1)} \\ 0 & & \end{array} \right)$$

Schritt 1: Bestimme eine unitäre Matrix T_1 (siehe (10.7), (10.8)) mit

$$B^{(2)} := T_1 B^{(1)} = \left(\begin{array}{cc|cc} * & * & * & * & \cdots \\ 0 & * & * & * & \cdots \\ \hline 0 & 0 & * & * & \cdots \\ \vdots & \vdots & \vdots & \vdots & \\ 0 & 0 & * & * & \cdots \end{array} \right) =: \left(\begin{array}{cc|c|c} B_1^{(2)} & & B_2^{(2)} & \\ \hline 0 & 0 & & \\ \vdots & \vdots & b^{(2)} & \\ 0 & 0 & & B_3^{(2)} \end{array} \right)$$

Schritt $k, k = 2, \dots, n - 2$: Bestimme eine unitäre Matrix T_k (siehe (10.7), (10.8)) mit

$$(10.6) \quad B^{(k+1)} := T_k B^{(k)} = \left(\begin{array}{ccc|cc} * & \cdots & * & * & \cdots \\ & \ddots & \vdots & & \\ 0 & & * & * & \cdots \\ \hline 0 & \cdots & 0 & * & \cdots \\ \vdots & & \vdots & \vdots & \\ 0 & \cdots & 0 & * & \cdots \end{array} \right) \left. \begin{array}{l} \vphantom{B^{(k+1)}} \\ \vphantom{B^{(k+1)}} \\ \vphantom{B^{(k+1)}} \end{array} \right\} \begin{array}{l} k + 1 \\ n - (k + 1) \end{array}$$

$$= \left(\begin{array}{ccc|c|c} B_1^{(k+1)} & & B_2^{(k+1)} & & \\ \hline 0 & \cdots & 0 & & \\ \vdots & & \vdots & b^{(k+1)} & B_3^{(k+1)} \end{array} \right).$$

Ergebnis: $R := B^{(n-1)}, Q := (T_{n-2} \cdots T_0)^H = T_0^H \cdots T_{n-2}^H$.

Rechtfertigung des Verfahrens:

Dann gilt tatsächlich

$R = B^{(n-1)}$ = obere Dreiecksmatrix, $Q = T_0^H \cdots T_{n-2}^H$ unitär als Produkt unitärer Matrizen und

$$R = B^{(n-1)} = \underbrace{T_{n-2} \cdots T_0}_{=Q^H} B = Q^H B, \quad \text{also} \quad QR = B.$$

Berechnung der Transformationen T_k :

Es bleibt, die Berechnung von T_k anzugeben. Beim Householder-Verfahren wählt man jeweils T_k von der Form

$$(10.7) \quad T_k = \left(\begin{array}{c|c} I_k & 0 \\ \hline 0 & H_k \end{array} \right)$$

mit

$$I_k = \text{Einheitsmatrix in } \mathbb{R}^{k,k},$$

und $H_k \in \mathbb{R}^{n-k, n-k}$ als **Householder Transformation** der Form

(10.8)

$$H_k = I - \frac{2}{w_k^H w_k} w_k w_k^H, \quad w_k = b^{(k)} + \sigma_k \|b^{(k)}\|_2 \begin{pmatrix} 1 \\ 0 \\ \vdots \end{pmatrix}, \quad \sigma_k = \begin{cases} 1 & \text{falls } b_1^{(k)} = 0, \\ \frac{b_1^{(k)}}{|b_1^{(k)}|} & \text{sonst.} \end{cases}$$

Man kann zeigen, dass mit dieser Wahl gilt

$$H_k \text{ unitär und hermitesch, } H_k b^{(k)} = \begin{pmatrix} \omega_k \|b^{(k)}\|_2 \\ 0 \\ \vdots \end{pmatrix}, \quad \omega_k \in \mathbb{C}, \quad |\omega_k| = 1.$$

Man sieht leicht, dass dann tatsächlich jeweils $B^{(k+1)}$ die Form (10.6) hat.

Statistik

Statistische Methoden werden in allen empirischen Wissenschaften verwendet. In der "Beschreibenden Statistik" geht es zunächst darum, Beobachtungsdaten übersichtlich darzustellen und durch Berechnung von Kenngrößen (Mittelwerte, Streuungen) zu charakterisieren.

Da jedoch Beobachtungsdaten in der Regel zufallsbehaftet sind (zufällige Meßfehler bei Experimenten, Möglichkeit unterschiedlicher Ergebnisse), besteht das Risiko von Fehlschlüssen. Die sogenannte "Schließende Statistik" stellt daher Methoden bereit, bei denen diese Fehlerrisiken abgeschätzt werden können. Die Abschätzung dieser Risiken beruht auf mathematischen Modellen für zufallsabhängige Vorgänge, die in der "Wahrscheinlichkeitstheorie" behandelt werden.

Dieser Teil des Skripts basiert in Teilen auf dem Buch v. Finckenstein, Lehn, Schellhaas, Wegmann; *Arbeitsbuch für Ingenieure II*, Teubner Verlag, 2006, das als vertiefende Literatur empfohlen wird.

Kapitel 11

Grundbegriffe der Statistik und Wahrscheinlichkeitstheorie

11.1 Messreihen

Im Folgenden werden zwei Typen von *Merkmalen* betrachtet:

- *quantitativ-diskrete*, z.B. Alter in Jahren, Geschosszahl eines Gebäudes,...
Die *Merkmalausprägungen* sind dann ganze Zahlen.
- *quantitativ-stetige*, z.B. Gebäudehöhe, Temperatur,...
Die *Merkmalausprägungen* sind dann reelle Zahlen.

Am Beginn einer statistischen Untersuchung steht immer die mehrfache Beobachtung eines Merkmals. Das Beobachtungsergebnis ist dann eine *Messreihe* von n Zahlen

$$x_1, x_2, \dots, x_n.$$

Definition 11.1.1 Sei x_1, x_2, \dots, x_n eine *Messreihe*. Ordnet man die Werte der *Messreihe* der Größe nach, so entsteht die zugehörige geordnete *Messreihe*

$$x_{(1)}, x_{(2)}, \dots, x_{(n)}.$$

Sie besteht aus den gleichen Zahlen, aber so umgeordnet, dass gilt $x_{(1)} \leq x_{(2)} \leq \dots \leq x_{(n)}$.

Die empirische Verteilungsfunktion einer *Messreihe* x_1, x_2, \dots, x_n ist die Funktion

$$F(z; x_1, x_2, \dots, x_n) = \frac{\text{Zahl der } x_i \text{ mit } x_i \leq z}{n} = \frac{\max \{i : x_{(i)} \leq z\}}{n}.$$

Wählt man $r - 1$ Zahlen $a_1 < a_2 < \dots < a_{r-1}$, so entsteht die Unterteilung von \mathbb{R} in r Klassen

$$\mathbb{R} =] - \infty, a_1] \cup]a_1, a_2] \cup \dots \cup]a_{r-2}, a_{r-1}] \cup]a_{r-1}, \infty[.$$

Mit der Abkürzung $F(z) = F(z; x_1, x_2, \dots, x_n)$ ergeben sich dann die *relativen Klassenhäufigkeiten* für diese r Klassen zu

$$F(a_1), F(a_2) - F(a_1), \dots, F(a_{r-2}) - F(a_{r-1}), 1 - F(a_{r-1}).$$

Wählt man noch zwei zusätzliche Zahlen

$$a_0 < \min\{a_1, x_{(1)}\}, \quad a_r > \max\{a_{r-1}, x_{(n)}\},$$

so können die relativen Klassenhäufigkeiten in einem *Histogramm* dargestellt werden: über jedem der Intervalle $]a_{j-1}, a_j]$, $j = 1, \dots, r$, wird ein Rechteck erreicht, das die jeweilige Klassenhäufigkeit als Fläche hat.

Beispiel:

Die zur Messreihe

2.2 4.5 0.8 1.7 5.8 1.2 5.6 2.5 3.9 1.7

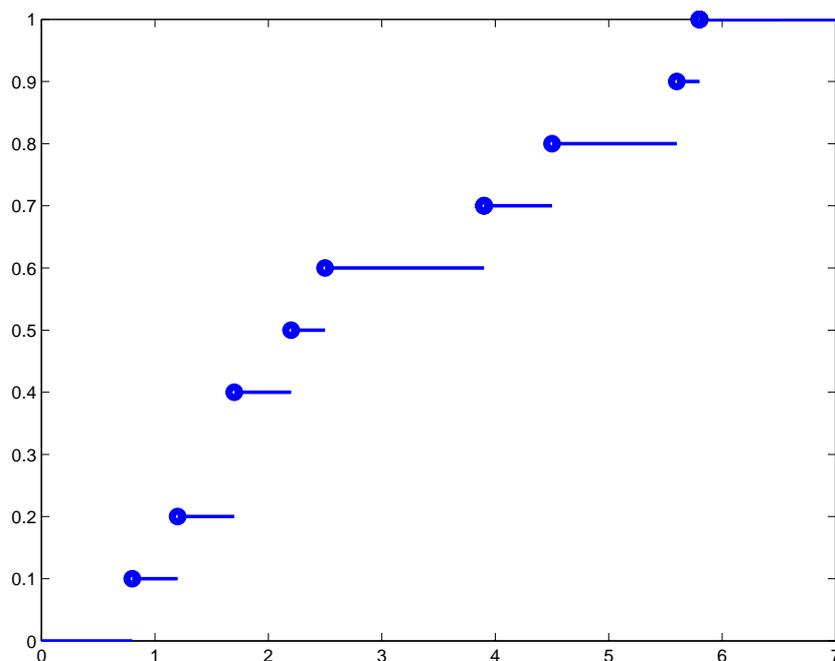
gehörige geordnete Messreihe ist

0.8 1.2 1.7 1.7 2.2 2.5 3.9 4.5 5.6 5.8.

Hierbei ist

$$x_{(1)} = x_3, \quad x_{(2)} = x_6, \quad x_{(3)} = x_{(4)} = x_4 = x_{10}, \quad x_{(5)} = x_1, \quad x_{(6)} = x_8, \\ x_{(7)} = x_9, \quad x_{(8)} = x_2, \quad x_{(9)} = x_7, \quad x_{(10)} = x_5.$$

Die empirische Verteilungsfunktion hat folgenden Graphen:



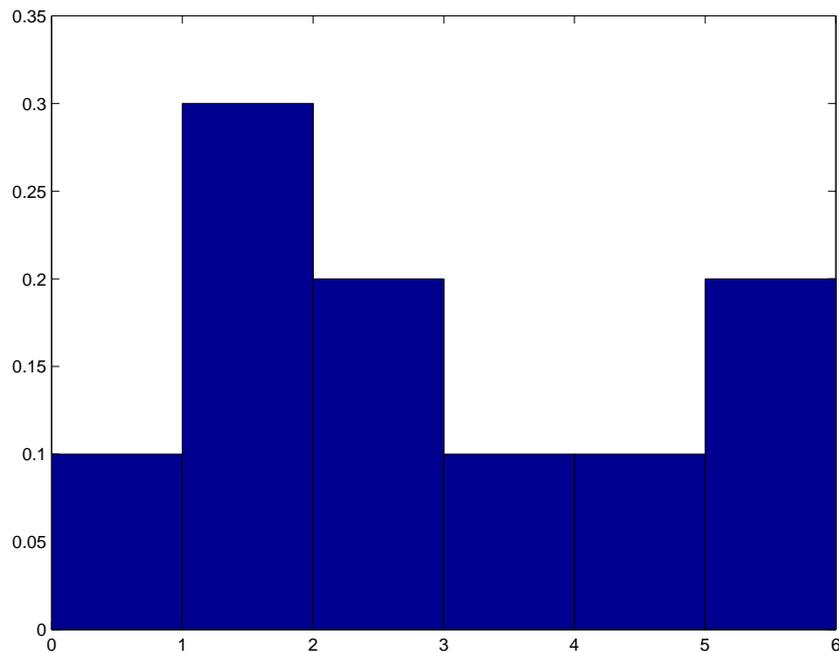
Zu der Unterteilung

$$0 < 1 < 2 < 3 < 4 < 5 < 6$$

ergeben sich die Klassenhäufigkeiten

$$\frac{1}{10}, \quad \frac{4-1}{10} = \frac{3}{10}, \quad \frac{6-4}{10} = \frac{2}{10}, \quad \frac{7-6}{10} = \frac{1}{10}, \quad \frac{8-7}{10} = \frac{1}{10}, \quad 1 - \frac{8}{10} = \frac{2}{10},$$

also das Histogramm



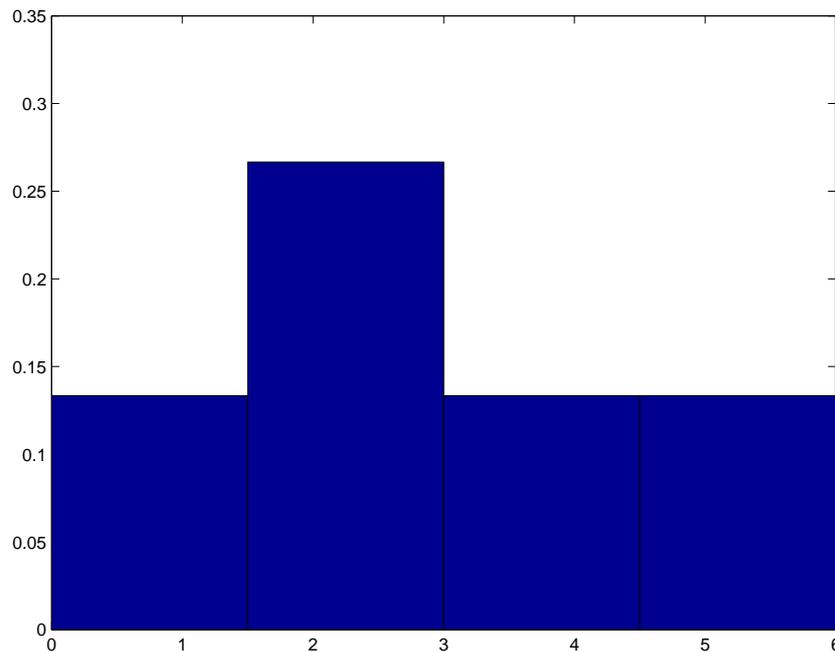
Zur Unterteilung

$$0 < 1.5 < 3 < 4.5 < 6$$

ergeben sich die Klassenhäufigkeiten

$$\frac{2}{10}, \quad \frac{6-2}{10} = \frac{4}{10}, \quad \frac{8-6}{10} = \frac{2}{10}, \quad 1 - \frac{8}{10} = \frac{2}{10},$$

mit zugehörigem Histogramm



11.2 Lage- und Streumaßzahlen

Zur Beschreibung und Charakterisierung von Messreihen dienen Lage- und Streumaßzahlen.

Sei x_1, \dots, x_n eine Messreihe.

11.2.1 Lagemaßzahlen

Beispiele für Lagemaßzahlen sind

Arithmetisches Mittel:

$$\bar{x} = \frac{1}{n}(x_1 + x_2 + \dots + x_n)$$

Median:

$$\tilde{x} = \begin{cases} x_{(\frac{n}{2})}, & \text{falls } n \text{ gerade,} \\ x_{(\frac{n+1}{2})}, & \text{falls } n \text{ ungerade.} \end{cases}$$

p -Quantil ($0 < p < 1$):

$$x_p = \begin{cases} x_{(np)}, & \text{falls } np \text{ ganzzahlig,} \\ x_{(\lceil np \rceil)}, & \text{falls } np \text{ nicht ganzzahlig.} \end{cases}$$

Hierbei ist

$$[x] = \max \{z \in \mathbb{Z} : z \leq x\} \quad (\text{Gauss'sche Klammer})$$

die größte ganze Zahl $\leq x$.

α -gestutztes Mittel ($0 < \alpha < 0.5$):

$$\bar{x}_\alpha = \frac{1}{n - 2k} (x_{(k+1)} + \dots + x_{(n-k)}), \quad k = [n\alpha].$$

Das 0.25-Quantil $x_{0.25}$ wird als *unteres Quartil*, das 0.75-Quantil $x_{0.75}$ wird als *oberes Quartil* bezeichnet.

11.2.2 Streuungsmaße

Beispiele für Streuungsmaße sind:

Empirische Varianz oder **empirische Stichprobenvarianz:**

$$s^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2$$

Empirische Streuung:

$$s = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2}$$

Spannweite:

$$v = x_{(n)} - x_{(1)}$$

Quartilabstand:

$$q = x_{0.75} - x_{0.25}.$$

11.2.3 Zweidimensionale Messreihen

Werden bei einer statistischen Erhebung zwei verschiedene Merkmale gleichzeitig ermittelt, so entstehen *zweidimensionale Messreihen*, d.h. endliche Folgen

$$(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n).$$

Analog wie oben definieren wir folgende Maßzahlen:

Arithmetische Mittel:

$$\bar{x} = \frac{1}{n} (x_1 + x_2 + \dots + x_n), \quad \bar{y} = \frac{1}{n} (y_1 + y_2 + \dots + y_n)$$

Empirische Varianzen:

$$s_x^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2, \quad s_y^2 = \frac{1}{n-1} \sum_{i=1}^n (y_i - \bar{y})^2$$

Empirische Streuungen:

$$s_x = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2}, \quad s_y = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (y_i - \bar{y})^2}$$

Weiterhin sind auch folgende Maßzahlen zwischen den x_i und y_i von Bedeutung:

Empirische Kovarianz:

$$s_{xy} = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})$$

Empirischer Korrelationskoeffizient:

$$r_{xy} = \frac{s_{xy}}{s_x s_y}.$$

Bemerkung: Es gilt immer

$$-1 \leq r_{xy} \leq 1.$$

Beweis: Sei $u = (x_i - \bar{x})_{1 \leq i \leq n}$, $v = (y_i - \bar{y})_{1 \leq i \leq n}$. Dann gilt nach der Cauchy-Schwartz-Ungleichung

$$r_{xy} = \frac{u^T v}{\|u\|_2 \|v\|_2} \in [-1, 1].$$

□

Bemerkung: Die empirische Varianz s^2 lässt sich auch nach der Formel berechnen

$$(11.1) \quad s^2 = \frac{1}{n-1} \left(\sum_{i=1}^n x_i^2 - n\bar{x}^2 \right)$$

Ebenso gilt für die empirische Kovarianz

$$(11.2) \quad s_{xy} = \frac{1}{n-1} \left(\sum_{i=1}^n x_i y_i - n\bar{x}\bar{y} \right)$$

Beweis: Es gilt

$$(n-1) s^2 = \sum_{i=1}^n (x_i - \bar{x})^2 = \sum_{i=1}^n (x_i^2 - 2x_i\bar{x} + \bar{x}^2) = \sum_{i=1}^n x_i^2 - 2n\bar{x}^2 + n\bar{x}^2 = \sum_{i=1}^n x_i^2 - n\bar{x}^2.$$

Die Formel für s_{xy} folgt ganz analog. □

Zur Veranschaulichung einer zweidimensionalen Messreihe dient das *Punktediagramm*, bei dem die Punkte (x_i, y_i) , $i = 1, \dots, n$, als Punkte in einem $x - y$ -Koordinatensystem eingetragen werden.

11.2.4 Regressionsgerade

Der Korrelationskoeffizient r_{xy} gibt Hinweise, ob die y -Werte tendenziell monoton wachsend oder monoton fallend von den x -Werten abhängen. Für diesen Zusammenhang soll nun angenommen werden, dass er sich im wesentlichen durch eine lineare Gleichung der Form

$$y = ax + b$$

beschreiben lässt. Wir nehmen also an, dass sich die Datenpunkte um eine Gerade mit der Steigung a und Achsenabschnitt b gruppieren. Wir wollen nun a und b bestimmen, damit die Gerade möglichst gut zu den Datenpunkten passt. Das Quadrat des Abstands zwischen Datenpunkt (x_i, y_i) und einem Punkt $(x_i, ax_i + b)$ auf der Geraden mit demselben x -Wert ist $(y_i - ax_i - b)^2$. Steigung a und Achsenabschnitt b der Geraden sollen nun so bestimmt werden, dass die Summe all dieser Quadrate

$$S(a, b) = \sum_{i=1}^n (y_i - ax_i - b)^2$$

minimal wird. Wir erhalten dann die sogenannte *Regressionsgerade*. Wir suchen also eine Lösung des Problems

$$(11.3) \quad \min_{(a,b) \in \mathbb{R}^2} S(a, b).$$

Bestimmung der Minimalstelle:

$$\frac{\partial S(a, b)}{\partial a} = \sum_{i=1}^n 2(y_i - ax_i - b)(-x_i) = -2 \sum_{i=1}^n (x_i y_i - ax_i^2 - bx_i) = 0.$$

$$\frac{\partial S(a, b)}{\partial b} = \sum_{i=1}^n 2(y_i - ax_i - b)(-1) = -2 \sum_{i=1}^n (y_i - ax_i - b) = 0.$$

Die zweite Gleichung ergibt

$$n\bar{y} - an\bar{x} - nb = 0,$$

also

$$b = \bar{y} - a\bar{x}.$$

Einsetzen in die erste Gleichung ergibt

$$\sum_{i=1}^n (x_i y_i - ax_i^2 - \bar{y}x_i + a\bar{x}x_i) = 0$$

und somit

$$\sum_{i=1}^n x_i y_i - n\bar{x}\bar{y} = a \left(\sum_{i=1}^n x_i^2 - n\bar{x}^2 \right).$$

Insgesamt ergibt sich für die Lösung (\hat{a}, \hat{b}) von (11.3) unter Verwendung von (11.1), (11.2):

Berechnung der Regressionsgerade:

$$y = \hat{a}x + \hat{b},$$

mit

$$\hat{a} = \frac{\sum_{i=1}^n x_i y_i - n\bar{x}\bar{y}}{\sum_{i=1}^n x_i^2 - n\bar{x}^2} = \frac{s_{xy}}{s_x^2}, \quad \hat{b} = \bar{y} - \hat{a}\bar{x}.$$

Wie bereits erwähnt, heisst die so gefundene Gerade *Regressionsgerade*. Die Abweichungen der Punkte (x_i, y_i) von der Regressionsgerade in vertikaler Richtung

$$r_i = y_i - \hat{a}x_i - \hat{b}, \quad i = 1, \dots, n$$

heissen *Residuen*. Nach kurzer Rechnung erhält man folgende

Formel für das Residuenquadrat:

$$\sum_{i=1}^n r_i^2 = \sum_{i=1}^n (y_i - \bar{y})^2 (1 - r_{xy}^2).$$

Die vertikale Abweichung von der Regressionsgerade hängt also eng mit dem Korrelationskoeffizienten r_{xy} zusammen. Für die extremen Werte $r_{xy} = 1$ bzw. $r_{xy} = -1$ verschwinden die Residuen, alle Punkte (x_i, y_i) liegen also auf der Regressionsgeraden.

Da die Werte

$$r_{xy} = \frac{s_{xy}}{s_x s_y} \quad \text{und} \quad \hat{a} = \frac{s_{xy}}{s_x^2}$$

gleiches Vorzeichen haben, ergibt sich also für $r_{xy} > 0$ eine streng monoton steigende, für $r_{xy} < 0$ eine streng monoton fallende und für $r_{xy} = 0$ eine horizontale Regressionsgerade.

