

Statistik und Wahrscheinlichkeitstheorie

Begleitmaterial zur Vorlesung

WS 2002/2003

O.Univ.Prof. Dipl.-Ing. Dr.techn. Reinhard VIERTL
Institut für Statistik und Wahrscheinlichkeitstheorie
Technische Universität Wien

STATISTIK UND WAHRSCHEINLICHKEITSTHEORIE

I EINLEITUNG

1. Historisches und Grundsätzliches
2. Beschreibende Statistik
3. Wahrscheinlichkeitsbegriffe

II STOCHASTISCHE GRUNDBEGRIFFE

4. Wahrscheinlichkeitsräume
5. Stochastische Unabhängigkeit
6. Stochastische Größen

III EINDIMENSIONALE VERTEILUNGEN

7. Verteilungsfunktion einer 1-dimensionalen Verteilung
8. Diskrete Verteilungen
9. Kontinuierliche Verteilungen
10. Gemischte Verteilungen
11. Erwartungswert einer stochastischen Größe
12. Erwartungswert von Funktionen von stochastischen Größen
13. Gammafunktion und zwei Verteilungen
14. Funktionen von stochastischen Größen
15. Die Tschebyscheff'sche Ungleichung

IV MEHRDIMENSIONALE VERTEILUNGEN

16. Stochastische Vektoren
17. Mehrdimensionale diskrete Verteilungen
18. Mehrdimensionale kontinuierliche Verteilungen
19. Erwartungswert von Funktionen von stochastischen Vektoren
20. Kovarianz, Korrelation und Unabhängigkeit
21. Bedingte Verteilungen
22. Funktionen von stochastischen Vektoren

V FOLGEN STOCHASTISCHER GRÖSSEN

23. Gesetz der großen Zahlen
24. Zentraler Grenzwertungssatz
25. Fundamentalsatz der Statistik
26. Stichproben und Statistiken

VI KLASSISCHE SCHLIESZENDE STATISTIK

27. Klassische Punktschätzungen
28. Konfidenzbereiche
29. Statistische Hypothesen und Tests
30. Tests für Normalverteilungen
31. Chiquadratstest
32. Klassische Regressionsrechnung

VII ELEMENTE DER BAYES-STATISTIK

33. Das Bayes'sche Theorem
34. Suffizienz und konjugierte Verteilungsfamilien
35. Verwendung der A-posteriori-Verteilung
36. Bayes'sche Entscheidungen

VIII ERGÄNZUNGEN

37. Unschärfe Information
38. Kodierungstheorie und Datenübertragung
39. Lebensdauern und Zuverlässigkeit

VORLESUNGSSTRUKTUR: ST. U. WT

- I EINLEITUNG
- II STOCHASTISCHE GRUNDBEGRIFFE
- III EINDIMENSIONALE VERTEILUNGEN
- IV MEHRDIMENSIONALE VERTEILUNGEN
- V FOLGEN STOCHASTISCHER GRÖSSEN
- VI KLASSISCHE SCHLIESZENDE STATISTIK
- VII BAYES'SCHE STATISTIK
- VIII ERGÄNZUNGEN

I

EINLEITUNG

Statistik und Wahrscheinlichkeitstheorie

Offizielle Statistik

Angewandte Statistik

Theoretische Statistik

Wahrscheinlichkeitstheorie

Stochastik

Wozu Statistik u. WR ?

„ Quantitative Erfassung von Massenphänomenen
und Beschreibung von nichtdeterministischen
Vorgängen “

1. Historisches und Grundsätzliches

Stat. Erhebungen: seit ca. 4500 Jahren

Ägypten, China (Militär, Steuer)
seit 550 v. Chr. regelmäßiger „Zensus“
im Röm. Reich

1754 erste Volkszählung in NÖ. (inkl. Wien)

Universitätsstatistik: seit dem 17. Jhdt. Lehre
von den Staatsmerkwürdigkeiten

Name Statistik: ital. statista = Staatsmann
Information zu Bevölkerung, Wirtschaft usw.

6.1

Wahrscheinlichkeitsrechnung: Im 16. Jhdt.

Beschr. von Glücksspielen

Beschr. von Unsicherheit


verschiedene W-Begriffe: objektivistisch
subjektivistisch
axiomatisch

Stochastik: στοχαστικός
στοχασεῖσθαι

Kausalität: deterministisch, stochastisch, fuzzy

1.2

Kausalität



1.3

Begleitende Beispiele:

B1: Stat. Qualitätskontrolle

N... Losumfang, A ... Anzahl schlechter Stücke
n ... Stichprobenumfang, a --- in der SP
Problem: Rückschluss auf A

B2: Lebensdauer eines Produktes

B3: Wartezeit bei einer Bedienstelle

B4: Abhängigkeit einer stochastischen Größe
von einer Kovariablen

1.4

2. Beschreibende Statistik

Merkmale und Häufigkeiten

2.1 Diskrete Merkmale

höchstens abzählbar viele mögliche Werte
die sich nicht häufen

2.1.1 Artmerkmale

A_1, A_2, \dots, A_m versch. mögl. Werte

n Beobachtungen

$H_n(A_j)$ = Anzahl der Beob. mit Wert A_j

2.1

$H_n(A_j)$ absolute Häufigkeit von A_j

$h_n(A_j) := H_n(A_j) / n$ relative — " —

Darstellung von Häufigkeitsverteilungen :

Strichlisten

Balkendiagramme

Kreisdiagramme

2.2

2.1.2 Ordnungsmerkmale

oft durch Zahlen dargestellt
 z_1, z_2, \dots, z_m versch. mögliche Werte

Für n Beobachtungen

$h_n(z_j)$ für $j = 1(1)m$

Darstellung der Häufigkeitsverteilung

Stabdiagramm

Summenkurve

2.3

2.2 Kontinuierliche Merkmale

können alle Zahlen aus einem Intervall annehmen

Für n Beobachtungen x_1, x_2, \dots, x_n

Darstellung der Häufigkeitsverteilung

Empirische Verteilungsfunktion $F_n^*(\cdot)$

$F_n^*(x) := h_n(-\infty, x]$ für jedes $x \in \mathbb{R}$

Ordnungsstatistik $x_{(1)} \leq x_{(2)} \leq \dots \leq x_{(n)}$

2.4

7.X.12

Für größere n bildet man Klassen


$[c_1, c_2], (c_2, c_3], (c_3, c_4], \dots, (c_m, c_{m+1}]$
 $K_1 \quad K_2 \quad K_3 \quad \dots \quad K_m$

relative Häufigkeiten der Klassen

Darstellung: Histogramm

Summenpolygon

Theoretisches Modell: Wahrscheinlichkeitsdichte
Verteilungsfunktion



3. Wahrscheinlichkeitsbegriffe

Stat. Versuch: Wiederholbare Handlung mit mehr oder weniger ungewissem Ausgang

Wahrscheinlichkeiten: Zahlen, die den Grad des Vertrauens in Ereignisse angeben

Ereignis: Eine Menge von möglichen Versuchsausgängen

M ... Merkmalraum = Menge der möglichen Versuchsausgänge

2.1

3.1 Klassische Wahrscheinlichkeitsdefinition

m mögliche Versuchsausgänge

$$M = \{a_1, a_2, \dots, a_m\}$$

Ereignis $A = \{a_{i_1}, \dots, a_{i_g}\}$, g Elemente

$W(A)$... Wahrscheinlichkeit von A

$$W(A) := \frac{g}{m}$$

Anwendung: Qualitätskontrolle

2.2

3.2 Geometrische Wahrscheinlichkeiten

Merkmalraum ∞ , $M \subseteq \mathbb{R}^k$ mit $I(M) < \infty$
alle Teilräume von M mit gleichem Inhalt
sind gleich wahrscheinlich

Für $A \subseteq M$ definiert man


$$W(A) := \frac{I(A)}{I(M)}$$

Bem.: $k=1$ Länge
 $k=2$ Fläche
 $k=3$ Volumen


3.3

Bsp.: Zufällige Ankunft in $[a, b]$
Teilintervall $[a_1, b_1] \subset [a, b]$

Bsp.: Rendezvous-Problem
2 Ankünfte in $[a, b]$, unabhängig



3.4



3.3 Grenzwert von Häufigkeiten

Konvergenzverhalten von $h_n(A)$ für $n \rightarrow \infty$

Empirisches Gesetz der großen Zahlen

$$h_n(A) \underset{n \rightarrow \infty}{\rightsquigarrow} p = W(A), \quad A \text{ fest}$$

Es gilt

$$0 \leq h_n(A) \leq 1 \quad \forall \text{ Ereignisse } A$$

$$A \wedge B \text{ unmöglich} \Rightarrow h_n(A \vee B) = h_n(A) + h_n(B)$$

Bem.: Theorie der Kollektive

3.4 Axiomatische Wahrscheinlichkeiten

Ereignissystem \mathcal{A} orthokomplementärer Verband
 σ -vollständig

\emptyset unmögliches Ereignis

e sicheres Ereignis

A^\perp das zu A komplementäre Ereignis

$$A \wedge A^\perp = \emptyset \quad \text{und} \quad A \vee A^\perp = e$$

$$A_1, A_2, A_3, \dots \text{ Folge mit } A_k \in \mathcal{A} \implies \begin{cases} \bigvee_{k=1}^{\infty} A_k \in \mathcal{A} \\ \bigwedge_{k=1}^{\infty} A_k \in \mathcal{A} \end{cases}$$

2.6

Wahrscheinlichkeitsverteilung W auf \mathcal{A}

$W: \mathcal{A} \rightarrow [0, 1]$ mit

$$W(\emptyset) = 0 \quad \text{und} \quad W(e) = 1$$

Für jede Folge A_1, A_2, A_3, \dots von einander paarweise ausschließenden Ereignissen gilt

$$W\left(\bigvee_{k=1}^{\infty} A_k\right) = \sum_{k=1}^{\infty} W(A_k) \quad \dots \quad \sigma\text{-Add.}$$

Bem.: Endliche Additivität folgt daraus

$$W(A^\perp) = 1 - W(A)$$

2.7

3.5 Subjektive Wahrscheinlichkeiten

Bewertungen der Unsicherheit bedingt durch den Wissensstand H : $W(A|H)$

Ereignisse: A, B ; es muss gelten:

(1) $0 \leq W(A) \leq 1$

(2) Falls A und B einander ausschließen, gilt

$$W(A \vee B|H) = W(A|H) + W(B|H)$$

(3) Falls neue Information verfügbar:

$$W(A \wedge B|H) = W(B|A \wedge H) \cdot W(A|H)$$

II

STOCHASTISCHE GRUNDBEGRIFFE

4. Wahrscheinlichkeitsräume

Spezialfall axiom. W , M Merkmalraum

Spezialfall von \mathcal{A} : Ereignisfeld. \mathcal{L} ist ein

System von Teilmengen von M

$A^{\perp} \cong A^c = M \setminus A$ zu A komplementäres Ereign.

$A \wedge B \cong A \cap B$ sowohl A als auch B Ereignis

$A \vee B \cong A \cup B$ entweder A oder B Ereignis

$\emptyset \cong \emptyset$ unmögliches Ereignis

$e \cong M$ sicheres Ereignis

Wahrscheinlichkeitsverteilung W auf \mathcal{L} :

$W: \mathcal{L} \rightarrow [0, 1]$

$W(M) = 1$

Für jede abzählbare Folge A_1, A_2, A_3, \dots von paarweise disjunkten Ereignissen gilt

$$W\left(\bigcup_{k=1}^{\infty} A_k\right) = \sum_{k=1}^{\infty} W(A_k)$$

Def.: Die Struktur (M, \mathcal{L}, W) heißt ein Wahrscheinlichkeitsraum.

4.1 Diskrete W-Räume

$M = \{a_1, a_2, \dots\}$ höchstens abzählbar unendlich
kein Häufungspunkt
reelle Zahlen p_1, p_2, \dots mit $p_i \geq 0$, $p_i = W(a_i)$
und $\sum_{i=1}^{\infty} p_i = 1$

\mathcal{L} = System aller Teilmengen von M

Für $A \subseteq M$ gilt $W(A) = \sum_{a \in A} W(a)$

Sonderfall: M endlich

4.3

4.2 Kontinuierliche W-Räume

$M = \mathbb{R}^k$, speziell $k=1$

\mathcal{L} = das am wenigsten umfassende Ereignisfeld
auf \mathbb{R}^k , das alle Intervalle umfasst

W-Vtlg. auf \mathcal{L} durch eine sog. Dichtefunktion
bestimmt

$f: \mathbb{R}^k \rightarrow [0, \infty)$ mit $\int_{-\infty}^{\infty} \dots \int_{-\infty}^{\infty} f(x_1, \dots, x_k) dx_1 \dots dx_k = 1$

Für $B \in \mathcal{L}$ gilt $W(B) := \int_B f(x_1, \dots, x_k) dx_1 \dots dx_k$

4.4

4.3 Satz: In jedem W -Raum gilt:

$$(1) A, B \in \mathcal{E} \text{ mit } A \subseteq B \Rightarrow W(A) \leq W(B)$$

$$(2) \text{ und } W(B \setminus A) = W(B) - W(A)$$

$$\text{Bew.: } B = A \cup (A^c \cap B) \Rightarrow W(B) = W(A) + W(A^c \cap B)$$

$$A^c \cap B = B \setminus A \Rightarrow W(B \setminus A) = W(B) - W(A) \quad //$$

Folgerung: $W(A^c) = 1 - W(A)$

4.4 Additionstheorem: In jedem W -Raum gilt für beliebige Ereignisse A, B, A_k :

$$(1) W(A \cup B) = W(A) + W(B) - W(A \cap B)$$

4.5

$$(2) W\left(\bigcup_{k=1}^n A_k\right) = \sum_{\{i_1, \dots, i_m\} \subseteq \{1, \dots, n\}} (-1)^{m-1} W(A_{i_1} \cap \dots \cap A_{i_m})$$

$$\text{Bew.: (1) } A \cup B = A \cup (A^c \cap B)$$

$$B = (A \cap B) \cup (A^c \cap B)$$

$$W(A \cup B) = W(A) + W(A^c \cap B)$$

$$- W(B) = -W(A \cap B) \pm W(A^c \cap B)$$

$$\underline{W(A \cup B) - W(B) = W(A) - W(A \cap B)} \Rightarrow (1)$$

(2) vollständige Induktion nach n

4.6

4.5 Bedingte Wahrscheinlichkeit

Def.: Sind A und B Ereignisse eines W -Raumes mit $W(A) > 0$, so ist die bedingte Wahrscheinlichkeit von B

$$W(B|A) := \frac{W(A \cap B)}{W(A)}$$

Bem.: Ist A fest, so entsteht eine neue W -Vtlg., genannt Bedingte Verteilung W_A auf $A \cap \mathcal{E}$

$$W_A(B \cap A) = W(B|A)$$

4.7

4.6 Multiplikationstheorem für Wahrsch.

In jedem W -Raum gilt für Ereignisse A, B, A_k , falls die bed. $W. \exists$:

$$(1) \quad W(A \cap B) = W(B|A) \cdot W(A)$$

$$= W(A|B) \cdot W(B)$$

$$(2) \quad W\left(\bigcap_{k=1}^n A_k\right) = W(A_1) \cdot W(A_2|A_1) \cdot W(A_3|A_1 \cap A_2)$$

$$\dots W(A_n|A_1 \cap \dots \cap A_{n-1})$$

Bew.: (1) aus der Def. der bed. $W.$

(2) vollständige Induktion nach n .