Das Vorzeichen von r_{xy} gibt also den Trend der Abhängigkeit der y -Werten von den x -Werten an.

11.3 Zufallsexperimente und Wahrscheinlichkeit

11.3.1 Zufallsexperimente

Ein Vorgang, der so genau beschrieben ist, dass er als beliebig oft wiederholbar betrachtet werden kann, und dessen Ergebnisse vom Zufall abhängen, nennen wir *Zufallsexperiment*. Es wird angenommen, dass die Menge der möglichen Ergebnisse soweit bekannt ist, dass jedem Ergebnis ein Element ω einer Menge Ω zugeordnet werden kann.

Definition 11.3.1 Ω heißt Ergebnismenge, seine Elemente ω Ergebnisse. Teilmengen $A \subset \Omega$ heißen Ereignisse. Ein Ereignis $A \subset \Omega$ tritt ein, falls ein Ergebnis $\omega \in A$ beobachtet wird.

Beispiele:

1. Wurf eines Würfels: $\Omega = \{1, 2, 3, 4, 5, 6\}$. Das Ereignis $A = \{1, 3, 5\}$ tritt ein, falls eine ungerade Zahl gewürfelt wird.
2. Wurf zweier unterscheidbarer Würfel: $\Omega = \{(i, j) : i, j \in \{1, 2, 3, 4, 5, 6\}\}$. Ω hat $6 \cdot 6 = 36$ Elemente.
3. Wurf zweier nicht unterscheidbarer Würfel: $\Omega = \{(i, j) : i, j \in \{1, 2, 3, 4, 5, 6\}, i \leq j\}$. Ω hat 21 Elemente.
4. Lebensdauer eines Gerätes: $\Omega =]0, \infty[$. Das Ereignis $A = \{\omega \in \mathbb{R} : \omega > 100\}$ tritt ein, wenn das Gerät mehr als 100 Stunden fehlerfrei funktioniert.

Definition 11.3.2 Das aus zwei Ereignissen A und B zusammengesetzte Ereignis $A \cup B$ tritt ein, falls ein Ergebnis ω mit $\omega \in A$ oder $\omega \in B$ (d.h. $\omega \in A \cup B$) beobachtet wird.

Entsprechend tritt das Ereignis $A \cap B$ ein, falls ein Ergebnis ω mit $\omega \in A$ und $\omega \in B$ (d.h. $\omega \in A \cap B$) beobachtet wird.

$A^c = \Omega \setminus A$ heißt zu A komplementäres Ereignis.

Zwei Ereignisse A und B heißen unvereinbar, falls $A \cap B = \emptyset$.

Die leere Menge \emptyset heißt unmögliches Ereignis und Ω das sichere Ereignis.

Die einelementigen Mengen $\{\omega\}$ von Ω heißen Elementarereignisse.

Auch für Folgen A_1, A_2, \dots von Ereignissen definieren wir das zusammengesetzte Ereignis $\bigcup_{i=1}^{\infty} A_i$, das eintritt, wenn mindestens ein A_i eintritt, und das Ereignis $\bigcap_{i=1}^{\infty} A_i$, das eintritt, wenn alle A_i zugleich eintreten.

11.3.2 Wahrscheinlichkeit

Fragt man im Falle der Betriebsdauer eines Gerätes danach, wie wahrscheinlich es ist, dass das Gerät exakt nach 100 Stunden (keinen Augenblick früher oder später!) seinen ersten Defekt hat, dann ist dies praktisch ausgeschlossen. Fragt man jedoch danach, dass der erste Defekt zwischen 90 und 100 Stunden auftritt, also nach der Wahrscheinlichkeit des Ereignisses $A = [90, 100]$, dann ist dies eine sachgerechte Fragestellung.

Dies zeigt, dass es sinnvoll ist, die Wahrscheinlichkeit des Eintretens von Ereignissen zu betrachten. Wir haben dabei die Vorstellung, dass die Wahrscheinlichkeit $P(A)$ für das

Eintreten des Ereignisses A in der Größenordnung der relativen Häufigkeit des Eintretens von A in langen Versuchsserien liegt.

Dazu betrachten wir ein System \mathcal{A} von Ereignissen (es muss nicht die Potenzmenge $\mathcal{P}(\Omega)$, also die Menge aller Teilmengen von Ω sein!), das folgende Eigenschaften hat:

Definition 11.3.3 ein System $\mathcal{A} \subset \mathcal{P}(\Omega)$ von Ereignissen heißt σ -Algebra, wenn gilt:

- a) $\Omega \in \mathcal{A}$.
- b) Falls $A \in \mathcal{A}$, dann gilt auch $A^c \in \mathcal{A}$.
- c) Mit jeder Folge $A_1, A_2, \dots \in \mathcal{A}$ gilt auch $\bigcup_{i=1}^{\infty} A_i \in \mathcal{A}$.

Bemerkung: Sind $A, B \in \mathcal{A}$, dann ist wegen b) und c) auch

$$A \cap B = (A^c \cup B^c)^c \in \mathcal{A}.$$

□

Eine σ -Algebra erlaubt gerade die Verknüpfungen von Ereignissen, die in der Praxis nützlich sind. Um jedem Ereignis eine Wahrscheinlichkeit zuzuordnen, betrachtet man eine Abbildung $P : \mathcal{A} \rightarrow \mathbb{R}$ mit folgenden Eigenschaften:

Definition 11.3.4 Eine Abbildung $P : \mathcal{A} \rightarrow \mathbb{R}$ heißt Wahrscheinlichkeitsmaß, wenn sie den folgenden Axiomen von Kolmogorov genügt:

- a) $P(A) \geq 0$ für $A \in \mathcal{A}$,
- b) $P(\Omega) = 1$,
- c) $P\left(\bigcup_{i=1}^{\infty} A_i\right) = \sum_{i=1}^{\infty} P(A_i)$ für paarweise unvereinbare $A_1, A_2, \dots \in \mathcal{A}$.

Bemerkung: c) umfasst auch endliche disjunkte Vereinigungen $\bigcup_{i=1}^n A_i$ durch die Wahl $A_i = \emptyset, i \geq n + 1$.

Aus diesen Axiomen folgen nützliche Regeln für das Rechnen mit Wahrscheinlichkeiten von Ereignissen A, B, A_1, \dots, A_n :

$$\begin{aligned}
 P(\emptyset) &= 0, \\
 0 &\leq P(A) \leq 1, \\
 P(A^c) &= 1 - P(A), \\
 A \subset B &\implies P(A) \leq P(B), \\
 P(A \cup B) &= P(A) + P(B) - P(A \cap B), \\
 P(A_1 \cup \dots \cup A_n) &= \sum_{i=1}^n P(A_i), \quad \text{falls } A_1, \dots, A_n \text{ paarweise unvereinbar (Additivität)}.
 \end{aligned}$$

Falls die Ergebnismenge endlich ist, also $\Omega = \{\omega_1, \dots, \omega_n\}$, und man wie beim Würfelwurf annehmen kann, dass jedes Elementarereignis $\{\omega_i\}$ gleich wahrscheinlich ist, dann folgt aus der Additivität

$$P(\{\omega_i\}) = \frac{1}{n}, \quad i = 1, \dots, n$$

und für beliebige Ereignisse mit Elementzahl $\#A$ gilt

$$P(A) = \frac{\text{Elementzahl von } A}{n} = \frac{\#A}{\#\Omega}.$$

Die Annahme gleicher Wahrscheinlichkeit für die Elementarereignisse heißt *Laplace-Annahme*.

Beispiel: Drei Würfel werden geworfen. Wie groß ist die Wahrscheinlichkeit, dass die Würfelsumme 11 ist?

Wir wählen $\Omega = \{(i, j, k) : i, j, k = 1, \dots, 6\}$. Dann ist $\#\Omega = 6^3 = 216$.

A sei das Ereignis "Würfelsumme ist 11".

Möglichkeiten für die drei Summanden (der Größe nach geordnet):

$$11 = 1 + 4 + 6 = 1 + 5 + 5 = 2 + 3 + 6 = 2 + 4 + 5 = 3 + 3 + 5 = 3 + 4 + 4.$$

Wir summieren die Anzahl der Tripel auf, die auf die angegebenen Summanden führen:

$$\#A = 6 + 3 + 6 + 6 + 3 + 3 = 27.$$

Dies ergibt

$$P(A) = \frac{\#A}{\#\Omega} = \frac{27}{216} = \frac{1}{8} = 0,125.$$

11.3.3 Elementare Formeln der Kombinatorik

Zur Berechnung der Elementezahlen von Ereignissen werden häufig kombinatorische Formeln verwendet. Wir geben einige wichtige Formeln an:

Sei Ω eine Menge mit n Elementen und $k \in \mathbb{N}$.

Geordnete Probe mit Wiederholungen:

Eine k -Tupel (x_1, \dots, x_k) mit $x_i \in \Omega$, $i = 1, \dots, k$, heißt *geordnete Probe* von Ω vom Umfang k mit Wiederholungen. Es gibt

$$n^k \quad (\text{Anzahl geordneter Proben mit Wiederholungen})$$

solcher Proben (für jede Stelle gibt es n Möglichkeiten).

Geordnete Probe ohne Wiederholungen:

Eine k -Tupel (x_1, \dots, x_k) , $k \leq n$, mit $x_i \in \Omega$, $i = 1, \dots, k$, und $x_i \neq x_j$ für $i \neq j$ heißt *geordnete Probe* von Ω vom Umfang k ohne Wiederholungen. Es gibt

$$n(n-1)(n-2) \cdot \dots \cdot (n-k+1) \quad (\text{Anzahl geordneter Proben ohne Wiederholungen})$$

solcher Proben (für die erste Stelle gibt es n Möglichkeiten, für die zweite $n - 1$, usw.).

Im Fall $k = n$ spricht man von einer *Permutation* der Menge Ω . Davon gibt es

$$n! = n(n-1)(n-2) \cdot \dots \cdot 2 \cdot 1 \quad (\text{Anzahl von Permutationen})$$

Ungeordnete Probe ohne Wiederholungen:

Eine Teilmenge $\{x_1, \dots, x_k\}$, $k \leq n$, von Ω heißt *ungeordnete Probe* von Ω vom Umfang k ohne Wiederholungen. Es gibt

$$\binom{n}{k} = \frac{n(n-1)(n-2) \cdot \dots \cdot (n-k+1)}{k!} = \frac{n!}{k!(n-k)!} \quad (\text{Anzahl } k\text{-elem. Teilmengen})$$

solcher Proben (es gibt $n(n-1)(n-2) \cdot \dots \cdot (n-k+1)$ geordnete Proben, aber jeweils $k!$ bestehen aus den gleichen k Elementen).

Beispiel:

1. Wie viele Möglichkeiten gibt es, k Einsen und $n - k$ Nullen anzuordnen?

Lösung: Jede Anordnung der Einsen entspricht einer k -elementigen Teilmenge von $\{1, \dots, n\}$, welche die Positionen der Einsen angibt. Also: $\binom{n}{k}$ Möglichkeiten.

2. Beim Austeilen gemischter Karten (32 Karten, davon 4 Asse) sei A das Ereignis "die ersten drei Karten sind Ass". Dann gilt unter der Laplace-Annahme

$$P(A) = \frac{4 \cdot 3 \cdot 2 \cdot 29!}{32!} = \frac{24}{32 \cdot 31 \cdot 30} = \frac{1}{1240}.$$

11.4 Bedingte Wahrscheinlichkeit, Unabhängigkeit

11.4.1 Bedingte Wahrscheinlichkeit

Seien A, B zwei Ereignisse mit $P(B) > 0$. Oft interessiert die Wahrscheinlichkeit von A unter der Bedingung, dass B eintritt. Man definiert diese *bedingte Wahrscheinlichkeit* $P(A|B)$ von A unter der Bedingung B durch

Bedingte Wahrscheinlichkeit von A unter der Bedingung B :

$$P(A|B) = \frac{P(A \cap B)}{P(B)}.$$

Beispiel: Beim Ziehen von einem gemischten Kartenstapel (32 Karten, 4 Asse) betrachte die Ereignisse A "die zweite Karte ist ein Ass" und B "die erste Karte ist ein Ass". Dann gilt

$$P(B) = \frac{4 \cdot 31!}{32!} = \frac{1}{8}, \quad P(A \cap B) = \frac{4 \cdot 3 \cdot 30!}{32!} = \frac{12}{32 \cdot 31}.$$

Dies ergibt

$$P(A|B) = \frac{12 \cdot 8}{32 \cdot 31} = \frac{3}{31}.$$

Direkte Rechnung: Wenn schon ein Ass gezogen ist, dann ist die Wahrscheinlichkeit, dass die zweite Karte wieder ein Ass ist

$$P(A|B) = \frac{3 \cdot 30!}{31!} = \frac{3}{31}.$$

Im Folgenden seien A_1, \dots, A_n paarweise unvereinbare Ereignisse, d.h. $A_i \cap A_j = \emptyset$ für $i \neq j$, und es sei $\bigcup_{i=1}^n A_i = \Omega$. Man spricht von einer *vollständigen Ereignisdisjunktion*.

Es gelten die folgenden Rechenregeln:

Regel von der vollständigen Wahrscheinlichkeit:

A_1, \dots, A_n sei eine vollständige Ereignisdisjunktion mit $P(A_i) > 0$, $i = 1, \dots, n$. Dann gilt:

$$P(B) = \sum_{i=1}^n P(A_i) \cdot P(B|A_i).$$

Beweis: Es gilt $P(A_i) \cdot P(B|A_i) = P(B \cap A_i)$. Die Mengen $C_i = B \cap A_i$ sind paarweise disjunkt mit $\bigcup_{i=1}^n C_i = B$. Wegen der Additivität gilt also

$$\sum_{i=1}^n P(A_i) \cdot P(B|A_i) = \sum_{i=1}^n P(C_i) = P\left(\bigcup_{i=1}^n C_i\right) = P(B).$$

□

Formel von Bayes:

A_1, \dots, A_n sei eine vollständige Ereignisdisjunktion mit $P(A_i) > 0$, $i = 1, \dots, n$, und B sei ein Ereignis mit $P(B) > 0$. Dann gilt für $i = 1, \dots, n$:

$$P(A_i|B) = \frac{P(A_i) \cdot P(B|A_i)}{\sum_{k=1}^n P(A_k) \cdot P(B|A_k)}.$$

Beweis: Der Nenner ist $P(B)$ nach der Regel von der vollständigen Wahrscheinlichkeit. Also ist die rechte Seite gegeben durch

$$\frac{P(A_i) \cdot P(B|A_i)}{P(B)} = \frac{P(A_i) \cdot P(B \cap A_i)/P(A_i)}{P(B)} = \frac{P(B \cap A_i)}{P(B)} = P(A_i|B).$$

□

Beispiel: Bei einer Reihenuntersuchung sind die Ereignisse A : "untersuchter Patient ist erkrankt" und B : "Befund positiv" von Interesse. Es sei $P(A) = 0,001$ die Wahrscheinlichkeit, dass ein Patient erkrankt ist. Weiter seien $P(B|A) = 0,92$ und $P(B|A^c) = 0,01$

die Wahrscheinlichkeiten für einen positiven Befund bei einem erkrankten bzw. nicht erkrankten Patienten.

Gesucht ist die bedingte Wahrscheinlichkeit, dass ein Patient bei einem positiven Befund tatsächlich erkrankt ist, also $P(A|B)$.

Mit $A_1 = A$, $A_2 = A^c$ ergibt die Bayessche Formel

$$P(A|B) = \frac{P(A)P(B|A)}{P(A)P(B|A) + P(A^c)P(B|A^c)} = \frac{0,001 \cdot 0,92}{0,001 \cdot 0,92 + 0,999 \cdot 0,01} = 0,0844.$$

Multiplikationsformel:

A_1, \dots, A_n seien Ereignisse mit $P(A_1 \cap A_2 \cap \dots \cap A_n) > 0$. Dann gilt

$$P(A_1 \cap A_2 \cap \dots \cap A_n) = P(A_1) \cdot P(A_2|A_1) \cdot P(A_3|A_1 \cap A_2) \cdot \dots \cdot P(A_n|A_1 \cap \dots \cap A_{n-1}).$$

Beweis: Vollständige Induktion nach n : Für $n = 2$ gilt

$$P(A_1) \cdot P(A_2|A_1) = P(A_1 \cap A_2).$$

Induktionsschritt:

$$P(A_1) \cdot P(A_2|A_1) \cdot P(A_3|A_1 \cap A_2) \cdot \dots \cdot P(A_n|A_1 \cap \dots \cap A_{n-1})$$

$$\stackrel{\text{Ind. Ann.}}{=} P(A_1 \cap \dots \cap A_{n-1}) \cdot P(A_n|A_1 \cap \dots \cap A_{n-1}) = P(A_n \cap A_1 \cap \dots \cap A_{n-1}).$$

□

11.4.2 Unabhängigkeit

Beim zweifachen Werfen eines Würfels erkennt man, dass die Ereignisse

$$A = \text{''1 beim zweiten Wurf''}, \quad B = \text{''1 beim ersten Wurf''}$$

von völlig unabhängig ablaufenden Teilexperimenten bestimmt wird und für die bedingte Wahrscheinlichkeit gilt

$$P(A|B) = \frac{P(A \cap B)}{P(B)} = \frac{1/6 \cdot 1/6}{1/6} = 1/6 = P(A).$$

Wir haben also

$$P(A \cap B) = P(A) \cdot P(B).$$

Dies motiviert die

Definition 11.4.1 Zwei Ereignisse A und B heißen unabhängig, falls gilt

$$P(A \cap B) = P(A) \cdot P(B).$$

Ereignisse A_1, \dots, A_n heißen vollständig unabhängig, falls für alle $\{i_1, \dots, i_k\} \subset \{1, \dots, n\}$ gilt

$$P(A_{i_1} \cap \dots \cap A_{i_k}) = P(A_{i_1}) \cdot \dots \cdot P(A_{i_k}).$$

Bemerkung: Aus der paarweisen Unabhängigkeit von mehr als zwei Ereignissen folgt nicht immer die vollständige Unabhängigkeit. \square

11.5 Zufallsvariablen und Verteilungsfunktion

Es sei Ω die Ergebnismenge und \mathcal{A} das Ereignissystem, auf dem die Wahrscheinlichkeit P erklärt ist. Oft ist man in der Statistik an einem dem Ergebnis $\omega \in \Omega$ zugeordneten Zahlenwert $X(\omega)$ interessiert.

Definition 11.5.1 Eine Zufallsvariable ist eine Abbildung

$$X : \Omega \rightarrow \mathbb{R}$$

mit der Eigenschaft, dass für jedes Intervall $I \subset \mathbb{R}$ die Urbildmenge

$$A = \{\omega \in \Omega : X(\omega) \in I\}$$

zum Ereignissystem \mathcal{A} gehört. Die Wahrscheinlichkeit dieses Ereignisses "X nimmt Werte im Intervall I an" bezeichnet man abkürzend mit $P(X \in I)$ und schreibt entsprechend

$$P(a \leq X \leq b), \quad P(X \leq x), \quad P(X < x), \quad P(|X - a| < b), \quad P(X = b) \text{ usw.}$$

Beispiel: Zwei Würfel werden geworfen. Wir wählen $\Omega = \{(i, j) : i, j = 1, \dots, 6\}$. Wir betrachten die Zufallsvariable $X : \Omega \rightarrow \mathbb{R}$,

$$X((i, j)) = i + j.$$

X beschreibt also die Summe der beiden gewürfelten Zahlen. Nun gilt zum Beispiel

$$P(X = 1) = 0, \quad P(X = 2) = P(\{(1, 1)\}) = \frac{1}{36}, \quad P(X = 3) = P(\{(1, 2), (2, 1)\}) = \frac{2}{36}, \dots$$

Definition 11.5.2 Sei $X : \Omega \rightarrow \mathbb{R}$ eine Zufallsvariable. Die Abbildung $F : \mathbb{R} \rightarrow \mathbb{R}$

$$F(x) = P(X \leq x), \quad x \in \mathbb{R},$$

heißt Verteilungsfunktion der Zufallsvariable X .

Man kann zeigen, dass mit den Abkürzungen

$$F(x+) = \lim_{h \searrow 0} F(x+h), \quad F(x-) = \lim_{h \searrow 0} F(x-h),$$

$$F(-\infty) = \lim_{x \rightarrow -\infty} F(x), \quad F(\infty) = \lim_{x \rightarrow \infty} F(x)$$

gilt: Verteilungsfunktionen sind monoton wachsende Funktionen mit

$$F(-\infty) = 0, \quad F(\infty) = 1, \quad F(x+) = F(x) \quad \forall x \in \mathbb{R}.$$

Zudem lassen sich alle interessierenden Wahrscheinlichkeiten im Zusammenhang mit der Zufallsvariable X berechnen:

$$P(X = a) = F(a) - F(a-),$$

$$P(a < X \leq b) = F(b) - F(a),$$

$$P(a \leq X < b) = F(b-) - F(a-),$$

$$P(a \leq X \leq b) = F(b) - F(a-),$$

$$P(X > a) = 1 - F(a).$$

Eine Zufallsvariable X heißt *diskret verteilt*, wenn sie nur endlich viele oder abzählbar unendlich viele Werte x_1, x_2, \dots annimmt. Ihre Verteilungsfunktion ist eine monoton wachsende Treppenfunktion, die jeweils an den Stellen x_i Sprünge der Höhe $P(X = x_i)$ hat.

Eine Zufallsvariable X heißt *stetig verteilt mit der Dichte f* , wenn ihre Verteilungsfunktion F durch

$$F(x) = \int_{-\infty}^x f(t) dt, \quad x \in \mathbb{R},$$

gegeben ist. Die Dichte ist hierbei eine nichtnegative Funktion, die Verteilungsfunktion F ist stetig und es gilt $F'(x) = f(x)$ für alle Stetigkeitsstellen x von f .

11.5.1 Beispiele für diskrete Verteilungen

Geometrische Verteilung

Es sei $0 < p < 1$. Eine Zufallsvariable X mit dem Wertebereich $\mathbb{N} = \{1, 2, \dots\}$ heißt *geometrisch verteilt* mit dem Parameter p , falls

$$P(X = i) = (1 - p)^{i-1} p, \quad i = 1, 2, \dots$$

Anwendung: Wird ein Zufallsexperiment, bei dem ein bestimmtes Ereignis mit Wahrscheinlichkeit p eintritt, so lange unabhängig wiederholt, bis zum ersten Mal dieses Ereignis eintritt, dann kann die Anzahl der dazu benötigten Versuche durch eine geometrisch verteilte Zufallsvariable modelliert werden ("Warten auf den ersten Erfolg").