4.8


4.7 Satz von der vollständigen Wahrscheinl. und Bayes'sche Formel

Ist H_1, \dots, H_n eine Zerlegung von M in Ereignisse, so gilt für jedes Ereignis A :

$$(1) \quad W(A) = \sum_{k=1}^n W(H_k) \cdot W(A|H_k)$$

$$(2) \quad W(H_i|A) = \frac{W(H_i) \cdot W(A|H_i)}{\sum_{k=1}^n W(H_k) \cdot W(A|H_k)} \quad \forall i=1(1)n$$

Beweis: (1)



$$A = A \cap M = A \cap \left[\bigcup_{k=1}^n H_k \right] = \bigcup_{k=1}^n (A \cap H_k)$$

da H_1, \dots, H_n paarweise disjunkt

$\Rightarrow A \cap H_1, \dots, A \cap H_n$ paarweise disjunkt

$$\Rightarrow W(A) = W\left(\bigcup_{k=1}^n (A \cap H_k)\right) = \sum_{k=1}^n W(A \cap H_k)$$

$$= \sum_{k=1}^n W(A|H_k) \cdot W(H_k) \quad \text{wegen Multiplikationstheorem}$$

(1) heißt Satz v. d. vollst. Wahrsch.

$$(2) \quad W(H_i|A) = \frac{W(A \cap H_i)}{W(A)} = \frac{W(A|H_i) \cdot W(H_i)}{\sum_{k=1}^n W(A|H_k) \cdot W(H_k)}$$

Bayes'sche Formel

Bem.: $W(H_k)$... A-priori-Wahrsch. der H_k
 $W(H_k|A)$... A-posteriori-Wahrsch. der H_k
 (nach dem Eintritt von A)

Anwendung: QK, Warensendung, gleiche Produkte von n Maschinen mit versch. Ausschusshäufigkeiten (Wahrsch.)

H_k ... k -te Maschine, $k=1(1)n$

A ... Ausschussstück

$W(A|H_k)$

Zusammengesetzte Warensendung

$W(H_k)$ = Wahrsch. Stück von Maschine k

Frage 1: Wahrsch., dass ein Stück aus der Warensendung Ausschuss ist?

$$W(A) = \sum_{k=1}^n W(A|H_k) \cdot W(H_k)$$

Frage 2: Wahrsch., dass ein Ausschussstück von der i -ten Maschine stammt?

$$W(H_i|A) = \text{Bayes'sche Formel}$$

5. Stochastische Unabhängigkeit

Beispiel: QK, mit Zurücklegen
ohne — " —

Zusammengesetzte Versuche

$(M_1, \mathcal{L}_1, W_1), (M_2, \mathcal{L}_2, W_2), A_i \in \mathcal{L}_i$

$(M_1 \times M_2, \mathcal{L}_1 \otimes \mathcal{L}_2, W_1 \otimes W_2)$

$W_1 \otimes W_2(A_1 \times A_2) := W_1(A_1) \cdot W_2(A_2)$

\exists ! W-Vtlg. $W_1 \otimes W_2$ auf $\mathcal{L}_1 \otimes \mathcal{L}_2$

Def.: Zwei Ereignisse A und B eines
W-Raumes heißen unabhängig, i.Z.

$A \perp\!\!\!\perp B$, wenn gilt:

$$W(A \cap B) = W(A) \cdot W(B)$$

Es gilt:

$$A \perp\!\!\!\perp B \iff \begin{cases} W(A|B) = W(A|B^c) = W(A) \\ W(B|A) = W(B|A^c) = W(B) \end{cases}$$

Bew.: 1) $A \perp\!\!\!\perp B \Rightarrow W(A \cap B) = W(A) \cdot W(B)$

$\Rightarrow W(A|B) = W(A)$; zu $W(A|B^c)$:

$A = (A \cap B) \cup (A \cap B^c) \Rightarrow W(A) = W(A \cap B) + W(A \cap B^c)$

$\Rightarrow W(A \cap B^c) = W(A) \cdot [1 - W(B)] = W(A) \cdot W(B^c)$

5.

2) Umkehrung: Ü

5

Für mehrere Ereignisse: A_1, \dots, A_n heiÙe

unabhängig,
wenn \forall Teilfamilien A_{j_1}, \dots, A_{j_k} gilt:
 $W\left(\bigcap_{i=1}^k A_{j_i}\right) = \prod_{i=1}^k W(A_{j_i}), j_i \in \{1, \dots, n\}$

B1: Stichprobe mit Zurücklegen aus N
n Stücke, A schlechte Stücke

$$W(\{x_1, \dots, x_n\}) = W(\{x_1^0\} \cap \dots \cap \{x_n^0\}) = \prod_{i=1}^n W_e(\{x_i\})$$

Sind genau k Einser im n-Tupel \Rightarrow

$$W(\{x_1, \dots, x_n\}) = p^k (1-p)^{n-k}, k = 0(1)n$$

$$p = \frac{A}{N}$$


Bem.: Wesentlich ist die Anzahl
schlechter Stücke

$$\sum_{i=1}^n x_i$$

6. Stochastische Größen

Alle nichtdeterministischen Größen

Beispiel: Minimaltemperatur innerhalb der nächsten 24 Stunden,
Funktion des Temperaturverlaufes $y(t)$



$$X = \min_{0 \leq t \leq 24} y(t)$$

2-dimensionale stochastische Größe

$$\begin{pmatrix} X \\ Y \end{pmatrix} = \begin{pmatrix} \max y(t) \\ \min y(t) \end{pmatrix} = \underline{X} \quad \text{stoch. Vektor}$$

B1: X = Anzahl schlechter Stücke in den n ausgewählten

$$M_X = \{0, 1, 2, \dots, n\}$$

$$\omega = (x_1, \dots, x_n) \in M_e^n \quad \text{mit } M_e = \{0, 1\}$$

$$X = X(\omega) = \sum_{i=1}^n x_i$$

Bem.: Stoch. Größen als Funktionen auf Ω -Räumen aufgefasst

Definition: X auf (M, \mathcal{F}, W) : \mathcal{B}_k Borel-
 $X: M \rightarrow \mathbb{R}^k$ mit $X^{-1}(B) \in \mathcal{F} \quad \forall B \in \mathcal{B}$
wobei $X^{-1}(B) := \{\omega \in M: X(\omega) \in B\}$

Es gilt: Im Falle 1-dim. st. Gr. X
d.h. $k=1$, gilt (hinreichend)

$$X^{-1}((-\infty, a]) = \{\omega: X(\omega) \leq a\} \in \mathcal{F} \quad \forall a \in \mathbb{R}$$

W.-Vtlg. von X :

$$W_X\{X \in B\} := W(X^{-1}(B)) \quad \forall B \in \mathcal{B}$$

B1: Punktwahrscheinlichkeiten

$$\begin{aligned} W\{X=k\} &= W_{\text{prod}}(X^{-1}(\{k\})) = \\ &= W_{\text{pr}}(\{(x_1, \dots, x_n): \sum_{i=1}^n x_i = k\}) = W_{\text{pr}}\left(\bigcup_{\substack{(x_1, \dots, x_n): \\ \sum x_i = k}} \{(x_1, \dots, x_n)\}\right) \\ &= \sum_{\substack{(x_1, \dots, x_n): \\ \sum x_i = k}} W_{\text{prod}}(\{(x_1, \dots, x_n)\}) = \binom{n}{k} p^k (1-p)^{n-k} \\ & \quad = p^k (1-p)^{n-k} \quad \text{für } k=0(1)n \end{aligned}$$



EINDIMENSIONALE VERTEILUNGEN

7. Verteilungsfunktionen

Def.: Die Verteilungsfunktion von X , $F(\cdot)$

$$F(x) := W\{X \leq x\} \quad \forall x \in \mathbb{R}$$

Bem.: $\{X \leq x\} := X^{-1}((-\infty, x])$

7.1 Eigenschaften von VF $F(\cdot)$

$$(1) \quad 0 \leq F(x) \leq 1 \quad \forall x \in \mathbb{R}$$

$$(2) \quad x_1 < x_2 \Rightarrow F(x_1) \leq F(x_2)$$

$$(3) \quad \lim_{x \rightarrow -\infty} F(x) = 0 \quad \text{und} \quad \lim_{x \rightarrow \infty} F(x) = 1$$

$$(4) \quad \lim_{h \downarrow 0} F(x+h) = F(x) \quad \forall x \in \mathbb{R}$$

Rechtsstetigkeit

Es gilt: Hat X die VF $F(\cdot)$, so folgt

$$(a) \quad W\{X = x\} = F(x) - \lim_{h \downarrow 0} F(x-h)$$

$$(b) \quad W\{a < X \leq b\} = F(b) - F(a)$$


Begr. von (b): Ereignis $(a, b] = (-\infty, b] \setminus (-\infty, a]$

$$\Rightarrow W((a, b]) = W((-\infty, b] \setminus (-\infty, a])$$

$$= W((-\infty, b]) - W((-\infty, a]) = F(b) - F(a) \quad //$$

7.2 Typen von VF

a) treppenförmig



b) stetige, stückw. diffb.:


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

c) Mischungen aus a) und b):

$$F(x) = p F_1(x) + (1-p) F_2(x) \quad \forall x \in \mathbb{R}$$

$p \in (0,1)$


$F_1(\cdot)$ treppenf., $F_2(\cdot)$ stetig



Def.: p-Fraktile x_p zur VF $F(\cdot)$:
 $F(x_p) = p$ mit $p \in (0,1)$

Bem.: 1) $X \sim F(\cdot) \Rightarrow W\{X \leq x_p\} = p$

2) p-Fraktile müssen weder existieren, noch eindeutig sein



21. III. '11

8. Diskrete 1-dim. Verteilungen von stoch. Größen X

M_X höchstens abzählbar, $M_X \subset \mathbb{R}$
 ohne Häufungspunkt


$$M_X = \{a_i : i \in I \subseteq \mathbb{N}\}$$

$$W\{X = a_i\} = W(\{a_i\}) = p(a_i) \geq 0$$

mit $\sum_{i \in I} p(a_i) = 1$

$p(a_i)$... Punktwahrscheinlichkeit von a_i

Stabdiagramm:



Bem.: VF dazu ist eine Treppenfunktion
 $W(\{x\}) = 0 \quad \forall x \notin M_X$

8.1 Dirac-Verteilung δ_μ , $\mu \in \mathbb{R}$

$$X \sim \delta_\mu \Leftrightarrow W\{X=\mu\} = 1 \quad \text{Determinismus}$$

8.2 Diskrete Gleichverteilung D_m , $m \in \mathbb{N}$

$$M = \{1, 2, \dots, m\}$$

$$p(k) = \frac{1}{m} \quad \forall k \in M$$

8.3 Alternativverteilung A_p , $p \in (0, 1)$

$$M = \{0, 1\}$$

$$W\{X=1\} = p$$

$$W\{X=0\} = 1-p \quad \Leftrightarrow: X \sim A_p$$

8.4 Binomialverteilung $B_{n,p}$

Ziehungen mit Zurücklegen


n unabhängige Alternativversuche

$X = \text{Anzahl der Einsen} \Rightarrow X \sim B_{n,p}$

$$M_X = \{0, 1, 2, \dots, n\}$$

$$W\{X=k\} = \binom{n}{k} p^k (1-p)^{n-k} \quad \forall k \in M_X$$

Stabdiagramme verschiedener Binomialverteilungen $B_{10,p}$



8.5 Hypergeometrische Vtlg. $H_{N,A,n}$

Ziehungen ohne Zurücklegen

N Elemente, A Ausschusstücke

n Stück gezogen (Stichprobenumfang $n < N$)

X Anzahl der Ausschusstücke in der SP

$$M_X = \{k_1, k_1+1, k_1+2, \dots, k_2\}$$

$$\text{mit } k_1 = \max(0, n-(N-A))$$

$$k_2 = \min(n, A)$$

$$W\{X=a\} = \frac{\binom{A}{a} \binom{N-A}{n-a}}{\binom{N}{n}} \quad \text{für } a = k_1(1)k_2$$

Begründung: klass. W-Def., $\binom{N}{n}$ mögliche
Auswahlen ohne Wiederholung

$\binom{A}{a}$ Auswahlen von a schlechten Stücken

$\binom{N-A}{n-a}$ Auswahlen von n-a guten Stücken

Bem.: Approximation für $n < \frac{N}{10}$:

$$H_{N,A,n} \approx B_{n, \frac{A}{N}}$$

Übung: Vergleich der Punktwahrscheinl.

8.6 Poisson-Vtlg. P_μ , $\mu > 0$

$$X \sim P_\mu \Leftrightarrow M_X = N_\mu$$

$$W\{X=k\} = \frac{\mu^k e^{-\mu}}{k!} \quad \text{für } k=0(1)\infty$$

Bem.: $0! := 1$, Exponentialreihe $e^x = \sum_{k=0}^{\infty} \frac{x^k}{k!}$

Approximationen

$$B_{n,p} \approx P_{n,p} \quad \text{für } n > 50, p < \frac{1}{10}$$

$$H_{N,A,n} \approx P_{n, \frac{A}{N}} \quad \text{für } n < \frac{N}{10}, A < \frac{N}{10}$$

8.7 Geometrische Vtlg. G_p , $0 < p < 1$

Alternativversuch so oft unabhängig
durchgeführt bis erstmals „1“ kommt

$$X \sim G_p \Leftrightarrow \begin{cases} M_X = \frac{1}{p} \\ W\{X=n\} = p \cdot (1-p)^{n-1} \end{cases}$$

Bem.: Geometrische Reihe

$$\sum_{n=1}^{\infty} p(1-p)^{n-1} = 1$$

9. Kontinuierliche 1-dim. Verteilungen bzw. kontin. stoch. Größen

Kontin. stoch. Größen X nehmen alle Werte eines Intervalls an, (stetige stoch. Gr.)