Binomialverteilung

Seine $n \in \mathbb{N}$ und $0 < p < 1$. Eine Zufallsvariable X mit dem Wertebereich $\mathbb{N} = \{1, 2, \dots\}$ heißt *binomialverteilt* mit Parametern n und p , kurz $B(n, p)$ -verteilt, falls

$$P(X = i) = \binom{n}{i} p^i (1-p)^{n-i}, \quad i = 0, 1, \dots, n.$$

Anwendung: Wird ein Zufallsexperiment, bei dem ein bestimmtes Ereignis mit Wahrscheinlichkeit p eintritt, n -mal unabhängig wiederholt, und dabei gezählt, wie oft dieses Ereignis eintritt, so kann diese zufällige Anzahl als $B(n, p)$ -verteilte Zufallsvariable X beschrieben werden ("Anzahl der Erfolge bei n Versuchen").

Poissonverteilung

Sei $\lambda > 0$. Eine Zufallsvariable X mit dem Wertebereich $\mathbb{N} \cup \{0\}$ heißt *Poisson-verteilt*, falls gilt

$$P(X = i) = \frac{\lambda^i}{i!} e^{-\lambda}, \quad i = 0, 1, 2, \dots$$

Sie eignet sich zur Modellierung von Zählergebnissen folgenden Typs: In einer Telefonzentrale wird die Anzahl der innerhalb von 10 Minuten eingehenden Anrufe gezählt. λ gibt die "mittlere Anzahl" der eingehenden Anrufe an.

11.5.2 Beispiele für stetige Verteilungen**Rechteckverteilung**

Es sei $a < b$. Eine stetig verteilte Zufallsvariable mit der Dichte

$$f(t) = \begin{cases} \frac{1}{b-a}, & a \leq t \leq b \\ 0 & \text{sonst} \end{cases}$$

heißt *rechteckverteilt* im Intervall $[a, b]$, kurz $R(a, b)$ -verteilt. Für die Verteilungsfunktion ergibt sich

$$F(x) = \int_{-\infty}^x f(t) dt = \begin{cases} 0, & x \leq a, \\ \frac{x-a}{b-a}, & a < x < b, \\ 1 & x \geq b. \end{cases}$$

Exponentialverteilung

Sei $\lambda > 0$. Eine stetig verteilte Zufallsvariable X mit der Dichte

$$f(t) = \begin{cases} 0, & t < 0, \\ \lambda e^{-\lambda t}, & t \geq 0, \end{cases}$$

heißt *exponentialverteilt* mit Parameter λ , kurz $Ex(\lambda)$ -verteilt. Für die Verteilungsfunktion ergibt sich

$$F(x) = \int_{-\infty}^x f(t) dt = \begin{cases} 0, & x < 0, \\ 1 - e^{-\lambda x}, & x \geq 0. \end{cases}$$

Normalverteilung

E seien $\mu \in \mathbb{R}$ und $\sigma > 0$. Eine stetig verteilte Zufallsvariable X mit der Dichte

$$f(t) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{1}{2}\left(\frac{t-\mu}{\sigma}\right)^2}, \quad t \in \mathbb{R},$$

heißt *normalverteilt* mit Parameter μ und σ^2 , kurz: $N(\mu, \sigma^2)$ -verteilt.

Im Fall $\mu = 0, \sigma^2 = 1$ spricht man von einer *Standard-Normalverteilung* und bezeichnet ihre Verteilungsfunktion mit

$$\Phi(x) = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^x e^{-t^2/2} dt.$$

Φ ist nicht geschlossen angebar und muss tabelliert oder numerisch ausgewertet werden. Offensichtlich gilt

$$\Phi(0) = \frac{1}{2}, \quad \Phi(-x) = 1 - \Phi(x), \quad x \geq 0.$$

Ist X eine $N(\mu, \sigma^2)$ -verteilte Zufallsvariable, dann rechnet man leicht nach, dass die Verteilungsfunktion durch

$$F_{\mu, \sigma^2}(x) = \Phi\left(\frac{x - \mu}{\sigma}\right)$$

gegeben ist. Tatsächlich ergibt sich durch die Substitution $s = \frac{t-\mu}{\sigma}$

$$F_{\mu, \sigma^2}(x) = \frac{1}{\sigma\sqrt{2\pi}} \int_{-\infty}^x e^{-\frac{1}{2}\left(\frac{t-\mu}{\sigma}\right)^2} dt = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{\frac{x-\mu}{\sigma}} e^{-\frac{1}{2}s^2} ds = \Phi\left(\frac{x - \mu}{\sigma}\right)$$

11.6 Erwartungswert und Varianz

Ist X eine diskret verteilte Zufallsvariable mit den Werten x_1, x_2, \dots , so heißt

$$E(X) = \sum_i x_i P(X = x_i)$$

Erwartungswert von X , falls $\sum_i |x_i| P(X = x_i) < \infty$.

Ist X eine stetig verteilte Zufallsvariable mit Dichte f , so heißt

$$E(X) = \int_{-\infty}^{\infty} x f(x) dx$$

Erwartungswert von X , falls $\int_{-\infty}^{\infty} |x| f(x) dx < \infty$.

Beispiele:

1. Sei X Poisson-verteilt mit Parameter $\lambda > 0$.

$$E(X) = \sum_{i=0}^{\infty} i \frac{\lambda^i}{i!} e^{-\lambda} = \lambda e^{-\lambda} \sum_{i=1}^{\infty} \frac{\lambda^{i-1}}{(i-1)!} = \lambda e^{-\lambda} e^{\lambda} = \lambda.$$

2. Sei X exponentialverteilt. Dann gilt

$$E(X) = \int_0^{\infty} x \lambda e^{-\lambda x} dx = -x e^{-\lambda x} \Big|_0^{\infty} + \int_0^{\infty} e^{-\lambda x} dx = 0 - \frac{1}{\lambda} e^{-\lambda x} \Big|_0^{\infty} = \frac{1}{\lambda}.$$

Ist $h : \mathbb{R} \rightarrow \mathbb{R}$ eine stückweise stetige Funktion. Dann hat die Zufallsvariable $h(X)$ für eine diskret verteilte Zufallsvariable X den Erwartungswert (im Falle seiner Existenz)

$$E(h(X)) = \sum_i h(x_i) P(X = x_i).$$

Ist X stetig verteilt mit Dichte f , dann hat $h(X)$ den Erwartungswert (im Falle seiner Existenz)

$$E(h(X)) = \int_{-\infty}^{\infty} h(x) f(x) dx.$$

Der Erwartungswert der quadratischen Abweichung der Zufallsvariablen X von ihrem Erwartungswert $E(X)$ heißt *Varianz* von X :

$$\text{Var}(X) = E([X - E(X)]^2).$$

Die *Standardabweichung* von X ist definiert durch $\sqrt{\text{Var}(X)}$.

11.6.1 Rechenregeln

Es gelten folgende Rechenregeln:

$$\begin{aligned} E(aX + b) &= aE(X) + b \\ E(h_1(X) + h_2(X)) &= E(h_1(X)) + E(h_2(X)). \end{aligned}$$

Daraus erhält man

$$\text{Var}(X) = E(X^2) - (E(X))^2.$$

Begründung: Es gilt

$$\begin{aligned} \text{Var}(X) &= E([X - E(X)]^2) = E(X^2 + 2E(X)X + E(X)^2) \\ &= E(X^2) - E(2E(X)X) + E(E(X)^2) = E(X^2) - 2E(X)E(X) + E(X)^2 \\ &= E(X^2) - E(X)^2. \end{aligned}$$

Außerdem gilt

$$\text{Var}(aX + b) = a^2 \text{Var}(X),$$

da

$$\begin{aligned} \text{Var}(aX + b) &= E((aX + b)^2) - (E(aX + b))^2 = E(a^2X^2 + 2abX + b^2) - (aE(X) + b)^2 \\ &= a^2E(X^2) + 2abE(X) + b^2 - a^2E(X)^2 - 2abE(X) - b^2 \\ &= a^2(E(X^2) - E(X)^2) = a^2 \text{Var}(X). \end{aligned}$$

Einige Beispiele:

| Verteilung | $E(X)$ | $\text{Var}(X)$ |
|--------------------|---------------------|-----------------------|
| $N(\mu, \sigma^2)$ | μ | σ^2 |
| $Ex(\lambda)$ | $\frac{1}{\lambda}$ | $\frac{1}{\lambda^2}$ |
| $B(n, p)$ | np | $np(1-p)$ |

Die Tschebyschevsche Ungleichung stellt einen Zusammenhang zwischen Erwartungswert und Varianz her:

Tschebyschevsche Ungleichung:

Es gilt

$$P(|X - E(X)| \geq c) \leq \frac{\text{Var}(X)}{c^2}, \quad c > 0.$$

Aus der Definition des Erwartungswerts ist klar, dass für Zufallsvariablen X_1, X_2, \dots, X_n gilt

$$E(X_1 + \dots + X_n) = E(X_1) + \dots + E(X_n).$$

Die Frage, ob eine entsprechende Formel auch für die Varianz gilt, führt auf den Begriff der Unabhängigkeit von Zufallsvariablen X_1, X_2, \dots, X_n .

Definition 11.6.1 Seien X_1, X_2, \dots, X_n Zufallsvariablen mit Verteilungsfunktionen F_1, \dots, F_n . Die gemeinsame Verteilungsfunktion von X_1, X_2, \dots, X_n ist definiert durch

$$F(x_1, \dots, x_n) = P(X_1 \leq x_1, \dots, X_n \leq x_n), \quad (x_1, \dots, x_n) \in \mathbb{R}^n.$$

Die Zufallsvariablen heißen unabhängig, wenn für alle $(x_1, \dots, x_n) \in \mathbb{R}^n$ die Ereignisse

$$\{X_1 \leq x_1\}, \dots, \{X_n \leq x_n\}$$

vollständig unabhängig sind, also

$$P(X_1 \leq x_1, \dots, X_n \leq x_n) = P(X_1 \leq x_1) \cdot \dots \cdot P(X_n \leq x_n)$$

oder kurz

$$F(x_1, \dots, x_n) = F_1(x_1) \cdot \dots \cdot F_n(x_n).$$

Satz 11.6.2 Die Zufallsvariablen X_1, X_2, \dots, X_n seien unabhängig. Dann gilt

$$\text{Var}(X_1 + \dots + X_n) = \text{Var}(X_1) + \dots + \text{Var}(X_n).$$

11.7 Gesetz der großen Zahlen, zentraler Grenzwertsatz

11.7.1 Das schwache Gesetz der großen Zahlen

Durch die Mittelung vieler unabhängiger identisch verteilter Zufallsvariablen erhält man eine Zufallsvariable, die mit großer Wahrscheinlichkeit Werte nahe beim Erwartungswert liefert.

Satz 11.7.1 (Das schwache Gesetz der großen Zahlen)

Ist X_1, X_2, \dots eine Folge unabhängiger identisch verteilter Zufallsvariablen (d.h. je endlich viele von ihnen sind unabhängig) mit $E(X_i) = \mu$, $\text{Var}(X_i) = \sigma^2$, dann gilt

$$\lim_{n \rightarrow \infty} P\left(\left|\frac{1}{n} \sum_{i=1}^n X_i - \mu\right| \geq \varepsilon\right) = 0 \quad \forall \varepsilon > 0.$$

Beweis: Setze $Y_n = \frac{1}{n} \sum_{i=1}^n X_i$. Dann gilt $E(Y_n) = \mu$ und wegen der Unabhängigkeit $\text{Var}(Y_n) = \frac{1}{n^2} \text{Var}(X_1 + \dots + X_n) = \frac{1}{n^2} n \sigma^2 = \frac{\sigma^2}{n}$. Die Tschebyschevsche Ungleichung ergibt nun

$$P(|Y_n - \mu| \geq \varepsilon) \leq \frac{\text{Var}(Y_n)}{\varepsilon^2} = \frac{\sigma^2}{n\varepsilon^2} \rightarrow 0 \quad \text{für } n \rightarrow \infty.$$

□

11.7.2 Zentraler Grenzwertsatz

Wir betrachten eine Zufallsvariable

$$Y = X_1 + \dots + X_n$$

mit unabhängigen Summanden X_1, \dots, X_n . Extrem große Werte von Y treten nur dann auf, wenn sehr viele X_i gleichzeitig große Werte annehmen. Wegen der Unabhängigkeit ist es sehr wahrscheinlich, dass große Werte eines Summanden durch kleine Werte eines anderen Summanden kompensiert werden. Es zeigt sich, dass die Verteilung von Y für großes n mehr und mehr einer Normalverteilung entspricht:

Satz 11.7.2 (Zentraler Grenzwertsatz)

Ist X_1, X_2, \dots eine Folge unabhängiger Zufallsvariablen mit

$$E(X_i) = \mu_i, \quad \text{Var}(X_i) = \sigma_i^2, \quad i = 1, 2, \dots,$$

so gilt unter schwachen zusätzlichen Voraussetzungen, z.B. dass X_i identisch verteilt sind:

$$\lim_{n \rightarrow \infty} P \left(\frac{X_1 + \dots + X_n - (\mu_1 + \dots + \mu_n)}{\sqrt{\sigma_1^2 + \dots + \sigma_n^2}} \leq y \right) = \Phi(y) \quad \forall y \in \mathbb{R}.$$

Eine arithmetisches Mittel

$$\bar{X}_{(n)} = \frac{1}{n}(X_1 + \dots + X_n)$$

ist für großes n also näherungsweise $N(\mu, \sigma^2)$ -verteilt, wobei

$$\mu = \frac{1}{n}E(X_1 + \dots + X_n) = \frac{1}{n}(\mu_1 + \dots + \mu_n), \quad \sigma^2 = \frac{1}{n^2}\text{Var}(X_1 + \dots + X_n) = \frac{1}{n^2}(\sigma_1^2 + \dots + \sigma_n^2).$$

Bemerkung: Hat X Erwartungswert μ und Varianz σ^2 , dann hat $\frac{X-\mu}{\sigma}$ den Erwartungswert 0 und Varianz 1. \square

Als mathematisches Modell für das Entstehen von Messreihen werden im folgenden unabhängige, identisch verteilte Zufallsvariablen X_1, \dots, X_n verwendet. Eine Messreihe x_1, \dots, x_n wird als Realisierung der Zufallsvariablen X_1, \dots, X_n angesehen, wir nehmen also an, dass ein Ereignis $\omega \in \Omega$ existiert mit

$$x_1 = X_1(\omega), \dots, x_n = X_n(\omega).$$

Haben die X_i Erwartungswert μ und Varianz σ^2 , dann sagt Satz 11.7.2 insbesondere aus, dass dann das arithmetische Mittel $\bar{X}_{(n)} = \frac{1}{n}(X_1 + \dots + X_n)$ für grosse n näherungsweise $N(\mu, \sigma^2/n)$ -verteilt ist.

Die Verteilungsfunktion der Zufallsvariablen X_1, \dots, X_n sei mit F bezeichnet. Was sagt die Messreihe über F aus?

Es ist intuitiv einleuchtend, dass die empirische Verteilungsfunktion

$$F_n(z; x_1, x_2, \dots, x_n) = \frac{\text{Zahl der } x_i \text{ mit } x_i \leq z}{n}$$

in engem Zusammenhang zur Wahrscheinlichkeit

$$F(z) = P(X_1 \leq z)$$

stehen muss. Es gilt:

Satz 11.7.3 (Zentralsatz der Statistik)

Sei X_1, X_2, \dots eine Folge unabhängiger identisch verteilter Zufallsvariablen mit der Verteilungsfunktion F und bezeichne

$$D_n(X_1, \dots, X_n) = \sup_{z \in \mathbb{R}} |F_n(z; X_1, \dots, X_n) - F(z)|$$

die zufällige Maximalabweichung zwischen empirischer und "wahrer" Verteilungsfunktion. Dann gilt

$$P\left(\lim_{n \rightarrow \infty} D_n(X_1, \dots, X_n) = 0\right) = 1,$$

$D_n(X_1, \dots, X_n)$ konvergiert also mit Wahrscheinlichkeit 1 gegen 0.

11.8 Testverteilungen und Quantilapproximationen

In der Statistik, insbesondere in der Testtheorie, werden die folgenden Verteilungen benötigt, die von der Normalverteilung abgeleitet werden:

Seien Z_1, \dots, Z_n unabhängige, identisch $N(0, 1)$ -verteilte Zufallsgrößen.

χ_r^2 -Verteilung:

Es sei $1 \leq r \leq n$. Eine Zufallsvariable X heißt χ_r^2 -verteilt, falls sie die Verteilungsfunktion besitzt

$$F(x) = P(Z_1^2 + \dots + Z_r^2 \leq x), \quad x \in \mathbb{R}.$$

t_r -Verteilung:

Es sei $1 \leq r \leq n - 1$. Eine Zufallsvariable X heißt t_r -verteilt, falls sie die Verteilungsfunktion besitzt

$$F(x) = P\left(\frac{Z_{r+1}}{\sqrt{(Z_1^2 + \dots + Z_r^2)/r}} \leq x\right), \quad x \in \mathbb{R}.$$

F -Verteilung:

Es sei $1 \leq r, s \leq n - 1$ mit $r + s \leq n$. Eine Zufallsvariable X heißt F -verteilt mit r und s Freiheitsgraden, falls sie die Verteilungsfunktion besitzt

$$F(x) = P\left(\frac{(Z_1^2 + \dots + Z_r^2)/r}{(Z_{r+1}^2 + \dots + Z_{r+s}^2)/s} \leq x\right), \quad x \in \mathbb{R}.$$

Die Dichten dieser Verteilungen können unter Verwendung der Gamma-Funktion

$$\Gamma(x) = \int_0^\infty e^{-t} t^{x-1}, \quad x > 0$$

und der Beta-Funktion

$$B(\alpha, \beta) = \int_0^1 t^{\alpha-1} (1-t)^{\beta-1} dt, \quad \alpha, \beta > 0$$

angegeben werden.

Bezeichnungen für Quantile: Allgemein ist das p -Quantil x_p für eine stetig verteilte Zufallsgröße mit Verteilungsfunktion F gegeben durch

$$F(x_p) = p.$$

Bezeichnungen:

- u_p p -Quantil der $N(0, 1)$ -Verteilung
- $t_{r;p}$ p -Quantil der t_r -Verteilung
- $\chi_{r;p}$ p -Quantil der χ_r^2 -Verteilung
- $F_{r,s;p}$ p -Quantil der $F_{r,s}$ -Verteilung

Für gängige Werte von p existieren Tabellen für diese Quantile.

11.8.1 Wichtige Anwendungsbeispiele

Seien X_1, \dots, X_n unabhängige, identisch $N(\mu, \sigma^2)$ -verteilte Zufallsvariable. Bilden wir ihr arithmetisches Mittel

$$\bar{X}_{(n)} := \frac{1}{n} \sum_{i=1}^n X_i$$

und die Stichprobenvarianz

$$S_{(n)}^2 := \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X}_{(n)})^2$$

dann gilt:

Satz 11.8.1 *Es seien X_1, \dots, X_n unabhängige, identisch $N(\mu, \sigma^2)$ -verteilte Zufallsvariable. Dann gilt:*

- $\bar{X}_{(n)}$ ist $N(\mu, \sigma^2/n)$ -verteilt,
- $\frac{n-1}{\sigma^2} S_{(n)}^2$ ist χ_{n-1}^2 -verteilt,
- $\bar{X}_{(n)}$ und $S_{(n)}^2$ sind unabhängig,
- $\sqrt{n} \frac{\bar{X}_{(n)} - \mu}{\sqrt{S_{(n)}^2}}$ ist t_{n-1} -verteilt.

Kapitel 12

Schätzverfahren und Konfidenzintervalle

12.1 Grundlagen zu Schätzverfahren

Für eine Messreihe x_1, \dots, x_n wird im Folgenden angenommen, dass sie durch n gleiche Zufallsexperimente unabhängig voneinander ermittelt werden. Jeden Messwert sehen wir als unabhängige Realisierung einer Zufallsvariable X an. Als mathematisches Modell für das Entstehen von Messreihen werden im folgenden unabhängige, identisch wie X verteilte Zufallsvariablen X_1, \dots, X_n verwendet. Eine Messreihe x_1, \dots, x_n wird als Realisierung der Zufallsvariablen X_1, \dots, X_n angesehen, wir nehmen also an, dass ein Ereignis $\omega \in \Omega$ existiert mit

$$x_1 = X_1(\omega), \dots, x_n = X_n(\omega).$$

Es wird nun angenommen, dass die Verteilungsfunktion F von X , die auch die Verteilungsfunktion der unabhängigen, identisch verteilten Zufallsvariablen X_i , $1 \leq i \leq n$, ist, einer durch einen Parameter $\theta \in \Theta \subset \mathbb{R}^k$ parametrisierten Familie

$$F_\theta, \quad \theta \in \Theta,$$

von Verteilungsfunktionen angehört. Dieser Parameter oder ein durch ihn bestimmter Zahlenwert $\tau(\theta)$ mit einer Abbildung $\tau : \Theta \rightarrow \mathbb{R}$ sei unbekannt und soll aufgrund der Messreihe näherungsweise geschätzt werden.

Beispiel: X und alle X_1, \dots, X_n seien normalverteilt. F_θ mit

$$\theta = (\mu, \sigma^2) \in \Theta = \mathbb{R} \times]0, \infty[$$

ist dann die Verteilungsfunktion einer $N(\mu, \sigma^2)$ -Verteilung. Soll der Erwartungswert geschätzt werden, so ist $\tau(\theta) = \mu$. Will man die Varianz schätzen, dann ist $\tau(\theta) = \sigma^2$.

Definition 12.1.1 Ein Schätzverfahren oder eine Schätzfunktion oder kurz ein Schätzer ist eine Abbildung

$$T_n : \mathbb{R}^n \rightarrow \mathbb{R}.$$

Sie ordnet einer Messreihe x_1, \dots, x_n einen Schätzwert $T_n(x_1, \dots, x_n)$ für den unbekanntem Wert $\tau(\theta)$ zu.

Die Zufallsvariable $T_n(X_1, \dots, X_n)$ heißt Schätzvariable.