Ihre W-Vtlg. wird durch eine sog. Dichtefunktion

$$f: \mathbb{R} \rightarrow [0, \infty)$$

$$\text{mit } \int_{-\infty}^{\infty} f(x) dx = 1$$

bestimmt.


$$W\{a \leq X \leq b\} := \int_a^b f(x) dx$$

zugehörige Verteilungsfunktion $F(\cdot)$

$$\text{Es gilt: 1) } F(x) = \int_{-\infty}^x f(t) dt$$

$$2) f(x) = \frac{d}{dx} F(x) \quad \forall x \text{ wo } F(\cdot) \text{ differenzierbar}$$

$$3) W\{X=x\} = 0 \quad \forall x \in \mathbb{R}$$





Definition: Die Indikatorfunktion $I_A(\cdot)$ einer Teilmenge $A \subseteq M$ ist

$$I_A(x) = \begin{cases} 1 & \text{für } x \in A \\ 0 & \text{für } x \notin A \end{cases}$$

9.1 Uniforme Vtlg. $U_{a,b}$, $a < b \in \mathbb{R}$

$$f(x) = \frac{1}{b-a} I_{(a,b)}(x) \quad \forall x \in \mathbb{R}$$



9.2 Exponentialverteilung Ex_τ , $\tau > 0$

$$f(x) = \frac{1}{\tau} e^{-\frac{x}{\tau}} I_{(0,\infty)}(x)$$

$$F(x) = (1 - e^{-\frac{x}{\tau}}) I_{[0,\infty)}(x)$$

9.3 Standard-Normalverteilung $N(0,1)$

Dichte $\varphi(x) = \frac{1}{\sqrt{2\pi}} e^{-\frac{x^2}{2}} \quad \forall x \in \mathbb{R}$

VF $\Phi(x) = \int_{-\infty}^x \varphi(t) dt$ tabelliert

Es gilt: $\Phi(-x) = 1 - \Phi(x) \quad \forall x > 0$

→ Abb.

9.4 Allgem. Normalvltg. $N(\mu, \sigma^2)$, $\mu \in \mathbb{R}$ $\sigma^2 > 0$

$f(x) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{(x-\mu)^2}{2\sigma^2}} \quad \forall x \in \mathbb{R}$

→ Abb.

Satz 9.1: Für die VF $F(\cdot | \mu, \sigma^2)$ der $N(\mu, \sigma^2)$ gilt:



$$F(x | \mu, \sigma^2) = \Phi\left(\frac{x-\mu}{\sigma}\right) \quad \forall x \in \mathbb{R}$$

Beweis: Integral $\int_{-\infty}^x f(t) dt$ transformieren


Substitution $\frac{t-\mu}{\sigma} = u$, $dt = \sigma du$

$$\begin{aligned} \Rightarrow \int_{-\infty}^x f(t) dt &= \int_{-\infty}^{\frac{x-\mu}{\sigma}} \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{u^2}{2}} \sigma du & \begin{array}{c|c} t & u \\ \hline -\infty & -\infty \\ x & \frac{x-\mu}{\sigma} \end{array} \\ &= \Phi\left(\frac{x-\mu}{\sigma}\right) // \end{aligned}$$

$N(0,1)$ -Verteilung



Normalverteilung



9.3.1

9.5 Logarithmische Normalverteilung

$$LN(\mu, \sigma^2), \mu \in \mathbb{R}, \sigma^2 > 0$$

$$X \sim LN(\mu, \sigma^2) \Leftrightarrow \begin{aligned} M_X &= (0, \infty) \\ \ln X &\sim N(\mu, \sigma^2) \end{aligned}$$

Verteilungsfunktion


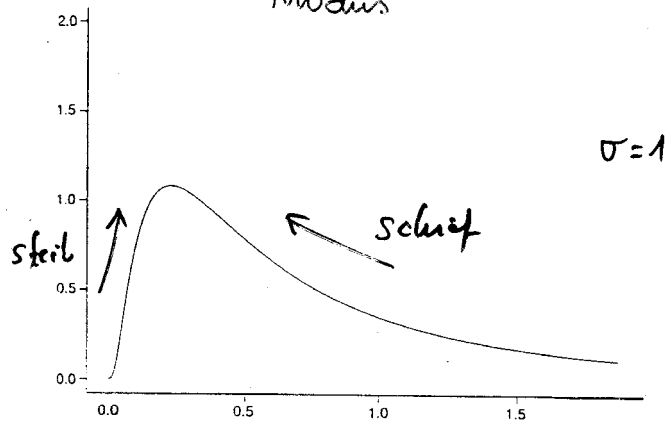

$$\begin{aligned} F_X(x) &= W\{X \leq x\} = W\{\ln X \leq \ln x\} \\ &= F_{N(\mu, \sigma^2)}(\ln x) = \Phi\left(\frac{\ln x - \mu}{\sigma}\right) \quad \forall x > 0 \end{aligned}$$

Dichtefunktion $f(x) = F'(x)$

→ Diagramm


9.4

$$X \sim \text{LN}(\mu, \sigma^2), \quad EX = \mu + \frac{\sigma^2}{2} = 1$$



10. Gemischte Verteilungen

Beispiel: Wartezeit, Ampel
 Grünphase a [sec.], Rotphase b [sec.]
 Ankunft zufällig ... $T \sim U_{0, a+b}$



$$\text{Wartezeit } X = \begin{cases} 0 & \text{für } T \in [0, a) \\ a+b-T & \text{für } T \in [a, a+b) \end{cases}$$

W-Vtlg. von X :


$$W\{X=0\} = W\{T \in [0, a)\} = \frac{a}{a+b} > 0$$

$$W\{0 < X \leq x\} = W\{T \in [a+b-x, a+b)\} = \frac{x}{a+b}$$

für $0 < x < b$

$$\Rightarrow W\{X \leq x\} = \frac{a}{a+b} + \frac{x}{a+b} \quad \text{für } 0 \leq x \leq b$$

VF $F_X(x)$ der Wartezeit:



Bem.:
 modifizierte
 Dichte

11. ERWARTUNGSWERT

Mittlerer Wert einer Verteilung

Beispiel D_m Mittelwert

$$\frac{1}{m} \sum_{i=1}^m x_i = \sum_{i=1}^m x_i p(x_i)$$

11.1 Diskrete Verteilungen

$$X \sim (M_X, p(x)) = W\{X=x\}, x \in M_X$$

Erwartungswert $\mathbb{E}X = \text{Mittel } \mu \text{ der Verteilung von } X$

$$\mathbb{E}X := \sum_{x: p(x) > 0} x \cdot p(x)$$

11.1

11.2 Kontinuierliche Verteilungen

$$X \sim f(\cdot)$$

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

Bem.: Massenschwerpunkt

$$\text{Beispiele: } X \sim \text{Ex}_{\tau} \Rightarrow \mathbb{E}X = \tau$$

$$X \sim N(\mu, \sigma^2) \Rightarrow \mathbb{E}X = \mu$$

$$X \sim U_{a,b} \Rightarrow \mathbb{E}X = \frac{a+b}{2}$$

11.2

11.3 Gemischte Verteilungen

$$X \sim (M_X = \{x_1, \dots, x_m\} \cup \langle a, b \rangle, p(x_i), f(\cdot))$$

$$0 < \sum_{i=1}^m p(x_i) < 1 \text{ und } \int_a^b f(x) dx = 1 - \sum_{i=1}^m p(x_i)$$

$$\mathbb{E}X := \sum_{i=1}^m x_i p(x_i) + \int_a^b x f(x) dx$$

Beispiele: Mittlere Wartezeit in Abschn. 10

Erwartungswerte von Lebensdauern

Bem.: Allgem. $\mathbb{E}X = \int_{-\infty}^{\infty} x dF(x)$

11.3

12. FUNKTIONEN VON STOCH. GRÖSSEN - ERWARTUNGSWERT

X Stoch. Gr., $\psi: \mathbb{R} \rightarrow \mathbb{R}$ (messbar)

$$\Rightarrow Y := \psi(X) :$$

Wert von $Y := \psi(\text{Wert von } X)$

$$\Rightarrow Y \text{ Stoch. Gr.}$$

Frage: $\mathbb{E}Y$

$$\text{i.A. } \mathbb{E}\psi(X) \neq \psi(\mathbb{E}X)$$

Bem.: Für lineares $\psi(\cdot)$ Gleichheit

12.1

12. FUNKTIONEN VON STOCH. GRÖSSEN - ERWARTUNGSWERT

X Stoch. Gr., $\psi: \mathbb{R} \rightarrow \mathbb{R}$ (messbar)

$\Rightarrow Y := \psi(X)$:

Wert von $Y := \psi(\text{Wert von } X)$

$\Rightarrow Y$ Stoch. Gr.

Frage: $\mathbb{E}Y$

i.A. $\mathbb{E}\psi(X) \neq \psi(\mathbb{E}X)$

Bem.: Für lineares $\psi(\cdot)$ Gleichheit

12.1

12.1 Satz vom unbewussten Statistiker

(1) Ist X diskret vt. $X \sim p(\cdot)$, $\psi: \mathbb{R} \rightarrow \mathbb{R}$ messbar
und $\exists \mathbb{E}[\psi(X)]$, so gilt :

$$\mathbb{E}[\psi(X)] = \sum_{x: p(x) > 0} \psi(x) p(x)$$

(2) Ist X kontin. vt. $X \sim f(\cdot)$, $\psi: \mathbb{R} \rightarrow \mathbb{R}$ wie in (1),
so gilt :

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

(3) Allgem.: $\mathbb{E}[\psi(X)] = \int_{-\infty}^{\infty} \psi(x) dF(x)$

12.2

12.2 Varianz

Falls die folgende Erwartung existiert, heißt

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

Varianz von X bzw. Varianz der Verteilung

Berechnung mittels des SvuStat.

Für gemischte Verteilungen:

$$\text{Var } X = \sum_{i=1}^m (x_i - \mathbb{E}X)^2 p(x_i) + \int_a^b (x - \mathbb{E}X)^2 f(x) dx$$

Bsp.: Wartezeit aus Abschnitt 10

12.3

$$X \sim N(\mu, \sigma^2) \Rightarrow \text{Var } X = \sigma^2$$

$$X \sim \text{Ex}_{\tau} \Rightarrow \text{Var } X = \tau^2$$

$$X \sim A_p \Rightarrow \text{Var } X = p(1-p)$$

$$X \sim B_{n,p} \Rightarrow \text{Var } X = np(1-p)$$

$$X \sim U_{a,b} \Rightarrow \text{Var } X = \frac{(b-a)^2}{12}$$

12.3 Satz: Ist X eine St. Gr. mit $\exists \text{Var } X$

und $c \in \mathbb{R}$, $d \in \mathbb{R}$, konstant, so gilt:

$$(1) \text{Var}(X+d) = \text{Var } X$$

$$(2) \text{Var}(cX) = c^2 \text{Var } X$$

$$(3) \text{Var}(cX+d) = c^2 \text{Var } X$$

12.4

$$\begin{aligned}
 \text{Beweis: (3) } \text{Var}(cX+d) &= \mathbb{E}[\{cX+d - \mathbb{E}(cX+d)\}^2] \\
 &= \mathbb{E}[\{cX+d - c\mathbb{E}X - d\}^2] = \mathbb{E}[c^2(X - \mathbb{E}X)^2] \\
 &= c^2 \mathbb{E}[(X - \mathbb{E}X)^2] = c^2 \text{Var} X \quad //
 \end{aligned}$$

12.4 Verschiebungssatz: Ist X eine SG mit existierender Varianz, so gilt:

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

$$\begin{aligned}
 \text{Beweis: } \text{Var} X &= \mathbb{E}[(X - \mathbb{E}X)^2] = \mathbb{E}[X^2 - 2(\mathbb{E}X)X + (\mathbb{E}X)^2] \\
 &= \mathbb{E}(X^2) - 2(\mathbb{E}X)\mathbb{E}X + \mathbb{E}[(\mathbb{E}X)^2] = \mathbb{E}(X^2) - 2(\mathbb{E}X)^2 + \\
 &+ (\mathbb{E}X)^2 = \mathbb{E}(X^2) - (\mathbb{E}X)^2 \quad //
 \end{aligned}$$

12.5

12.5 Standardisierung

Def.: $\sqrt{\text{Var} X}$ heißt Streuung von X

Def.: Ist X SG mit $\exists \text{Var} X = \sigma^2$ ($\Rightarrow \exists \mathbb{E}X = \mu$), so ist die zugeh. Standardisierte SG

$$\frac{X - \mu}{\sigma}$$

$$\text{Es gilt: (1) } \mathbb{E}\left(\frac{X - \mu}{\sigma}\right) = 0$$

$$(2) \text{Var}\left(\frac{X - \mu}{\sigma}\right) = 1$$

$$\text{Bew.: (1) } \frac{X - \mu}{\sigma} = \frac{1}{\sigma}(X - \mu) \quad \text{und} \quad \mathbb{E}\left(\frac{1}{\sigma}(X - \mu)\right) = \dots$$

12.6

13. GAMMAFUNKTION UND ZWEI VERTEILUNGEN

$$n \in \mathbb{N} \Rightarrow n! := n(n-1)(n-2) \dots 3 \cdot 2 \cdot 1$$


Fortsetzung dieser Funktion $n \rightarrow n!$ zu einer Funktion auf $(-1, \infty)$:

$$x \rightarrow x! := \int_0^x t^{x-1} e^{-t} dt$$

Bew.: partielle Integration

13.1 Gammafunktion

$$x \rightarrow \Gamma(x) := \int_0^{\infty} t^{x-1} e^{-t} dt \quad \text{für } x > 0$$



Es gilt: 1) $\Gamma(x) = (x-1)\Gamma(x-1)$

2) $\Gamma(n) = (n-1)!$ $\forall n \in \mathbb{N}$

3) $\Gamma(\frac{1}{2}) = \sqrt{\pi}$


13.2 Gammaverteilung $\text{Gam}(\alpha, \beta)$, $\alpha > 0, \beta > 0$

$$\text{Dichte } f(x) = \frac{x^{\alpha-1} e^{-\frac{x}{\beta}}}{\Gamma(\alpha) \cdot \beta^\alpha} I_{(0, \infty)}(x)$$

Es gilt: $X \sim \text{Gam}(\alpha, \beta) \Rightarrow \mathbb{E}X = \alpha\beta$
 $\text{Var } X = \alpha\beta^2$

$\text{Gam}(\frac{n}{2}, 2) \dots \chi_n^2$ Chiquadrat-Vtlg.

Dichtefunktionen von χ_n^2 -Verteilungen



13.3 t_n -Verteilung, $n \in \mathbb{N}$

$$\text{Dichte } f(x) = \frac{\Gamma(\frac{n+1}{2})}{\Gamma(\frac{n}{2})\sqrt{n\pi}} \cdot \frac{1}{(1+\frac{x^2}{n})^{\frac{n+1}{2}}} \quad \forall x \in \mathbb{R}$$

$$\text{Es gilt: } X \sim t_n \Rightarrow \mathbb{E}X = 0 \quad \forall n > 1$$

$$\text{Var}X = \frac{n}{n-2} \quad \forall n > 2$$

Bem.: Für $n \rightarrow \infty$ konvergiert die Dichte gegen die Dichte der $N(0,1)$

13.4

14. VERTEILUNG VON FUNKTIONEN STOCH. GRÖSSEN

X SG, $\psi: \mathbb{R} \rightarrow \mathbb{R}$ messbar $Y = \psi(X)$

$F(\cdot)$ VF von X

gesucht: VF $G(\cdot)$ von Y

14.1 Satz: $X \sim F(\cdot)$, $\psi: \mathbb{R} \rightarrow \mathbb{R}$ monoton und invertierbar, so hat $Y = \psi(X)$ die VF

$$G(x) = F(\psi^{-1}(x)) \quad \forall x \in \mathbb{R}$$

$$\text{Bew.: } G(x) = W\{Y \leq x\} = W\{\psi(X) \leq x\}$$

$$= W\{X \leq \psi^{-1}(x)\} = F(\psi^{-1}(x)) \quad \forall x \in \mathbb{R} //$$

14.1

14.2 Satz: Gilt zusätzlich zu den Vorausss. von Satz 14.1 dass X kontin. vt. ist mit Dichte $f(\cdot)$ und dass $\psi^{-1}(\cdot)$ differenzierbar ist, so ist $Y = \psi(X)$ auch kontin. vt. mit folgender Dichte $g(\cdot)$:

$$g(x) = f(\psi^{-1}(x)) \cdot \left| \frac{d}{dx} \psi^{-1}(x) \right|$$

Bew.: Kettenregel der Diff.-Rechnung

Beispiel: $X \sim N(0,1)$, gesucht: Vtlg. von X^2
 VF $G(\cdot)$ von X^2 : $G(x) = W\{X^2 \leq x\}$ (Bem. zu Satz)
 $= W\{-\sqrt{x} \leq X \leq \sqrt{x}\} = \Phi(\sqrt{x}) - \Phi(-\sqrt{x}) = 2\Phi(\sqrt{x}) - 1$

14.2

Differentiation von $G(\cdot)$ ergibt die Dichte $g(\cdot)$ von X^2

$$g(x) = \frac{d}{dx} G(x) = 2\Phi'(\sqrt{x}) \cdot \frac{1}{2} \cdot x^{-\frac{1}{2}} \quad \text{für } x > 0$$

$$= \frac{1}{\sqrt{2\pi}} e^{-\frac{x}{2}} x^{-\frac{1}{2}} I_{(0,\infty)}(x) \hat{=} \chi_1^2$$

$$\text{(da } \Gamma(\frac{1}{2}) = \sqrt{\pi} \text{)}$$

14.3 Satz: Gilt $X \sim N(\mu, \sigma^2)$ und sind $c, d \in \mathbb{R}$ mit $c \neq 0$, so gilt:

$$cX + d \sim N(c\mu + d, c^2\sigma^2)$$

Bew.: Satz 9.1 und Anwendung von Satz 14.2 //

14.3

14.4 Satz: (1) Ist $X \sim F(\cdot)$ und $\exists F^{-1}(\cdot)$

$$\Rightarrow F(X) \sim U_{0,1}$$

(2) Ist $F(\cdot)$ eine invertierbare VF und $Y \sim U_{0,1}$

$$\Rightarrow F^{-1}(Y) \text{ hat die VF } F(\cdot)$$

Bew.: (1) Ist $G(\cdot)$ die VF der SG $F(X)$, so gilt

$$\text{für } y \in [0,1]: G(y) = W\{F(X) \leq y\} = W\{X \leq F^{-1}(y)\}$$

$$= F(F^{-1}(y)) = y \Rightarrow G(\cdot) \text{ ist die VF der}$$

kontin. Gleichverteilung $U_{0,1}$


zu (2): Für die VF $H(\cdot)$ der SG $F^{-1}(Y)$ gilt:

14.4

$$H(x) = W\{F^{-1}(Y) \leq x\} = W\{Y \leq F(x)\} = F(x)$$

$$\forall x \in \mathbb{R}, \text{ da } Y \sim U_{0,1} \Rightarrow F^{-1}(Y) \sim F(\cdot) //$$

Bem.:



Anwendung: Computersimulation von Verteilungen
mit Hilfe der Simulation der $U_{0,1}$

14.5

15. TSCHEBYSCHESCHE UNGLEICHUNG

Abschätzung zum Beweis des Gesetzes der großen Zahlen


15.1 Tsch.-U.: Für jede SG X mit $\exists \text{Var } X$ gilt $\forall \varepsilon > 0$:

$$W\{|X - \mathbb{E}X| \geq \varepsilon\} \leq \frac{\text{Var } X}{\varepsilon^2}$$

Bew.: (für kontin. vt. SG) $X \sim f(\cdot)$, $\mu = \mathbb{E}X$, $\sigma^2 = \text{Var } X$

$$\frac{\sigma^2}{\varepsilon^2} = \frac{1}{\varepsilon^2} \int_{-\infty}^{\infty} (x - \mu)^2 f(x) dx = \frac{1}{\varepsilon^2} \int_{\{|x - \mu| \geq \varepsilon\}} (x - \mu)^2 f(x) dx +$$

Bem. Die Tsch. U. ist sehr grob



$$\text{da } |x - \mu| \geq \varepsilon \Leftrightarrow \left(\frac{x - \mu}{\varepsilon}\right)^2 \geq 1$$

$$= \int_{\{|x - \mu| \geq \varepsilon\}} \left(\frac{x - \mu}{\varepsilon}\right)^2 f(x) dx \geq \int_{\{|x - \mu| \geq \varepsilon\}} f(x) dx = W\{|X - \mu| \geq \varepsilon\}$$

$$+ \frac{1}{\varepsilon^2} \int_{\{|x - \mu| < \varepsilon\}} (x - \mu)^2 f(x) dx \geq \frac{1}{\varepsilon^2} \int_{\{|x - \mu| \geq \varepsilon\}} (x - \mu)^2 f(x) dx =$$

IV

MEHRDIMENSIONALE VERTEILUNGEN

16. STOCHASTISCHE VEKTOREN

Versuchsausgänge, die durch $m > 1$ reelle Zahlen x_1, \dots, x_m beschrieben werden.

Stoch. Modell (X_1, \dots, X_m) , $X_i \in SG \ \forall i = 1(1)m$
genannt m-dim. Stochastischer Vektor

Beispiel: System aus m Komponenten


X_i Lebensdauer der i -ten Komponente

Spezialfall $m=2$ $\underline{X} = (X_1, X_2) = (X, Y)$

2-dim. VF $F_{(x,y)} := W\{X \leq x, Y \leq y\} \ \forall (x,y) \in \mathbb{R}^2$

Mit Hilfe der 2-dim. VF erhält man die Wahrsch. von endlichen Rechtecken $B = (a_1, b_1] \times (a_2, b_2]$

$$W(B) = F(b_1, b_2) - F(a_1, b_2) - F(b_1, a_2) + F(a_1, a_2)$$



16.2

16.1 Randverteilungen

Ist $\underline{X} = (X_1, \dots, X_m)$ ein SV, so heißen die Verteilungen jedes Teilvektors $(X_{i_1}, \dots, X_{i_k})$, $k < m$ Randverteilungen.

Spezialfall $k=1$: Einzelverteilungen der X_i

Es gilt: $\underline{X} = (X, Y)$ 2-dim. SV mit VF $F(x, y)$
 \Rightarrow die 1-dim. VF_n $F_1(\cdot)$ von X und $F_2(\cdot)$ von Y sind

$$F_1(x) = W\{X \leq x\} = \lim_{y \uparrow \infty} F(x, y) \quad \forall x \in \mathbb{R}$$

$$F_2(y) = W\{Y \leq y\} = \lim_{x \uparrow \infty} F(x, y) \quad \forall y \in \mathbb{R}$$

16.3

17. MEHRDIMENSIONALE DISKRETE VERT.

M abzählbare Menge von reellen m -Tupeln (x_1, \dots, x_m) ohne Häufungspunkt mit zugehörigen Punktwahrscheinlichkeiten $p(x_1, \dots, x_m)$, sodass

$$\sum_{(x_1, \dots, x_m) \in M} p(x_1, \dots, x_m) = 1$$

Die W. einer Teilmenge A von M ist def. durch

$$W(A) := \sum_{(x_1, \dots, x_m) \in A} p(x_1, \dots, x_m)$$

Beispiel: Multinomialverteilung $M_{n; \theta_1, \dots, \theta_m}$

17.1

2-dim SV bzw. Verteilungen $(X, Y) \sim p(x, y)$

Darstellung in Tabellenform oder als Diagramm

$X \backslash Y$	b_1	b_2	\dots	b_j	\dots	b_ℓ
a_1	$p(a_1, b_1)$	$p(a_1, b_2)$	\dots	$p(a_1, b_j)$	\dots	$p(a_1, b_\ell)$
a_2	$p(a_2, b_1)$	$p(a_2, b_2)$	\dots	$p(a_2, b_j)$	\dots	$p(a_2, b_\ell)$
\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots
a_i	$p(a_i, b_1)$	$p(a_i, b_2)$	\dots	$p(a_i, b_j)$	\dots	$p(a_i, b_\ell)$
\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots
a_k	$p(a_k, b_1)$	$p(a_k, b_2)$	\dots	$p(a_k, b_j)$	\dots	$p(a_k, b_\ell)$

17.2

17.1 Randverteilungen $(X, Y) \sim p(x, y)$

Punktwahrscheinlichkeiten der Einzelgrößen

$$p_1(x) = W\{X=x\} = \sum_{y \in M_Y} W\{(X, Y) = (x, y)\} = \sum_{y \in M_Y} p(x, y)$$

$$p_2(y) = W\{Y=y\} = \sum_{x \in M_X} W\{(X, Y) = (x, y)\} = \sum_{x \in M_X} p(x, y)$$

Bem.: Name Randverteilung siehe Tabelle

Für höherdimensionale SV_n gibt es mehrdimensionale Randverteilungen

17.2

2-dim. Verteilungstabelle

$X \backslash Y$	b_1	b_2	\dots	b_j	\dots	b_e	$p_1(x)$
a_1	$p(a_1, b_1)$	$p(a_1, b_2)$	\dots	$p(a_1, b_j)$	\dots	$p(a_1, b_e)$	$p_1(a_1)$
a_2	$p(a_2, b_1)$	$p(a_2, b_2)$	\dots	$p(a_2, b_j)$	\dots	$p(a_2, b_e)$	$p_1(a_2)$
\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots
a_i	$p(a_i, b_1)$	$p(a_i, b_2)$	\dots	$p(a_i, b_j)$	\dots	$p(a_i, b_e)$	$p_1(a_i)$
\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots
a_k	$p(a_k, b_1)$	$p(a_k, b_2)$	\dots	$p(a_k, b_j)$	\dots	$p(a_k, b_e)$	$p_1(a_k)$
$p_2(y)$	$p_2(b_1)$	$p_2(b_2)$	\dots	$p_2(b_j)$	\dots	$p_2(b_e)$	1

Randverteilung von X

Randverteilung von Y

18. MEHRDIMENSIONALE KONTIN. VTLGEN

$\underline{X} = (X_1, \dots, X_m) \sim f(x_1, \dots, x_m)$ m -dim. Dichtefunktion

$f: \mathbb{R}^m \rightarrow [0, \infty)$ mit $\int_{\mathbb{R}^m} \dots \int f(x_1, \dots, x_m) dx_1 \dots dx_m = 1$

Als Ereignisfeld auf \mathbb{R}^m das am wenigsten umfassende Ereignisfeld, das alle m -dim. Intervalle I_m enthält:

$$I_m := \prod_{i=1}^m (a_i, b_i] \quad \text{mit} \quad a_i < b_i \in \mathbb{R}$$

Dieses Ereignisfeld nennt man das System der m -dim. Borelmengen \mathcal{B}_m .

18.1

Für $B \in \mathcal{B}_m$ ist die W. $W(B)$ def. durch

$$W(B) := \int_B \dots \int f(x_1, \dots, x_m) dx_1 \dots dx_m$$

Im Spezialfall $B = I_m = \prod_{i=1}^m (a_i, b_i]$ gilt

$$W(I_m) = \int_{a_1}^{b_1} \dots \int_{a_m}^{b_m} f(x_1, \dots, x_m) dx_1 \dots dx_m$$

Beispiel: m -dim. Normalverteilung $N(\mu, \Sigma)$

$$\mu = \begin{pmatrix} \mu_1 \\ \vdots \\ \mu_m \end{pmatrix} \in \mathbb{R}^m, \quad \Sigma = \begin{pmatrix} \sigma_{11} & \dots & \sigma_{1m} \\ \sigma_{21} & \dots & \sigma_{2m} \\ \vdots & \ddots & \vdots \\ \sigma_{m1} & \dots & \sigma_{mm} \end{pmatrix}$$

symmetrische, reelle,
positiv definite
quadratische Matrix

18.2

m -dim. Dichtefunktion mittels der inversen Matrix

$$\Sigma^{-1} = \begin{pmatrix} \alpha_{11} & \dots & \alpha_{1m} \\ \vdots & & \vdots \\ \alpha_{m1} & \dots & \alpha_{mm} \end{pmatrix}$$

$$f(x_1, \dots, x_m) = \frac{1}{(2\pi)^{\frac{m}{2}} \sqrt{\text{Det } \Sigma}} e^{-\frac{1}{2} \sum_{i=1}^m \sum_{j=1}^m \alpha_{ij} (x_i - \mu_i)(x_j - \mu_j)}$$

$$\forall (x_1, \dots, x_m) \in \mathbb{R}^m$$

18.1 2-dim. Normalverteilung $N(\mu_x, \mu_y, \sigma_x^2, \sigma_y^2, \rho)$

$$\mu = \begin{pmatrix} \mu_x \\ \mu_y \end{pmatrix}, \quad \sigma_x^2 > 0, \quad \sigma_y^2 > 0, \quad -1 < \rho < 1, \quad \Sigma = \begin{pmatrix} \sigma_x^2 & \rho \sigma_x \sigma_y \\ \rho \sigma_x \sigma_y & \sigma_y^2 \end{pmatrix}$$

18.3

Dichtefunktion $f(x,y) =$

$$= \frac{1}{2\pi \sigma_x \sigma_y \sqrt{1-\rho^2}} e^{-\frac{1}{2(1-\rho^2)} \left[\left(\frac{x-\mu_x}{\sigma_x}\right)^2 - 2\rho \left(\frac{x-\mu_x}{\sigma_x}\right) \left(\frac{y-\mu_y}{\sigma_y}\right) + \left(\frac{y-\mu_y}{\sigma_y}\right)^2 \right]}$$

$$\forall (x,y) \in \mathbb{R}^2$$



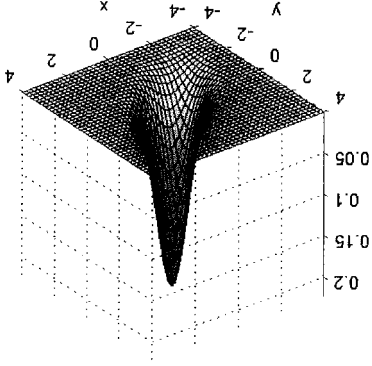
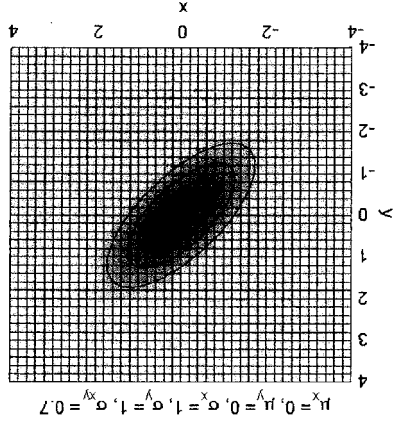


Bem.: $\sigma_x^2 \hat{=} \sigma_{11}$, $\sigma_y^2 \hat{=} \sigma_{22}$, $\rho \sigma_x \sigma_y \hat{=} \sigma_{12} = \sigma_{21}$

ρ ist ein Maß für den Zusammenhang von X und Y

Für reale Verteilungen müssen die Parameter $\mu_x, \mu_y, \sigma_x^2, \sigma_y^2, \rho$ aus Daten statistisch geschätzt werden.