Erwartungswert und Varianz der Schätzvariablen $T_n(X_1, \dots, X_n)$ sowie aller X_i hängen von der Verteilungsfunktion F_θ ab, die seiner Berechnung zugrundegelegt wird. Um dies zu verdeutlichen, schreiben wir

$$E_\theta(T_n(X_1, \dots, X_n)), \quad E_\theta(X_1), \dots$$

sowie

$$\text{Var}_\theta(T_n(X_1, \dots, X_n)), \quad \text{Var}_\theta(X_1), \dots$$

Außerdem schreiben wir für durch F_θ berechnete Wahrscheinlichkeiten

$$P_\theta(a \leq T_n(X_1, \dots, X_n) \leq b), \quad P_\theta(a \leq X_1 \leq b), \dots$$

Definition 12.1.2 Ein Schätzer $T_n : \mathbb{R}^n \rightarrow \mathbb{R}$ heißt erwartungstreu für $\tau : \Theta \rightarrow \mathbb{R}$, falls gilt

$$E_\theta(T_n(X_1, \dots, X_n)) = \tau(\theta) \quad \text{für alle } \theta \in \Theta.$$

Beispiele:

1. τ sei gegeben durch $\tau(\theta) = E_\theta(X) = \mu$. Das arithmetische Mittel $\bar{X}_{(n)} = \frac{1}{n}(X_1 + \dots + X_n)$ ist ein erwartungstreuer Schätzer für $\tau(\theta)$. Tatsächlich gilt

$$E_\theta(\bar{X}_{(n)}) = E_\theta\left(\frac{1}{n}(X_1 + \dots + X_n)\right) = \frac{1}{n}(E_\theta(X_1) + \dots + E_\theta(X_n)) = \frac{1}{n}n\mu = \mu.$$

2. τ sei gegeben durch $\tau(\theta) = \text{Var}_\theta(X)$. Die Stichprobenvarianz $S_{(n)}^2 := \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X}_{(n)})^2$ ist ein erwartungstreuer Schätzer für $\tau(\theta)$. Denn es gilt

$$\begin{aligned} \sum_{i=1}^n (X_i - \bar{X}_{(n)})^2 &= \sum_{i=1}^n ((X_i - \mu) - (\bar{X}_{(n)} - \mu))^2 \\ &= \sum_{i=1}^n ((X_i - \mu)^2 - 2(X_i - \mu)(\bar{X}_{(n)} - \mu) + (\bar{X}_{(n)} - \mu)^2) \\ &= \sum_{i=1}^n (X_i - \mu)^2 - 2n(\bar{X}_{(n)} - \mu)^2 + n(\bar{X}_{(n)} - \mu)^2 \\ &= \sum_{i=1}^n (X_i - \mu)^2 - n(\bar{X}_{(n)} - \mu)^2. \end{aligned}$$

Nun gilt $E_\theta((\bar{X}_{(n)} - \mu)^2) = \text{Var}_\theta(\bar{X}_{(n)}) = \frac{1}{n^2}n\text{Var}_\theta(X)$, also

$$\begin{aligned} E_\theta \left(\sum_{i=1}^n (X_i - \bar{X}_{(n)})^2 \right) &= \sum_{i=1}^n E_\theta((X_i - \mu)^2) - nE_\theta((\bar{X}_{(n)} - \mu)^2) \\ &= n\text{Var}_\theta(X) - n\frac{1}{n}\text{Var}_\theta(X) = (n-1)\text{Var}_\theta(X). \end{aligned}$$

Definition 12.1.3 *Ein Folge von Schätzern T_1, T_2, \dots heißt konsistent für τ , wenn für alle $\varepsilon > 0$ und alle $\theta \in \Theta$ gilt*

$$\lim_{n \rightarrow \infty} P_\theta (|T_n(X_1, \dots, X_n) - \tau(\theta)| > \varepsilon) = 0.$$

Es gilt folgender

Satz 12.1.4 *Ist T_1, T_2, \dots eine Folge von Schätzern, die erwartungstreu für τ sind und gilt*

$$\lim_{n \rightarrow \infty} \text{Var}_\theta(T_n(X_1, \dots, X_n)) = 0 \quad \text{für alle } \theta \in \Theta,$$

dann ist die Folge von Schätzern konsistent für τ .

Beweis: Wegen $E_\theta(T_n(X_1, \dots, X_n)) = \tau(\theta)$ gilt nach der Ungleichung von Tschebyschev

$$P_\theta(|T_n(X_1, \dots, X_n) - \tau(\theta)| > \varepsilon) \leq \frac{\text{Var}_\theta(T_n(X_1, \dots, X_n))}{\varepsilon^2} \rightarrow 0.$$

□

Beispiel: Es sei $X \sim N(\mu, \sigma^2)$ -verteilt, $\theta = (\mu, \sigma^2) \in \Theta = \mathbb{R} \times]0, \infty[$ und $\tau(\theta) = \mu$. Der Schätzer

$$T_n(X_1, \dots, X_n) = \bar{X}_{(n)} = \frac{1}{n}(X_1 + \dots + X_n)$$

ist nach Satz 11.8.1 $N(\mu, \sigma^2/n)$ -verteilt, also erwartungstreu mit Varianz

$$\text{Var}_\theta(T_n(X_1, \dots, X_n)) = \sigma^2/n \rightarrow 0 \quad \text{für } n \rightarrow \infty.$$

Daher ist die Schätzerfolge nach Satz 12.1.4 auch konsistent.

12.2 Maximum-Likelihood-Schätzer

Bei gegebener Verteilungsklasse F_θ , $\theta \in \Theta$, lassen sich Schätzer für den Parameter θ oft mit der Maximum-Likelihood-Methode gewinnen.

Sind die zugrundeliegenden Zufallsvariablen X_1, \dots, X_n stetig verteilt, so ist die Verteilungsfunktion F_θ durch eine Dichte

$$f_\theta(x), \quad x \in \mathbb{R},$$

bestimmt. Im Fall diskreter Zufallsvariablen X , bzw. X_1, \dots, X_n definieren wir

$$f_\theta(x) = P_\theta(X = x) \quad \text{für alle } x \text{ aus dem Wertevorrat } \mathbb{X} \text{ von } X.$$

Definition 12.2.1 Für eine Messreihe x_1, \dots, x_n heißt die Funktion $L(\cdot; x_1, \dots, x_n)$ mit

$$L(\theta; x_1, \dots, x_n) = f_\theta(x_1) \cdot f_\theta(x_2) \cdot \dots \cdot f_\theta(x_n)$$

die zu x_1, \dots, x_n gehörige Likelihood-Funktion.

Ein Parameterwert

$$\hat{\theta} = \hat{\theta}(x_1, \dots, x_n)$$

mit

$$L(\hat{\theta}; x_1, \dots, x_n) \geq L(\theta; x_1, \dots, x_n) \quad \text{für alle } \theta \in \Theta$$

heißt Maximum-Likelihood-Schätzwert für θ . Existiert zu jeder möglichen Messreihe x_1, \dots, x_n ein Maximum-Likelihood-Schätzwert $\hat{\theta}(x_1, \dots, x_n)$, dann heißt

$$T_n : \mathbb{X}^n \rightarrow \mathbb{R}, \quad T_n(x_1, \dots, x_n) = \hat{\theta}(x_1, \dots, x_n)$$

Maximum-Likelihood-Schätzer.

Beispiel: Die Zufallsvariablen seien Poisson-verteilt mit Parameter $\theta > 0$, also

$$f_\theta(x) = \frac{\theta^x}{x!} e^{-\theta}, \quad x \in \mathbb{N} \cup \{0\}.$$

Dies ergibt

$$L(\theta; x_1, \dots, x_n) = \frac{1}{x_1! \cdots x_n!} \cdot \theta^{x_1 + \dots + x_n} \cdot e^{-n\theta}, \quad x_i \in \mathbb{N} \cup \{0\}.$$

L wird genau dann maximal, wenn die Log-Likelihood-Funktion $\ln(L)$, also

$$\ln L(\theta; x_1, \dots, x_n) = -n\theta - \ln(x_1! \cdots x_n!) + (x_1 + \dots + x_n) \ln \theta,$$

maximal wird. Die erste Ableitung dieser Funktion nach θ ist

$$\frac{d \ln L}{d\theta} = -n + \frac{x_1 + \dots + x_n}{\theta}$$

mit der eindeutigen Nullstelle

$$\hat{\theta}(x_1, \dots, x_n) = \frac{1}{n}(x_1 + \dots + x_n).$$

Da die zweite Ableitung negativ ist, ist $\hat{\theta}$ der Maximum-Likelihood-Schätzer für θ und ist nichts anderes als das arithmetische Mittel.

12.3 Konfidenzintervalle

Die Situation sei wie beim Schätzen. Es wird eine Messreihe x_1, \dots, x_n beobachtet und es sollen diesmal Ober- und Unterschranken für den Wert $\tau(\theta)$ aus der Messreihe ermittelt werden. Durch ein Paar

$$U : \mathbb{R}^n \rightarrow \mathbb{R}, \quad O : \mathbb{R}^n \rightarrow \mathbb{R}$$

von Schätzern mit

$$U(x_1, \dots, x_n) \leq O(x_1, \dots, x_n)$$

wird ein "zufälliges Intervall"

$$I(X_1, \dots, X_n) = [U(X_1, \dots, X_n), O(X_1, \dots, X_n)]$$

definiert.

Definition 12.3.1 Sei $0 < \alpha < 1$. Das zufällige Intervall $I(X_1, \dots, X_n)$ heißt Konfidenzintervall für $\tau(\theta)$ zum Konfidenzniveau $1 - \alpha$, falls gilt

$$P_\theta(U(X_1, \dots, X_n) \leq \tau(\theta) \leq O(X_1, \dots, X_n)) \geq 1 - \alpha \quad \text{für alle } \theta \in \Theta.$$

Das zu einer bestimmten Messreihe x_1, \dots, x_n gehörige Intervall

$$I(x_1, \dots, x_n) = [U(x_1, \dots, x_n), O(x_1, \dots, x_n)]$$

heißt konkretes Schätzintervall für $\tau(\theta)$.

Die Forderung stellt sicher, dass mit Wahrscheinlichkeit $1 - \alpha$ ein konkretes Schätzintervall den Wert $\tau(\theta)$ enthält.

12.3.1 Konstruktion von Konfidenzintervallen

Wir nehmen an, dass X_1, \dots, X_n unabhängig, identisch normalverteilt sind. Die Verteilungsfunktion F_θ ist dann durch den zweidimensionalen Parameter $\theta = (\mu, \sigma^2)$ bestimmt durch

$$F_\theta(x) = F_{(\mu, \sigma^2)}(x) = \Phi\left(\frac{x - \mu}{\sigma}\right).$$

Mit den bereits eingeführten Bezeichnungen

$$\bar{X}_{(n)} := \frac{1}{n} \sum_{i=1}^n X_i, \quad S_{(n)}^2 := \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X}_{(n)})^2$$

erhält man folgende Konfidenzintervalle zum Niveau $1 - \alpha$:

Konfidenzintervall für μ bei bekannter Varianz $\sigma^2 = \sigma_0^2$:

Hier ist $\Theta = \{(\mu, \sigma_0^2) : \mu \in \mathbb{R}\}$ und $\tau(\theta) = \mu$. Das Konfidenzintervall für μ lautet

$$I(X_1, \dots, X_n) = \left[\bar{X}_{(n)} - u_{1-\alpha/2} \frac{\sigma_0}{\sqrt{n}}, \bar{X}_{(n)} + u_{1-\alpha/2} \frac{\sigma_0}{\sqrt{n}} \right].$$

mit dem $(1 - \alpha/2)$ -Quantil $u_{1-\alpha/2}$ der $N(0, 1)$ -Verteilung, also

$$\Phi(u_{1-\alpha/2}) = 1 - \alpha/2.$$

Begründung: $\bar{X}_{(n)}$ ist nach Satz 11.8.1 $N(\mu, \sigma_0^2/n)$ -verteilt. Also gilt:

$$Y_n := \frac{\bar{X}_{(n)} - \mu}{\sqrt{\sigma_0^2/n}} \text{ ist } N(0, 1)\text{-verteilt.}$$

Wegen $\Phi(-u_{1-\alpha/2}) = \alpha/2$ gilt

$$P_\theta(-u_{1-\alpha/2} \leq Y_n \leq u_{1-\alpha/2}) = 1 - \alpha.$$

Einsetzen und Umformen ergibt

$$P_\theta(-u_{1-\alpha/2} \leq \frac{\bar{X}_{(n)} - \mu}{\sigma_0/\sqrt{n}} \leq u_{1-\alpha/2}) = P_\theta\left(\bar{X}_{(n)} - u_{1-\alpha/2} \frac{\sigma_0}{\sqrt{n}} \leq \mu \leq \bar{X}_{(n)} + u_{1-\alpha/2} \frac{\sigma_0}{\sqrt{n}}\right) = 1 - \alpha.$$

Konfidenzintervall für μ bei unbekannter Varianz σ^2 :

Hier ist $\Theta = \{(\mu, \sigma^2) : \mu \in \mathbb{R}, \sigma^2 > 0\}$ und $\tau(\theta) = \mu$. Das Konfidenzintervall für μ lautet

$$I(X_1, \dots, X_n) = \left[\bar{X}_{(n)} - t_{n-1; 1-\alpha/2} \sqrt{\frac{S_{(n)}^2}{n}}, \bar{X}_{(n)} + t_{n-1; 1-\alpha/2} \sqrt{\frac{S_{(n)}^2}{n}} \right]$$

mit dem $(1 - \alpha/2)$ -Quantil $t_{n-1; 1-\alpha/2}$ der t_{n-1} -Verteilung.

Begründung: Nach Satz 11.8.1 ist

$$Y_n := \frac{\bar{X}_{(n)} - \mu}{\sqrt{S_{(n)}^2/n}} \text{ ist } t_{n-1}\text{-verteilt.}$$

Eine Rechnung völlig analog wie eben liefert das Konfidenzintervall.

Konfidenzintervall für σ^2 bei bekanntem Erwartungswert $\mu = \mu_0$:

Hier ist $\Theta = \{(\mu_0, \sigma^2) : \sigma^2 > 0\}$ und $\tau(\theta) = \sigma^2$. Das Konfidenzintervall für σ^2 lautet

$$I(X_1, \dots, X_n) = \left[\frac{\sum_{i=1}^n (X_i - \mu_0)^2}{\chi_{n;1-\alpha/2}^2}, \frac{\sum_{i=1}^n (X_i - \mu_0)^2}{\chi_{n;\alpha/2}^2} \right].$$

Begründung: Jedes $\frac{X_i - \mu_0}{\sigma}$ ist $N(0, 1)$ -verteilt. Wegen der Unabhängigkeit ist also nach 11.8 $\frac{1}{\sigma^2} \sum_{i=1}^n (X_i - \mu_0)^2$ χ_n^2 -verteilt. Dies ergibt

$$P_\theta \left(\chi_{n;\alpha/2}^2 \leq \frac{1}{\sigma^2} \sum_{i=1}^n (X_i - \mu_0)^2 \leq \chi_{n;1-\alpha/2}^2 \right) = 1 - \alpha$$

und Auflösen nach σ^2 liefert das Konfidenzintervall.

Konfidenzintervall für σ^2 bei unbekanntem Erwartungswert:

Hier ist $\Theta = \{(\mu, \sigma^2) : \mu \in \mathbb{R}, \sigma^2 > 0\}$ und $\tau(\theta) = \sigma^2$. Das Konfidenzintervall für σ^2 lautet

$$I(X_1, \dots, X_n) = \left[\frac{(n-1)S_{(n)}^2}{\chi_{n-1;1-\alpha/2}^2}, \frac{(n-1)S_{(n)}^2}{\chi_{n-1;\alpha/2}^2} \right].$$

Begründung: Nach Satz 11.8.1 ist $\frac{n-1}{\sigma^2} S_{(n)}^2$ χ_{n-1}^2 -verteilt. Dies ergibt

$$P_\theta \left(\chi_{n-1;\alpha/2}^2 \leq \frac{n-1}{\sigma^2} S_{(n)}^2 \leq \chi_{n-1;1-\alpha/2}^2 \right) = 1 - \alpha$$

und Auflösen nach σ^2 liefert das Konfidenzintervall.

Kapitel 13

Tests bei Normalverteilungsannahmen

13.1 Grundlagen

Beim Testen geht es um die Frage, ob eine Messreihe x_1, \dots, x_n , die als Realisierung von unabhängigen, identisch verteilten Zufallsvariablen X_1, \dots, X_n angesehen wird, zu einer bestimmten Annahme über die Verteilung der X_i passt oder ihr widerspricht. Die zu prüfende Annahme heißt *Nullhypothese* H_0 und das Verfahren, mit dem entschieden wird, ob ein Widerspruch vorliegt, d.h. ob die Nullhypothese H_0 verworfen werden soll, heißt *Test*.

Seien also X_1, \dots, X_n unabhängige, identisch verteilte Zufallsvariablen, so dass eine Messreihe x_1, \dots, x_n als Realisierung von X_1, \dots, X_n aufgefasst werden kann. Dann ist ein Test durch die Angabe seines *kritischen Bereichs* $K \subset \mathbb{R}^n$ vollständig beschrieben: Es werde eine Messreihe x_1, \dots, x_n beobachtet.

Test:

Falls $(x_1, \dots, x_n) \in K$: Lehne H_0 ab.

Sonst: Lehne H_0 nicht ab.

Es gibt zwei wichtige Fehlermöglichkeiten:

Fehler 1. Art: H_0 wird abgelehnt, obwohl H_0 zutrifft.

Fehler 2. Art: H_0 wird nicht abgelehnt, obwohl H_0 nicht zutrifft.

Natürlich soll K so gewählt werden, dass die Wahrscheinlichkeit für einen Fehler 1. Art klein ist.

Hierzu wird ein *Testniveau* α vorgegeben und gefordert, dass gilt:

Unter der Nullhypothese gilt $P((X_1, \dots, X_n) \in K) \leq \alpha$.

Im folgenden wird der kritische Bereich mit Hilfe einer zur Nullhypothese passenden Funk-

tion

$$T : \mathbb{R}^n \rightarrow \mathbb{R},$$

der sogenannten *Testgröße*, und geeignete kritische Schranken c bzw. c_1 und c_2 beschrieben. Wir betrachten folgende vier Möglichkeiten:

Falls sowohl große als auch kleine Werte von T gegen H_0 sprechen:

- $K = \{(x_1, \dots, x_n) \in \mathbb{R}^n : |T(x_1, \dots, x_n)| > c\}$,
- $K = \{(x_1, \dots, x_n) \in \mathbb{R}^n : T(x_1, \dots, x_n) < c_1 \text{ oder } T(x_1, \dots, x_n) > c_2\}$.

Falls nur große bzw. kleine Werte von T gegen H_0 sprechen:

- $K = \{(x_1, \dots, x_n) \in \mathbb{R}^n : T(x_1, \dots, x_n) > c\}$,
- $K = \{(x_1, \dots, x_n) \in \mathbb{R}^n : T(x_1, \dots, x_n) < c\}$.

Tests lassen sich nach dem folgenden allgemeinen Prinzip konstruieren.

Konstruktionsprinzip für Test zum Niveau α :

1. Verteilungsannahme formulieren.
2. Nullhypothese H_0 formulieren.
3. Testgröße T wählen und ihre Verteilung unter H_0 bestimmen.
4. $I \subset \mathbb{R}$ so wählen, dass unter H_0 gilt $P(T(X_1, \dots, X_n) \in I) \leq \alpha$.

I wird durch die kritischen Schranken festgelegt und ist von der Form

$$I = \mathbb{R} \setminus [-c, c], \quad I = \mathbb{R} \setminus [c_1, c_2], \quad I =]c, \infty[, \text{ oder } I =]-\infty, c[.$$

Als Werte für das Niveau α werden oft 0.1, 0.05 und 0.01 gewählt.

13.2 Wichtige Test bei Normalverteilungsannahme

Wir nehmen nun an, dass X_1, \dots, X_n unabhängig, identisch $N(\mu, \sigma^2)$ -verteilt sind. Die wichtigsten Tests verwenden Nullhypothesen über Erwartungswert und Varianz.

Wir geben die Konstruktion verschiedener Test nach obigem Prinzip an.

Gauß-Test

1. X_1, \dots, X_n unabhängig, identisch $N(\mu, \sigma_0^2)$ -verteilt, σ_0^2 bekannt.
2. a) $H_0 : \mu = \mu_0$, b) $H_0 : \mu \leq \mu_0$, c) $H_0 : \mu \geq \mu_0$
3. Die Testgröße

$$T(X_1, \dots, X_n) = \frac{\sqrt{n}}{\sigma_0} (\bar{X}_{(n)} - \mu_0)$$

ist nach Satz 11.8.1 $N(0, 1)$ -verteilt, falls $\mu = \mu_0$ gilt.

4. Ablehnung, falls
 - a) $|T| > u_{1-\alpha/2}$, b) $T > u_{1-\alpha}$, c) $T < u_\alpha$.

t-Test

1. X_1, \dots, X_n unabhängig, identisch $N(\mu, \sigma^2)$ -verteilt, σ^2 unbekannt.
2. a) $H_0 : \mu = \mu_0$, b) $H_0 : \mu \leq \mu_0$, c) $H_0 : \mu \geq \mu_0$
3. Die Testgröße

$$T(X_1, \dots, X_n) = \sqrt{n} \frac{\bar{X}_{(n)} - \mu_0}{\sqrt{S_{(n)}^2}}$$

ist nach Satz 11.8.1 t_{n-1} -verteilt, falls $\mu = \mu_0$ gilt.

4. Ablehnung, falls
 - a) $|T| > t_{n-1; 1-\alpha/2}$, b) $T > t_{n-1; 1-\alpha}$, c) $T < t_{n-1; \alpha}$.

χ^2 -Streuungstest

1. X_1, \dots, X_n unabhängig, identisch $N(\mu, \sigma^2)$ -verteilt, μ unbekannt.
2. a) $H_0 : \sigma^2 = \sigma_0^2$, b) $H_0 : \sigma^2 \leq \sigma_0^2$, c) $H_0 : \sigma^2 \geq \sigma_0^2$
3. Die Testgröße

$$T(X_1, \dots, X_n) = \frac{n-1}{\sigma_0^2} \cdot S_{(n)}^2$$

ist nach Satz 11.8.1 χ_{n-1}^2 -verteilt, falls $\sigma^2 = \sigma_0^2$ gilt.

4. Ablehnung, falls
 - a) $T < \chi_{n-1; \alpha/2}^2$ oder $T > \chi_{n-1; 1-\alpha/2}^2$, b) $T > \chi_{n-1; 1-\alpha}^2$, c) $T < \chi_{n-1; \alpha}^2$.

Literaturverzeichnis

- [Br92] D. Braess. *Finite Elemente*. Springer Verlag, Heidelberg, 1992.
- [DB02] P. Deuffhard, F. Bornemann. *Numerische Mathematik II*. de Gruyter, Berlin, 2002.
- [Gr72] R.D. Grigorieff. *Numerik gewöhnlicher Differentialgleichungen 1*. Teubner, Stuttgart, 1972.
- [HNW93] E. Hairer, S. Nørsett, G. Wanner. *Solving Ordinary Differential Equations I*. Springer, Berlin, 1993.
- [Heu89] H. Heuser. *Gewöhnliche Differentialgleichungen*. Teubner, Stuttgart, 1989.
- [vFLSW02] von Finckenstein, Lehn, Schellhaas, Wegmann. *Arbeitsbuch Mathematik für Ingenieure, Bd. II*, Teubner, Stuttgart, 2002
- [Pl00] R. Plato. *Numerische Mathematik kompakt*. Vieweg Verlag, Braunschweig, 2000.
- [St94] J. Stoer. *Numerische Mathematik 1*. Springer Verlag, Berlin, 1994.
- [SB90] J. Stoer, R. Bulirsch. *Numerische Mathematik 2*. Springer Verlag, Berlin, 1990.
- [TS88] W. Törnig, P. Spellucci. *Numerische Mathematik für Ingenieure und Physiker 1*. Springer Verlag, Berlin, 1988.
- [TS90] W. Törnig, P. Spellucci. *Numerische Mathematik für Ingenieure und Physiker 2*. Springer Verlag, Berlin, 1990.
- [We92] J. Werner. *Numerische Mathematik 2*. Vieweg Verlag, Braunschweig, 1992.
- [Wa86] W. Walter. *Gewöhnliche Differentialgleichungen*. Springer, Berlin, 1986.