$\rho = 0$ stoch. unabhängig

18.4



18.2 Randdichten

$\underline{X} = (X, Y) \sim f(x, y)$, Randverteilung von X :

$$\begin{aligned}
 W\{X \in A\} &= W\{X \in A, Y \text{ beliebig}\} = W\{X \in A, -\infty < Y < \infty\} \\
 &= \int_{-\infty}^{\infty} \left[\int_A f(x, y) dx \right] dy = \int_A \underbrace{\left[\int_{-\infty}^{\infty} f(x, y) dy \right]}_{f_1(x)} dx \\
 &= \int_A f_1(x) dx \quad A \in \mathcal{B}_1
 \end{aligned}$$

$\Rightarrow f_1(\cdot)$ ist die Dichte der Randverteilung von X ,
genannt Randdichte von X

$$f_1(x) := \int_{-\infty}^{\infty} f(x,y) dy \quad \forall x \in \mathbb{R} \quad \text{Randdichte von } X$$

$$f_2(y) := \int_{-\infty}^{\infty} f(x,y) dx \quad \forall y \in \mathbb{R} \quad \text{Randdichte von } Y$$

18.3 Satz: $(X,Y) \sim N(\mu_x, \mu_y, \sigma_x^2, \sigma_y^2, \rho)$

$$\Rightarrow X \sim N(\mu_x, \sigma_x^2)$$

$$Y \sim N(\mu_y, \sigma_y^2)$$

o. Bew.

18.7

19. ERWARTUNG VON FUNKTIONEN VON STOCH. VEKTOREN

$\underline{X} = (X_1, \dots, X_m)$ SV, $\psi: \mathbb{R}^m \rightarrow \mathbb{R}$ messbar
 $\Rightarrow Z = \psi(X_1, \dots, X_m)$ SG

gesucht: IEZ

Beispiele: 1) $\psi(x_1, \dots, x_m) = \sum_{i=1}^m x_i$

2) $\psi(x_1, \dots, x_m) = \sum_{i=1}^m x_i^2$

3) $\psi(x_1, \dots, x_m) = \min_{i=1(1)m} x_i$

4) $\psi(x_1, \dots, x_m) = \max_{i=1(1)m} x_i$

19.1

19.1 Satz vom unbewussten Statistiker:

Ist $\underline{X} = (X_1, \dots, X_m)$ ein SV und $\psi: \mathbb{R}^m \rightarrow \mathbb{R}$ eine messbare Funktion, sodass $\exists \mathbb{E}\psi(\underline{X})$, so gilt:

(1) Im diskreten Fall $\underline{X} \sim (M_{\underline{X}}, p(x_1, \dots, x_m))$

$$\mathbb{E}\psi(X_1, \dots, X_m) = \sum_{(x_1, \dots, x_m) \in M_{\underline{X}}} \psi(x_1, \dots, x_m) p(x_1, \dots, x_m)$$

(2) Im kontinuierlichen Fall $\underline{X} \sim f(x_1, \dots, x_m)$

$$\mathbb{E}\psi(X_1, \dots, X_m) = \int_{\mathbb{R}^m} \psi(x_1, \dots, x_m) f(x_1, \dots, x_m) dx_1 \dots dx_m$$

(3) Im gemischten Fall eine Kombination

19.2

19.2 Linearität der Erwartungsbildung:

Sind X_1, \dots, X_n 1-dim. SG_n mit $\exists \mathbb{E}X_i \forall i=1(1)n$ und a_1, \dots, a_n reelle Konstanten, so gilt:

$$\mathbb{E}\left(\sum_{i=1}^n a_i X_i\right) = \sum_{i=1}^n a_i \mathbb{E}X_i$$

Bew.: Mittels des S.vu.Stat.

$$\underline{\text{Bem.:}} \quad \mathbb{E}(X+Y) = \mathbb{E}X + \mathbb{E}Y$$

19.3

20. Kovarianz, Korrelation und Unabhängigkeit

Beschreibung von Zusammenhängen zwischen SG_n

20.1 Kovarianz

Für zwei SG_n X und Y mit \exists Varianzen ist die Kovarianz $\text{Cov}(X, Y)$ definiert durch

$$\text{Cov}(X, Y) = \mathbb{E}[(X - \mathbb{E}X)(Y - \mathbb{E}Y)]$$

Bem.: Berechnung mittels S.v.u.Stat.

$\text{Cov}(X, Y)$ Maß für die Abhängigkeit von X und Y

Beispiel: $(X, Y) \sim N(\mu_x, \mu_y, \sigma_x^2, \sigma_y^2, \rho) \Rightarrow \text{Cov}(X, Y) = \rho\sigma_x\sigma_y$

$(X_1, \dots, X_m) \sim N(\mu, \Sigma) \Rightarrow \text{Cov}(X_k, X_\ell) = \sigma_{k\ell}$

20.1

20.2 Satz: Falls $\exists \text{Cov}(X, Y)$, so gilt:

$$\text{Cov}(X, Y) = \mathbb{E}(X \cdot Y) - (\mathbb{E}X) \cdot (\mathbb{E}Y)$$

$$\begin{aligned} \text{Bew.: } \text{Cov}(X, Y) &= \mathbb{E}[(X - \mathbb{E}X)(Y - \mathbb{E}Y)] \\ &= \mathbb{E}[X \cdot Y - Y \cdot \mathbb{E}X - X \cdot \mathbb{E}Y + (\mathbb{E}X) \cdot (\mathbb{E}Y)] \\ &= \mathbb{E}(X \cdot Y) - \mathbb{E}X \cdot \mathbb{E}Y - \mathbb{E}X \cdot \mathbb{E}Y + \mathbb{E}X \cdot \mathbb{E}Y // \end{aligned}$$

20.3 Satz: Sind X_1, \dots, X_n SG_n mit $\exists \text{Var} X_i \forall i=1(1)n$ und c_1, \dots, c_n reelle Konstanten, so gilt:

$$\text{Var}\left(\sum_{i=1}^n c_i X_i\right) = \sum_{i=1}^n c_i^2 \text{Var} X_i + 2 \sum_{\substack{i=1 \\ j=2 \\ i < j}}^{n-1} c_i c_j \text{Cov}(X_i, X_j)$$

Sonderfall: $\text{Var}(X+Y) = \text{Var} X + \text{Var} Y + 2 \cdot \text{Cov}(X, Y)$

20.2

$$\begin{aligned}
\text{Bew.: } \text{Var}(X+Y) &= \mathbb{E}\{[X+Y - \mathbb{E}(X+Y)]^2\} \\
&= \mathbb{E}\{[X+Y - \mathbb{E}X - \mathbb{E}Y]^2\} = \mathbb{E}\{[(X-\mathbb{E}X) + (Y-\mathbb{E}Y)]^2\} \\
&= \mathbb{E}\{(X-\mathbb{E}X)^2 + (Y-\mathbb{E}Y)^2 + 2(X-\mathbb{E}X)(Y-\mathbb{E}Y)\} \\
&= \underbrace{\mathbb{E}[(X-\mathbb{E}X)^2]}_{\text{Var } X} + \underbrace{\mathbb{E}[(Y-\mathbb{E}Y)^2]}_{\text{Var } Y} + 2\underbrace{\mathbb{E}[(X-\mathbb{E}X)(Y-\mathbb{E}Y)]}_{\text{Cov}(X,Y)} //
\end{aligned}$$

20.4 Korrelationskoeffizient

Sind X und Y SG_n mit \exists Varianzen, so ist der Korrelationskoeffizient $\rho_{X,Y}$ von X und Y def. als

$$\rho_{X,Y} = \frac{\text{Cov}(X,Y)}{\sqrt{\text{Var } X} \cdot \sqrt{\text{Var } Y}}$$

20.3

Es gilt: 1) $-1 \leq \rho_{X,Y} \leq 1$

2) Falls $|\rho_{X,Y}| = 1$, so gilt f.s. ein linearer Zusammenhang von X und Y , d.h. $W\{Y = kX + d\} = 1$

$\rho_{X,Y} = 1$ positive lineare Kopplung

$\rho_{X,Y} = -1$ negative —" —"

Beispiel: $(X,Y) \sim N(\mu_x, \mu_y, \sigma_x^2, \sigma_y^2, \rho) \Rightarrow \rho_{X,Y} = \rho$

Def.: Gilt $\rho_{X,Y} = 0$, so heißen X und Y unkorreliert.

20.5 Satz: Für paarweise unkorrelierte SG_n gilt:

$$\text{Var}\left(\sum_{i=1}^n X_i\right) = \sum_{i=1}^n \text{Var } X_i \quad (\text{vgl. Satz 20.3})$$

20.4

20.6 Stochastische Unabhängigkeit SG_n

SG_n X und Y sind unabhängig, wenn für ihre gemeinsame VF $G(\cdot, \cdot)$, wobei $X \sim F_1(\cdot)$ und $Y \sim F_2(\cdot)$, gilt:

$$G(x, y) = F_1(x) \cdot F_2(y) \quad \forall (x, y) \in \mathbb{R}^2 \quad (X \perp Y)$$

Es gilt: Die Unabhängigkeit ist gleichbedeutend mit

- (1) $p(x, y) = p_1(x) \cdot p_2(y) \quad \forall (x, y)$ im diskreten Fall
- (2) $f(x, y) = f_1(x) \cdot f_2(y) \quad \forall (x, y)$ im kontinuierl. Fall

Beispiel: $(X, Y) \sim N(\mu_x, \mu_y, \sigma_x^2, \sigma_y^2, \rho)$, so sind X und Y genau dann unabhängig, wenn $\rho = 0$.

20.5

20.7 Satz: Sind X und Y unabhängig, so gilt für alle messbaren Funktionen $\varphi(\cdot)$ und $\psi(\cdot)$, für die $\exists \mathbb{E}[\varphi(X)]$ und $\exists \mathbb{E}[\psi(Y)]$:

$$\mathbb{E}[\varphi(X) \cdot \psi(Y)] = \mathbb{E}[\varphi(X)] \cdot \mathbb{E}[\psi(Y)]$$

Bew.: für den kontin. Fall; $g(x, y) = f_1(x) \cdot f_2(y) \quad \forall (x, y) \in \mathbb{R}^2$,
S.v.u.Stat. \Rightarrow

20.8 Satz: Für SG X und Y gilt: $X \perp Y \Rightarrow \int_{X, Y} = 0$

$$\begin{aligned} \text{Bew.: } \text{Cov}(X, Y) &= \mathbb{E}[(X - \mathbb{E}X)(Y - \mathbb{E}Y)] = \text{Satz 20.7} \\ &= \mathbb{E}[X - \mathbb{E}X] \cdot \mathbb{E}[Y - \mathbb{E}Y] = [\mathbb{E}X - \mathbb{E}X] \cdot [\mathbb{E}Y - \mathbb{E}Y] = 0 \\ &\Rightarrow \int_{X, Y} = 0 \quad // \end{aligned}$$

20.6

21. BEDINGTE VERTEILUNGEN

(X, Y) 2-dim. SV

gesucht: Vtlg. von $Y|X=x$

21.1 Diskrete Vtlgen.

$(X, Y) \sim p(x, y) \quad \forall (x, y) \in M_{(X, Y)}$

$p_1(\cdot)$ Randverteilung von X

$p_2(\cdot)$ " " Y

Bedingte Verteilungen von $Y|X=x$

$X|Y=y$

21.1

$$p(y|x) := W\{Y=y|X=x\} = \frac{W\{X=x \wedge Y=y\}}{W\{X=x\}} = \frac{p(x, y)}{p_1(x)}$$

bei festem x , $\forall y \in M_Y$

$$p(x|y) := \frac{p(x, y)}{p_2(y)} \quad \forall x \in M_X, y \text{ fest}$$

21.2 Kontinuierliche Vtlgen.

$(X, Y) \sim f(x, y)$

Problem: $W\{X=x\} = 0$

Lösung: Bedingte Dichten von $Y|X=x$

$X|Y=y$

21.2

$f_1(\cdot)$ Randdichte von X

$f_2(\cdot)$ — " — " Y

Bedingte Dichte $f(y|x) := \frac{f(x,y)}{f_1(x)}$ $\forall x: f_1(x) > 0$

$f(x|y) := \frac{f(x,y)}{f_2(y)}$ $\forall y: f_2(y) > 0$

Beispiel: $(X, Y) \sim N(\mu_1, \mu_2, \sigma_1^2, \sigma_2^2, \rho)$

$$f(y|x) = \frac{1}{\sqrt{2\pi} \sigma_2 \sqrt{1-\rho^2}} \exp\left\{-\frac{(y - [\mu_2 + \rho \frac{\sigma_2}{\sigma_1}(x - \mu_1)])^2}{2(1-\rho^2)\sigma_2^2}\right\}$$
$$\hat{=} N\left(\mu_2 + \rho \frac{\sigma_2}{\sigma_1}(x - \mu_1), (1-\rho^2)\sigma_2^2\right)$$

21.3

Definition: Für (X, Y) heißt die Funktion

$x \rightarrow \mathbb{E}(Y|X=x)$ bedingte Erwartung von $Y|X$,
auch genannt Regressionsfunktion von Y bezüglich X .

Analog $y \rightarrow \mathbb{E}(X|Y=y)$

Sonderfall: $(X, Y) \sim N(\mu_1, \mu_2, \sigma_1^2, \sigma_2^2, \rho)$

$$\Rightarrow \mathbb{E}(Y|X=x) = \mu_2 + \rho \frac{\sigma_2}{\sigma_1}(x - \mu_1)$$

Regressionsgerade

21.4

22. FUNKTIONEN VON STOCH. VEKTOREN

$\underline{X} = (X_1, \dots, X_m)$ SV, $\psi: \mathbb{R}^m \rightarrow \mathbb{R}^k$ messbar

$Z = \psi(\underline{X})$ k -dim. SV

gesucht: W-Vtlg. von Z

Beispiele: 1) $X, Y \text{ SG}_n, Z = X + Y$

2) $X_1, \dots, X_m \text{ SG}_n, Z = \min(X_1, \dots, X_m)$

3) $X_1, \dots, X_n \text{ SG}_n, Z = \frac{1}{n} \sum_{i=1}^n X_i$

4) $X, Y \text{ SG}_n, Z = X \cdot Y$

22.1

22.1 Lineartransformation von Normalverteilungen

$\underline{X} = (X_1, \dots, X_m) \sim N(\underline{\mu}, \Sigma)$

$A = (a_{ij})_{\substack{i=1(1)m \\ j=1(1)m}}$ reguläre Matrix

$\Rightarrow \underline{Z} = A\underline{X} \sim N(A\underline{\mu}, A\Sigma A^T)$

(ohne Beweis)

22.2 Satz: Sind X_1, \dots, X_n unabhängige $\text{SG}_n, X_i \sim F_i(\cdot)$,
so gilt:

(a) $W\{\max(X_1, \dots, X_n) \leq x\} = \prod_{i=1}^n F_i(x) \quad \forall x \in \mathbb{R}$

(b) $W\{\min(X_1, \dots, X_n) \leq x\} = 1 - \prod_{i=1}^n [1 - F_i(x)] \quad \forall x \in \mathbb{R}$

22.2

Beweis: (a) $\{ \max(X_1, \dots, X_n) \leq x \} = \bigcap_{i=1}^n \{X_i \leq x\}$
 $\Rightarrow W\{\max_{i=1(1)n} X_i \leq x\} = W(\bigcap_{i=1}^n \{X_i \leq x\}) = \prod_{i=1}^n W\{X_i \leq x\}$ //

(b) analog, mittels $W\{\min_{i=1(1)n} X_i \leq x\} = 1 - W\{\min_{i=1(1)n} X_i > x\}$
 $= F_i(x)$

22.3 Ordnungsstatistiken

Sind X_1, \dots, X_n SG_n , so nennt man die der Größe nach geordneten SG_n $X_{(1)} \leq X_{(2)} \leq \dots \leq X_{(n)}$ die zugehörigen Ordnungsstatistiken.

Bem.: $X_{(1)} = \min(X_1, \dots, X_n)$
 $X_{(n)} = \max(X_1, \dots, X_n)$

22.3.3

22.4 Faltung von W.-Vtügen.

X, Y unabhängige SG_n mit VF F_n $X \sim F(\cdot)$, $Y \sim G(\cdot)$
 gesucht: VF $H(\cdot)$ von $X+Y$

Es gilt: $H(x) = \int_{-\infty}^{\infty} F(x-t) dG(t) \quad \forall x \in \mathbb{R}$

Beweis: (a) Diskrete Verteilungen $X \sim p_1(\cdot)$, $Y \sim p_2(\cdot)$


$q(a) = W\{X+Y=a\} = W(\bigcup_{\substack{(x,y): \\ x+y=a}} \{X=x, Y=y\})$

$= W(\bigcup_{\substack{(x,y): \\ x+y=a}} [\{X=x\} \cap \{Y=y\}]) = \sum_{\substack{(x,y): \\ x+y=a}} W(\{X=x\} \cap \{Y=y\})$

22.4.3

$$= \sum_{\substack{(x,y): \\ x+y=a}} W\{X=x\} \cdot W\{Y=y\} = \sum_{x \in M_x} W\{X=x\} \cdot W\{Y=a-x\}$$

$$= \sum_{x \in M_x} p_1(x) \cdot p_2(a-x)$$



Anwendung

Additionstheorem für Poisson-Verteilungen:

$$X \sim P_\mu, Y \sim P_\xi, X \perp\!\!\!\perp Y \Rightarrow X+Y \sim P_{\mu+\xi}$$


$$\text{Bew.: } q(a) = \sum_{x=0}^{\infty} p_1(x) \cdot p_2(a-x) = \sum_{x=0}^a \frac{\mu^x e^{-\mu}}{x!} \cdot \frac{\xi^{a-x} e^{-\xi}}{(a-x)!}$$

22.5

$$= \frac{e^{-(\mu+\xi)}}{a!} \sum_{x=0}^a \underbrace{\binom{a}{x} \mu^x \xi^{a-x}}_{= (\mu+\xi)^a} = \frac{(\mu+\xi)^a e^{-(\mu+\xi)}}{a!} \hat{=} P_{\mu+\xi}$$

(b) Kontinuierliche Verteilungen $X \sim f(\cdot), Y \sim g(\cdot)$

$$H(a) = W\{X+Y \leq a\} = \underbrace{\iint_{x+y \leq a} f(x)g(y) dx dy}$$



22.6

Differentiation von $H(\cdot)$ ergibt die Dichte $h(\cdot)$

$$\text{Es gilt: } h(a) = \frac{d}{da} \int_{-\infty}^{\infty} F(a-y)g(y)dy = \int_{-\infty}^{\infty} \frac{d}{da} F(a-y)g(y)dy$$

$$= \int_{-\infty}^{\infty} f(a-y)g(y)dy \quad \text{Faltprodukt der Dichten } f(\cdot) \text{ und } g(\cdot)$$

Anwendung: Addition unabhängiger Zufallszahlen

$X \sim U_{0,1}$, $Y \sim U_{0,1}$, $X \perp\!\!\!\perp Y$, gesucht: Dichte von $X+Y$

$$h(a) = \int_{-\infty}^{\infty} f(a-y)g(y)dy = \int_{-\infty}^{\infty} I_{(0,1)}(a-y)I_{(0,1)}(y)dy$$

2.7

Der Integrand ist genau dann positiv (=1), wenn

$$[0 < a-y < 1] \wedge [0 < y < 1],$$

dies gilt genau dann, wenn


$$[a-1 < y < a] \wedge [0 < y < 1].$$

Daher gilt

$$\text{für } 0 \leq a \leq 1: h(a) = \int_0^a 1 dy = a$$

$$\text{für } 1 \leq a \leq 2: h(a) = \int_{a-1}^1 1 dy = 2-a$$

$$\text{sonst: } h(a) = 0$$



2.8

Additionstheorem für Normalverteilungen:

Gilt $X_i \sim N(\mu_i, \sigma_i^2)$ für $i=1(1)n$ und sind X_1, \dots, X_n unabh.

$$\Rightarrow \sum_{i=1}^n X_i \sim N\left(\sum_{i=1}^n \mu_i, \sum_{i=1}^n \sigma_i^2\right)$$

Beweis: Faltung der Dichten und Induktion

Additionstheorem für Gammaverteilungen:

Gilt $X_i \sim \text{Gam}(\alpha_i, \lambda)$ für $i=1(1)n$ und X_1, \dots, X_n unabhängig

$$\Rightarrow \sum_{i=1}^n X_i \sim \text{Gam}\left(\sum_{i=1}^n \alpha_i, \lambda\right)$$

Beweis: Faltung und Induktion

22.9

Bem.: Sonderfall χ_n^2

Erlang - Vtlg. $\text{Er}_{n,\lambda}$

Sind X_1, \dots, X_n unabhängig exponentialverteilt mit

Dichte $f(x) = \lambda e^{-\lambda x} I_{(0,\infty)}(x)$, so hat die SG $\sum_{i=1}^n X_i$













eine Erlang - Verteilung mit Dichtefunktion

$$f(x|n,\lambda) = \frac{\lambda^n}{(n-1)!} x^{n-1} e^{-\lambda x} I_{(0,\infty)}(x)$$

Beweis: Faltung und Induktion

Anwendung: Warteschlangen

22.10



$Er(3,1)$

$Er(2,1)$

V

FOLGEN STOCH. GRÖSZEN

$X_1, X_2, \dots, X_n, \dots$ unendliche Folge von SG_n X_i

Def.: Eine ∞ Folge von SG_n heißt unabhängige Folge, wenn je endlich viele der SG_n unabhängig sind.

Bem.: UIV-Folgen (engl. IID) als mathem. Beschreibung für beliebig oft wiederholbare stat. Versuche.

23. GESETZ DER GROSZEN ZAHLEN

Konvergenz von Folgen SG_n

Bem.: Für UIV-Folgen und das empirische GgZ gilt für ein festes Ereignis B nach n Durchführungen für die relativen Häufigkeiten $h_n(B)$ mit

$$X_i = \begin{cases} 1 & \text{falls B beim } i\text{-ten Versuch eintritt} \\ 0 & \text{falls B beim } i\text{-ten Versuch nicht eintritt} \end{cases}$$

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

Bem.: \bar{X}_n ist eine SG (vor Durchf. der Versuche)

Def.: Eine Folge $(X_n, n \in \mathbb{N})$ von SGn X_n konvergiert in der Wahrscheinlichkeit gegen eine SG X_0 , i.Z.

$X_n \xrightarrow[n \rightarrow \infty]{W} X_0$, wenn gilt:

$$\lim_{n \rightarrow \infty} W\{|X_n - X_0| \geq \varepsilon\} = 0 \quad \forall \varepsilon > 0$$

23.1 Gesetz der großen Zahlen: Ist $(X_n, n \in \mathbb{N})$ eine UIV-Folge mit $\exists \text{Var} X_i = \sigma^2 < \infty$, so gilt:

$$\overline{X}_n \xrightarrow[n \rightarrow \infty]{W} \mathbb{E} X_i = \mu \in \mathbb{R}$$

Beweis: $\exists \text{Var} X_i \Rightarrow \exists \mathbb{E} X_i = \mu$ (endlich),

mit $S_n := X_1 + \dots + X_n$ folgt $\mathbb{E} S_n = n\mu$ und wegen

23.2

der Unabhängigkeit der X_1, \dots, X_n $\text{Var} S_n = n\sigma^2$

$$\Rightarrow \mathbb{E} \overline{X}_n = \mathbb{E} \left[\frac{1}{n} S_n \right] = \frac{1}{n} \mathbb{E} S_n = \frac{1}{n} \cdot n \cdot \mu = \mu.$$

$$\text{Var} \overline{X}_n = \text{Var} \left(\frac{1}{n} S_n \right) = \frac{1}{n^2} \text{Var} S_n = \frac{1}{n^2} \cdot n \cdot \sigma^2 = \frac{\sigma^2}{n}$$

Aus der Tschebyscheff'schen Ungl. folgt

$$W\{|\overline{X}_n - \mu| \geq \varepsilon\} \leq \frac{\text{Var} \overline{X}_n}{\varepsilon^2} \quad \forall \varepsilon > 0.$$

$$\lim_{n \rightarrow \infty} W\{|\overline{X}_n - \mu| \geq \varepsilon\} \leq \lim_{n \rightarrow \infty} \frac{\sigma^2/n}{\varepsilon^2} = \lim_{n \rightarrow \infty} \frac{\sigma^2}{n\varepsilon^2} = 0 \quad //$$

Bem.: Zum empir. GgZ, $X_i := I_B \Rightarrow X_i \sim A_{W(B)}$

$$\Rightarrow h_n(B) = \overline{X}_n \xrightarrow[n \rightarrow \infty]{W} \mathbb{E} X_i = W(B)$$

23.3

24. ZENTRALER GRENZVERTEILUNGSSATZ

Verteilung von Summen von unabh. SG_n , Faltung
vgl. Abschn. 22

24.1 ZGS: Ist X_1, X_2, \dots eine ∞ Folge von unabh. SG_n
mit $\exists \text{Var} X_k \forall k \in \mathbb{N}$ und erfüllen die VF $F_k(\cdot)$
der X_k die sog. Lindeberg-Bedingung, so gilt
für die Folge $Z_n, n \in \mathbb{N}$ der standardisierten
Summen

$$Z_n := \frac{\sum_{k=1}^n X_k - \mathbb{E}(\sum_{k=1}^n X_k)}{\sqrt{\text{Var}(\sum_{k=1}^n X_k)}}$$

$$\lim_{n \rightarrow \infty} W\{Z_n \leq x\} = \Phi(x) \quad \forall x \in \mathbb{R}.$$

24.1

Bem.: 1) Die LB lautet mit den Bez. $\mu_k := \mathbb{E}X_k$,

$$\Delta_n^2 := \text{Var}(\sum_{k=1}^n X_k) = \sum_{k=1}^n \text{Var} X_k$$

$$L_n(\varepsilon) := \frac{1}{\Delta_n^2} \sum_{k=1}^n \int_{\{x: |x - \mu_k| \geq \varepsilon \Delta_n\}} (x - \mu_k)^2 dF_k(x) \xrightarrow{n \rightarrow \infty} 0 \quad \forall \varepsilon > 0$$

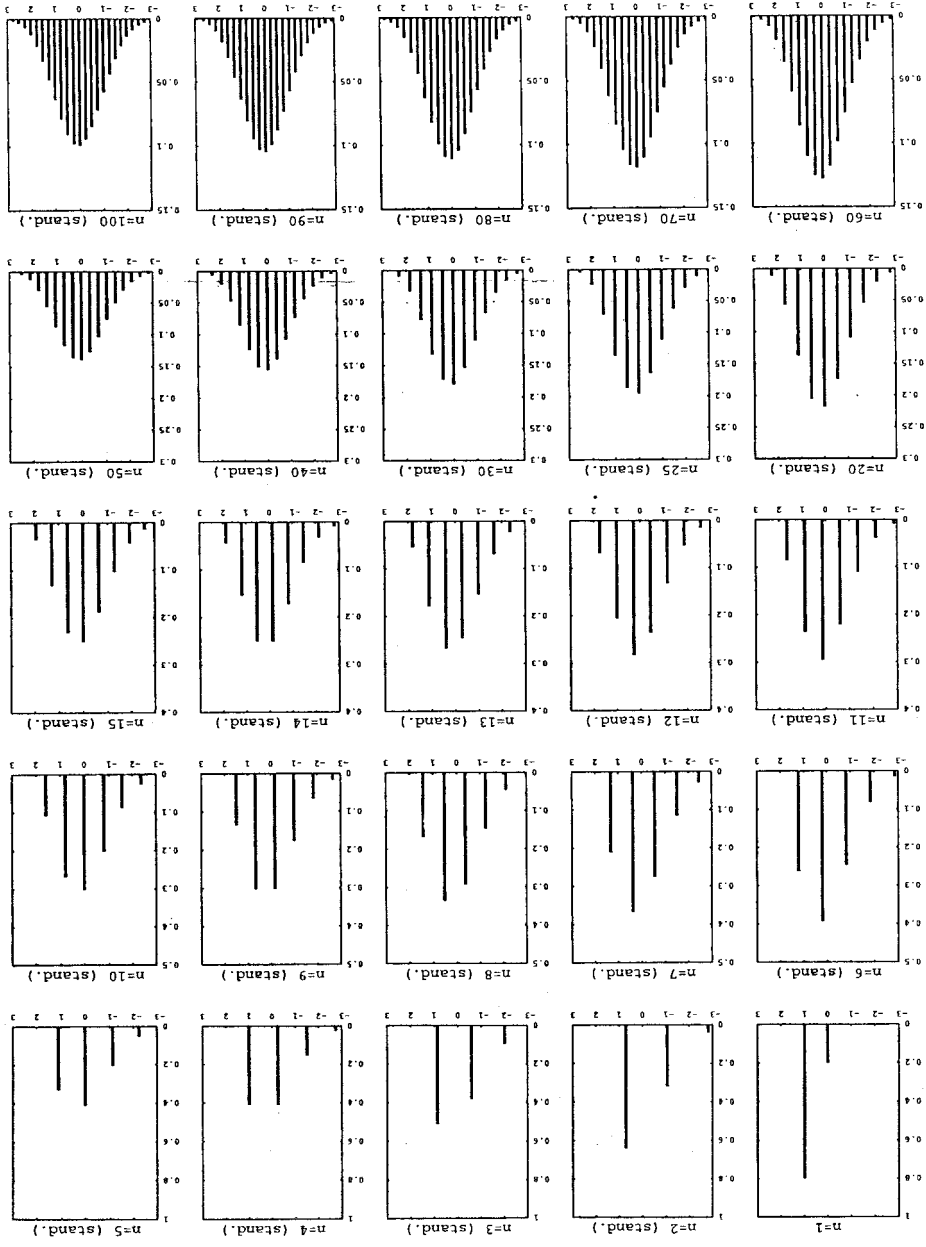
Dies bedeutet, dass keine einzelne Vtlg. $F_k(\cdot)$
dominierenden Einfluss auf die GV hat.

2) Für UIV-Folgen ist die LB erfüllt.

3) Für glm. beschränkte SG_n $|X_k| \leq C \quad \forall k \in \mathbb{N}$ mit

$$\text{Var}(\sum_{k=1}^n X_k) \xrightarrow{n \rightarrow \infty} \infty \quad \text{ist die LB erfüllt.}$$

24.2



24.2 Normalapproximation

$\sum_{k=1}^n X_k = S$ mit X_1, \dots, X_n unabh. für größeres n

wegen $Z = \frac{S - \mathbb{E}S}{\sqrt{\text{Var}S}} \sim N(0,1)$ „approximativ“

$$\Rightarrow S = \sqrt{\text{Var}S} \cdot Z + \mathbb{E}S \sim N(\mathbb{E}S, \text{Var}S)$$

Bem.: 1) Approximation für die VF

$$W\{S \leq x\} \approx \Phi\left(\frac{x - \mathbb{E}S}{\sqrt{\text{Var}S}}\right)$$

2) Bei Approximation einer diskret vt. SG X durch

$$Y \sim N(\mu, \sigma^2): \quad W\{X = x\} \approx W\left\{x - \frac{1}{2} \leq Y \leq x + \frac{1}{2}\right\}$$

25. FUNDAMENTALSATZ DER STATISTIK

X_1, X_2, \dots UIV-Folge mit $X_i \sim F(\cdot)$

Für $X_1 = x_1, X_2 = x_2, \dots, X_n = x_n$ empir. VF $F_n^*(\cdot)$
aus Abschn. 2.2

Die SG $\frac{1}{n} \sum_{i=1}^n I_{(-\infty, x]}(X_i)$ liefert nach Beobachtung
der $X_i = x_i \forall x \in \mathbb{R}$ genau den Wert $F(x)$, d.h.

$$F_n^*(x; X_1, \dots, X_n) = \frac{1}{n} \sum_{i=1}^n I_{(-\infty, x]}(X_i)$$

Für $n \rightarrow \infty$ konvergiert die Folge $F_n^*(x)$ bzw. $F_n^*(\cdot)$

25.1

25.1 Satz: Gilt X_1, X_2, \dots UIV-Folge mit $X_i \sim F(\cdot)$,
so gilt für jedes feste $x \in \mathbb{R}$

$$(a) \mathbb{E}(F_n^*(x; X_1, \dots, X_n)) = F(x)$$

$$(b) F_n^*(x; X_1, \dots, X_n) \xrightarrow[n \rightarrow \infty]{W} F(x)$$

$$\text{Beweis: (a) } \mathbb{E}\left[\frac{1}{n} \sum_{i=1}^n I_{(-\infty, x]}(X_i)\right] = \frac{1}{n} \sum_{i=1}^n \mathbb{E} I_{(-\infty, x]}(X_i)$$

$$= \frac{1}{n} \cdot n \cdot F(x) = F(x)$$

$$= W\{X \leq x\} \\ = F(x)$$

$$(b) \frac{I_{(-\infty, x]}(X_1) + \dots + I_{(-\infty, x]}(X_n)}{n} \xrightarrow[n \rightarrow \infty]{W} \mathbb{E} I_{(-\infty, x]}(X_i)$$

$$\text{also } F_n^*(x) \xrightarrow[n \rightarrow \infty]{W} F(x) \quad //$$

25.2

25.2 Fundamentalsatz: Für UIV-Folgen mit $X_i \sim F(\cdot)$ gilt


$$W\left\{\lim_{n \rightarrow \infty} \sup_{x \in \mathbb{R}} |F_n^*(x) - F(x)| = 0\right\} = 1$$

(ohne Beweis)

Bem.: 1) f.s. glm. Konvergenz

2) $\sup_{x \in \mathbb{R}} |F_n^*(x) - F(x)|$ da $\max_{x \in \mathbb{R}} |F_n^*(x) - F(x)|$ u.U. $\#$

3) $F_n^*(\cdot)$ Schätzung für $F(\cdot)$



26. STICHPROBEN UND STATISTIKEN

Gesucht: Verteilung von $SG_n X$
gegeben: Beobachtungen von X

Def.: Sind X_1, \dots, X_n UIV wie X , so heißen X_1, \dots, X_n eine (mathematische) Stichprobe von X .

Nach Beobachtung von $X_1 = x_1, \dots, X_n = x_n$ nennt man x_1, \dots, x_n konkrete Stichprobe von X . (kurz SP)

Ist $\psi: \mathbb{R}^n \rightarrow \mathbb{R}^k$ messbar und X_1, \dots, X_n eine SP, so heißt $\psi(X_1, \dots, X_n)$ eine (k-dim.) Statistik, wenn $\psi(\cdot)$ nicht von unbekanntem Parametern abhängt.

26.1

Bsp.: 1) $\psi(X_1, \dots, X_n) = \left(\sum_{i=1}^n X_i, \sum_{i=1}^n X_i^2 \right)$

2) $\psi(X_1, \dots, X_n) = \frac{1}{n} \sum_{i=1}^n X_i$ Stichprobenmittel \bar{X}_n

3) $\psi(X_1, \dots, X_n) = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X}_n)^2$ Stichprobenvarianz

26.1 Es gilt: Hat X den Merkmalraum M_X , so ist der Merkmalraum einer SP (X_1, \dots, X_n) von X gleich M_X^n , genannt Stichprobenraum.

Für die W-Vtlg. einer SP gilt:

(a) Im diskreten Fall $X \sim (M_X, p(x))$

$$w(x_1, \dots, x_n) = \prod_{i=1}^n p(x_i) \quad V(x_1, \dots, x_n) \in M_X^n$$

26.2

(b) Im kontinuierlichen Fall $X \sim f(\cdot)$ gilt für die gemeinsame Dichte $g(x_1, \dots, x_n)$ der SP

$$g(x_1, \dots, x_n) = \prod_{i=1}^n f(x_i) \quad \forall (x_1, \dots, x_n) \in M_{X,n}^n$$

Definition: Eine Statistik, die zur Schätzung einer charakteristischen Größe der W -Vtlg. von X dient, nennt man eine Schätzfunktion.

Definition: Hängt die W -vtlg. W_θ , $\theta \in \Theta$ von X von einem sog. Parameter θ ab, so heißt die Menge Θ der möglichen Werte des Parameters der Parameter-raum.

26.3

Beispiele: 1) Ex_τ , $\theta = \tau$, $\Theta = (0, \infty)$

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

3) A_θ , $\Theta = [0, 1]$

4) P_μ , $\theta = \mu$, $\Theta = (0, \infty)$

Bem.: Geraffter Parameter $\tau(\theta)$ mit $\tau: \Theta \rightarrow \mathbb{R}$

Bsp.: $N(\mu, \sigma^2)$, $\tau(\theta) = \mu$ oder $\tau(\theta) = \sigma$

Bem.: Falls die Vtlg. durch einen endlichdim. Parameter bestimmt ist, spricht man von parametrischer Statistik; sonst von nichtparametrischer St.

26.4

Es gibt 3 große Zweige der schließenden Statistik

- a) Klassische objektivistische Statistik
- b) Bayes'sche Statistik
- c) Statistik bei unscharfer Information
(Fuzzy Information)

Bem.: Entscheidung bei Unsicherheit

Fuzzy Wahrscheinlichkeiten

27. KLASSISCHE PUNKTSCHÄTZUNGEN

SG $X \sim (M_X, W_X)$, X_1, \dots, X_n SP von X

$\mathcal{N}: M_X^n \rightarrow \mathbb{R}^k$ Statistik

$\mathcal{N}(X_1, \dots, X_n)$ SG

Falls $\mathcal{N}(X_1, \dots, X_n)$ Schätzfunktion und x_1, \dots, x_n konkrete SP $\Rightarrow \mathcal{N}(x_1, \dots, x_n)$ Schätzwert.

Für geraffte Parameter $\tau(\theta) \in \mathbb{R}$

Schätzfunktion $t(X_1, \dots, X_n)$ mit $t: M_X^n \rightarrow \mathbb{R}$

27.1

Verschiedene Güteeigenschaften von Schätzfunktionen bzw. Schätzwerten.

27.1 Unverzerrtheit

Def.: Eine SF $\mathcal{N}(X_1, \dots, X_n)$ heißt unverzerrt (oder erwartungstreu) für eine char. Größe ξ , falls

$$\mathbb{E} \mathcal{N}(X_1, \dots, X_n) = \xi \quad \forall \text{ mögl. Vtlgen von } X$$

Bem.: Für parametrische Modelle $X \sim W_\theta$, $\theta \in \Theta$ muss gelten

$$\mathbb{E}_\theta \mathcal{N}(X_1, \dots, X_n) = \xi \quad \forall \theta \in \Theta$$

27.2

27.2 Satz: Für jede SG X und SP X_1, \dots, X_n gilt:

(a) falls $\exists \mathbb{E}X \Rightarrow \bar{X}_n$ unverzerrte SF für $\mathbb{E}X$

(b) für $\exists \text{Var} X \Rightarrow$ die Stichprobenvarianz S_n^2 ist unverzerrt für $\text{Var} X$

Beweis: (a) Übung

$$\begin{aligned} \text{(b)} \quad \mathbb{E} \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X}_n)^2 &= \frac{1}{n-1} \sum_{i=1}^n \mathbb{E}(X_i^2 - 2X_i \bar{X}_n + \bar{X}_n^2) \\ &= \dots = \mathbb{E}(X_i^2) - (\mathbb{E}X_i)^2 = \text{Var} X_i = \text{Var} X \quad // \end{aligned}$$

Bem.: Für geraffte Parameter $\tau(\theta)$ für Unverzerrtheit:

$$\mathbb{E}_\theta t(X_1, \dots, X_n) = \tau(\theta) \quad \forall \theta \in \Theta$$

Bsp.: $X \sim N(\mu, \sigma^2)$, $\tau(\theta) = \mu$, $t(X_1, \dots, X_n) = \bar{X}_n$
 $\Rightarrow \mathbb{E}_{\theta} \bar{X}_n = \mu \quad \forall \theta = (\mu, \sigma^2) \in \Theta$

27.3 Effizienz

Für unverzerrte SF_n möglichst kleine Varianz

$$\mathcal{J} = \{ t(X_1, \dots, X_n) : T = t(X_1, \dots, X_n) \text{ unverzerrt} \}$$

Def.: Eine SF $t^*(X_1, \dots, X_n) \in \mathcal{J}$ heißt effizient (in der Klasse \mathcal{J}), falls

$$\text{Var} t^*(X_1, \dots, X_n) = \min_{t \in \mathcal{J}} \text{Var} t(X_1, \dots, X_n)$$

27.4 Satz: Ist X eine SG mit endlicher $\overline{\text{Var}} X$ und X_1, \dots, X_n eine SP von X , so ist \overline{X}_n die effiziente lineare SF für $\mathbb{E}X$.

Beweis: $J = \{t(X_1, \dots, X_n) = \sum_{i=1}^n \alpha_i X_i\}$ mit $\sum_{i=1}^n \alpha_i = 1$

wegen $\mathbb{E}(\sum_{i=1}^n \alpha_i X_i) = \mathbb{E}X_i$ (Unverzerrtheit)

Es gilt $\text{Var}(\sum_{i=1}^n \alpha_i X_i) = \sum_{i=1}^n \alpha_i^2 \text{Var} X_i$ (wegen Ua)

\Rightarrow Varianz der SF minimal für $\sum_{i=1}^n \alpha_i^2$ minimal.

Es gilt $\sum_{i=1}^n \alpha_i^2 = \sum_{i=1}^n (\alpha_i - \frac{1}{n} + \frac{1}{n})^2 = \sum_{i=1}^n [(\alpha_i - \frac{1}{n})^2 + 2(\alpha_i - \frac{1}{n})\frac{1}{n}$

$+ (\frac{1}{n})^2] = \sum_{i=1}^n (\alpha_i - \frac{1}{n})^2 + \sum_{i=1}^n 2(\alpha_i - \frac{1}{n})\frac{1}{n} + \sum_{i=1}^n \frac{1}{n^2} = \dots$

27.5

$$= \sum_{i=1}^n (\alpha_i - \frac{1}{n})^2 + \frac{2}{n} (\sum_{i=1}^n \alpha_i - 1) + \frac{1}{n} \geq 0$$

Ausdruck minimal für $\alpha_i = \frac{1}{n} \quad \forall i = 1(1)n \quad //$

27.5 Konsistenz

Für Stichprobenumfang $n \rightarrow \infty$ Konvergenz von Folgen von Schätzfunktionen gegen gesuchte Werte (GgZ)

Definition: Ist X_1, X_2, \dots eine UIV-Folge, so heißt eine Folge $t_n(X_1, \dots, X_n)$; $n \in \mathbb{N}$ von Schätzfunktionen für eine char. Größe ξ der Verteilung von X_i

27.6

konsistent, wenn $t_n(X_1, \dots, X_n) \xrightarrow[n \rightarrow \infty]{W} \xi$

d.h. wenn gilt:

$$\lim_{n \rightarrow \infty} W\{\xi - \varepsilon < t_n(X_1, \dots, X_n) < \xi + \varepsilon\} = 1 \quad \forall \varepsilon > 0$$

Bem.: $\xi \in \mathbb{R}$; ξ ist häufig ein (geraffter) Parameter

Es gilt: Aus dem GgZ folgt, dass \bar{X}_n ; $n \in \mathbb{N}$ eine konsistente Schätzfolge für $\mathbb{E}X_i$ bildet (Vsn.)

Beispiel: Die Folge der Werte $F_n^*(x)$, $n \in \mathbb{N}$ der empir. VF_n an einer festen Stelle $x \in \mathbb{R}$ bildet für $n \rightarrow \infty$ eine konsistente Schätzfolge für den Wert $F(x)$

27.7

27.6 Plausibilität

Eigenschaft von Schätzwerten für Parameter

Für diskret vt. SG_n $X \sim p(\cdot | \theta)$, $\theta \in \Theta$ gemeinsame Vtlg. einer SP (X_1, \dots, X_n) diskret mit Punktwahrscheinlichk.

$$w(x_1, \dots, x_n | \theta) = \prod_{i=1}^n p(x_i | \theta) \quad V(x_1, \dots, x_n) \in M_X^n$$

Nach Beobachtung der konkreten SP x_1, \dots, x_n ist $w(x_1, \dots, x_n | \theta)$ eine Funktion der Variablen θ , genannt Plausibilitätsfunktion. $l(\theta; x_1, \dots, x_n)$, wobei x_1, \dots, x_n Konstanten sind.

$$l : \Theta \rightarrow [0, \infty)$$

27.6

Ist θ_0 der wahre Parameterwert, so ist ein möglichst guter Schätzwert $\hat{\theta}$ für θ_0 gesucht

Definition: Der plausible Schätzwert $\hat{\theta}$ für θ_0 ist jener Parameterwert, für den, falls er existiert, die Wahrsch. der erhaltenen konkreten SP x_1, \dots, x_n maximal ist, d.h.

$$l(\hat{\theta}, x_1, \dots, x_n) = \max_{\theta \in \Theta} l(\theta, x_1, \dots, x_n)$$

Bem.: $\frac{\partial l(\theta, x_1, \dots, x_n)}{\partial \theta} = 0$ bzw. $\frac{\partial \ln l(\theta, x_1, \dots, x_n)}{\partial \theta} = 0$

notwendige Bedingung falls $l(\theta, x_1, \dots, x_n)$ diffb.

Beispiel: $X \sim A_\theta$, konkrete SP x_1, \dots, x_n

$$p(x|\theta) = \theta^x (1-\theta)^{1-x} I_{\{0,1\}}(x) \quad \text{mit } \theta \in [0,1]$$

$$l(\theta, x_1, \dots, x_n) = \prod_{i=1}^n \theta^{x_i} (1-\theta)^{1-x_i} I_{\{0,1\}}(x_i)$$

$$= \theta^{\sum_{i=1}^n x_i} (1-\theta)^{n - \sum_{i=1}^n x_i} \prod_{i=1}^n I_{\{0,1\}}(x_i)$$

log. PF $\ln l(\theta, x_1, \dots, x_n) = \dots = 0$ " Ü

plausibler Schätzwert $\hat{\theta} = \bar{x}_n = \frac{x_1 + \dots + x_n}{n}$

Ähnlich: plaus. SW für μ in P_μ " Ü

Für kontinuierliche Verteilungen $X \sim f(\cdot|\theta)$, $\theta \in \Theta$ ist die Plausibilitätsfunktion die gemeinsame Dichtef. der Stichprobe, aufgefasst als Funktion von θ , d.h.

$$l(\theta, x_1, \dots, x_n) = \prod_{i=1}^n f(x_i|\theta) = g(x_1, \dots, x_n|\theta)$$

Def.: Der plausible Schätzwert $\hat{\theta}$ ist, falls er \exists , jener Parameterwert, der die PF maximiert

Bem.: Für Vektorparameter $\theta = (\theta_1, \dots, \theta_k)$

$$\frac{\partial l(\theta_1, \dots, \theta_k; x_1, \dots, x_n)}{\partial \theta_j} = 0 \quad \forall j=1(1)k$$

oder analog für $\ln l(\theta, x_1, \dots, x_n)$

27.11

Bsp.: $X \sim N(\mu, \sigma^2)$, $\theta = (\mu, \sigma^2)$, $k=2$, Beob. x_1, \dots, x_n

$$l^*(\theta, x_1, \dots, x_n) = \ln l(\mu, \sigma^2; x_1, \dots, x_n) = \sum_{i=1}^n \frac{(x_i - \mu)^2}{2\sigma^2} \quad \ddot{U}$$
$$= -\frac{n}{2} \ln(2\pi) - \frac{n}{2} \ln \sigma^2 - \frac{\sum_{i=1}^n (x_i - \mu)^2}{2\sigma^2}$$

$$\frac{\partial l^*}{\partial \mu} = \frac{\sum_{i=1}^n (x_i - \mu)}{\sigma^2} = 0 \quad \Rightarrow \quad \hat{\mu} = \bar{x}_n$$

$$\frac{\partial l^*}{\partial \sigma^2} = -\frac{n}{2\sigma^2} + \frac{\sum_{i=1}^n (x_i - \mu)^2}{2(\sigma^2)^2} = 0 \quad \Rightarrow \quad \hat{\sigma}^2 = \frac{\sum_{i=1}^n (x_i - \bar{x}_n)^2}{n}$$

\Rightarrow plaus. SW für $\theta = (\mu, \sigma^2)$ ist $\widehat{(\mu, \sigma^2)} = (\bar{x}_n, \frac{n-1}{n} s_n^2)$

Bem.: versch. Güteeigenschaften

27.12

Bsp.: $X \sim \text{Exp}_\tau$, $f(x|\tau) = \frac{1}{\tau} e^{-\frac{x}{\tau}} I_{(0, \infty)}(x)$ mit $\tau \in (0, \infty)$

\Rightarrow plaus. SW $\hat{\tau} = \bar{x}_n$ "Ü

Definition: Eine SF $\mathcal{N}(X_1, \dots, X_n)$, die jeder konkreten SP x_1, \dots, x_n den plausiblen SW $\mathcal{N}(x_1, \dots, x_n)$ zuordnet, heißt plausible Schätzfunktion.

28. KONFIDENZBEREICHE

Quantitative Güteangaben für Parameterschätzungen

Def.: Ein KB mit ÜDW $1-\alpha$ für einen Parameter θ_0 eines Stoch. Modells $X \sim f(\cdot|\theta)$, $\theta \in \Theta$ ist eine Teilmenge $C_{1-\alpha} \subset \Theta$ für die gilt $W\{\theta_0 \in C_{1-\alpha}\} = 1-\alpha$.

Bem.: Konstruktion von KB_n mittels sogenannter Pivot-Größen

28.1 Pivot-Größen

Def.: Eine SG, die eine Funktion $q(X_1, \dots, X, \theta)$ einer Stichprobe von $X \sim W_\theta$, $\theta \in \Theta$ und des Parameters θ ist,

deren Verteilung nicht von θ abhängt, nennt man Pivot-Größe.

28.2 Satz: Ist X_1, \dots, X_n eine SP von $X \sim N(\mu, \sigma^2)$,

so gilt:

$$\left. \begin{aligned} \frac{\bar{X}_n - \mu}{S_n / \sqrt{n}} &\sim t_{n-1} \\ \frac{(n-1)S_n^2}{\sigma^2} &\sim \chi_{n-1}^2 \end{aligned} \right\} \text{unabhängig}$$

(ohne Beweis)

Damit kann man sowohl 2-dim. KB als auch Konfidenzintervalle für μ bzw. σ^2 konstruieren

28.2

28.3 Satz: Konfidenzintervalle mit ÜDW $1-\alpha$ für die Parameter der Normalverteilung sind:

$$\text{für } \mu: \left[\bar{X}_n - \frac{S_n}{\sqrt{n}} \cdot t_{n-1; 1-\frac{\alpha}{2}}; \bar{X}_n + \frac{S_n}{\sqrt{n}} \cdot t_{n-1; 1-\frac{\alpha}{2}} \right]$$

$$\text{für } \sigma^2: \left[\frac{(n-1)S_n^2}{\chi_{n-1; 1-\frac{\alpha}{2}}^2}; \frac{(n-1)S_n^2}{\chi_{n-1; \frac{\alpha}{2}}^2} \right]$$

Beweis: (für μ) SP $X_1, \dots, X_n \Rightarrow$

$$\frac{\bar{X}_n - \mu}{S_n / \sqrt{n}} \text{ Pivot-Größe mit } t\text{-Vtlg. } t_{n-1}$$
$$t_{n-1;p} = p\text{-Fraktiles der } t_{n-1}$$

28.3

$$\Rightarrow W_{\mu, \sigma^2} \left\{ t_{n-1, \frac{\alpha}{2}} \leq \frac{\bar{X}_n - \mu}{S_n / \sqrt{n}} \leq t_{n-1, 1 - \frac{\alpha}{2}} \right\} = 1 - \alpha$$

$$V(\mu, \sigma^2)$$

Das Ereignis $\{ \dots \}$ lässt sich beschreiben durch "äquivalente Umformung der Doppelungleichung in

$$\bar{X}_n - \frac{S_n}{\sqrt{n}} \cdot t_{n-1, 1 - \frac{\alpha}{2}} \leq \mu \leq \bar{X}_n - \frac{S_n}{\sqrt{n}} \cdot t_{n-1, \frac{\alpha}{2}}$$

und wegen $t_{n-1, \frac{\alpha}{2}} = -t_{n-1, 1 - \frac{\alpha}{2}}$ folgt die Beh.

(für σ^2 analoge Umformung) " Ü

29. STAT. HYPOTHESEN UND TESTS

Problem: Welche Vtlg. hat eine SG X ?

Def.: Eine Stat. Hypothese ist eine Aussage über die Verteilung von X .

Bsp.: \mathcal{H} : X ist normalverteilt

Bem.: Zu Stat. Hypothesen auch Gegenhypothesen betrachtet: \mathcal{H}_0 \mathcal{H}_1

Def.: Ein Statistischer Test ist ein Verfahren zur Entscheidung, ob eine Stat. Hypothese angenommen oder verworfen wird.



29.1 Wahrscheinlichkeitspapiere

Transformation der $(x, F(x))$ -Ebene auf (t, z) -Ebene
dass die Bilder der VF_n $F(\cdot)$ aus \mathcal{H}_0 Geraden sind.

Beispiel: Normalverteilungsnetz

$\mathcal{H}_0: X \sim N(\mu, \sigma^2)$, μ und σ^2 beliebig

$$y = \Phi\left(\frac{x-\mu}{\sigma}\right)$$



Transformation $t = x$, $p \rightarrow u_p$ (p -Fraktiles der $N(0,1)$)

29.2

Es gilt: Zusammenhang zwischen u_p und x_p
 $x_p \dots p$ -Fraktiles der $N(\mu, \sigma^2)$

$$u_p = \frac{x_p - \mu}{\sigma} \quad \forall p \in (0,1)$$


Beweis: $X \sim N(\mu, \sigma^2) \Rightarrow p = W\{X \leq x_p\} =$

$$= W\left\{ \frac{X - \mu}{\sigma} \leq \frac{x_p - \mu}{\sigma} \right\}; \text{ wegen der strikten Monotonie}$$


$\sim N(0,1) = u_p$ von $\Phi(\cdot) \Rightarrow \text{Beh.} //$

Test: Gestalt des Bildes der empir. VF oder einer
anderen Schätzung der VF.

29.3



Normal Probability Plot



29.2 Fehlerarten und Fehlerwahrscheinlichkeiten

Eine Stat. Hypothese \mathcal{H}_0 kann richtig oder falsch sein.

Def.: Die Verwerfung einer richtigen Hypothese heißt ein Fehler erster Art.

Die Annahme einer falschen Hypothese heißt ein Fehler zweiter Art.

Bem.: Fehlerwahrscheinlichkeiten

$$\alpha = W\{\mathcal{H}_0 \text{ verworfen} \mid \mathcal{H}_0 \text{ richtig}\}$$

$$\beta = W\{\mathcal{H}_0 \text{ angenommen} \mid \mathcal{H}_0 \text{ falsch}\}$$

29.5

Ideal wären Tests, die beide Fehlerwahrscheinlichkeiten klein halten. \rightarrow Plausibilitätsquotiententests

Die Konstruktion von Stat. Tests erfolgt über Fehlerwahrscheinlichkeiten erster Art.

29.3 Verwerfungsräume, Teststatistiken und kritische Bereiche

SP X_1, \dots, X_n von X , Hypothese \mathcal{H}

Stichprobenraum M_X^m zerlegt: $M_X^m = V \cup A$

falls eine konkrete SP x_1, \dots, x_n in V liegt, wird \mathcal{H} verworfen, V heißt Verwerfungsraum.

29.6

Beispiel: $X \sim N(\mu, \sigma_0^2)$, σ_0^2 bekannt, SP X_1, \dots, X_n

$\mathcal{H}_0: \mu = \mu_0$ mit gegebenem μ_0

Zur Konstruktion eines Tests gibt man eine kleine Wahrscheinlichkeit α eines Fehlers 1. Art (Irrtumswahrscheinlichkeit) vor.

Bei richtiger \mathcal{H}_0 gilt $T = \frac{\bar{X}_n - \mu_0}{\sigma_0 / \sqrt{n}} \sim N(0,1)$

Die Testentscheidung hängt vom Wert der sog. Teststatistik T ab: Es gilt, falls \mathcal{H}_0 richtig,

$$W \left\{ u_{\frac{\alpha}{2}} \leq T \leq u_{1-\frac{\alpha}{2}} \right\} = 1-\alpha$$

29.7

Wegen $u_{\frac{\alpha}{2}} = -u_{1-\frac{\alpha}{2}}$ nimmt man den Verwerfungsraum

$$V = \left\{ (x_1, \dots, x_n) : \left| \frac{\bar{x}_n - \mu_0}{\sigma_0 / \sqrt{n}} \right| \geq u_{1-\frac{\alpha}{2}} \right\}$$

Bem.: Man nimmt \mathcal{H}_0 an oder verwirft \mathcal{H}_0 , je nachdem ob der konkrete Wert t der Teststatistik T im Intervall $(-u_{1-\frac{\alpha}{2}}, u_{1-\frac{\alpha}{2}})$ liegt oder im


Komplement $(-\infty, -u_{1-\frac{\alpha}{2}}] \cup [u_{1-\frac{\alpha}{2}}, \infty) = C$

C heißt kritischer Bereich für die Teststatistik

29.8

Zur Fehlerwahrscheinlichkeit zweiter Art:

$$T = \frac{\bar{X}_n - \mu_0}{\sigma_0 / \sqrt{n}} \sim N\left(\frac{\mu - \mu_0}{\sigma_0 / \sqrt{n}}, 1\right)$$



29.9

30. TESTS FÜR NORMALVERTEILUNGEN

Alle betrachteten SG als normalverteilt vorausges.
Parameter unbekannt

30.1 t-Test für den Erwartungswert

Ist $X \sim N(\mu, \sigma^2)$ mit μ und σ^2 unbekannt und x_1, \dots, x_n eine konkrete SP von X , so ist ein Test für $\mathcal{H}_0: \mu = \mu_0$ mit Wahrsch. α eines Fehlers 1. Art durch folgenden Verwerfungsraum V gegeben:

$$V = \left\{ (x_1, \dots, x_n) : \frac{\sqrt{n} |\bar{x}_n - \mu_0|}{s_n} \geq t_{n-1, 1-\frac{\alpha}{2}} \right\}$$

mit $t_{n-1, p}$... p-Fraktilen der t_{n-1} -Vtlg.

30.1

Begründung: Satz 28.2 $\Rightarrow T = \frac{\sqrt{n}(\bar{X}_n - \mu_0)}{S_n} \sim t_{n-1}$

Dichtef. der t_{n-1} symmetrisch $\Rightarrow t_{n-1, \frac{\alpha}{2}} = -t_{n-1, \frac{\alpha}{2}}$

$$W\{\text{Fehler 1. Art}\} = W\left\{\frac{\sqrt{n}|\bar{X}_n - \mu_0|}{S_n} \geq t_{n-1, 1-\frac{\alpha}{2}}\right\} = \alpha //$$

30.2 Test für die Varianz

Ist $X \sim N(\mu, \sigma^2)$ mit μ und σ^2 unbekannt, x_1, \dots, x_n eine konkrete SP von X , so ist ein Test für die $\mathcal{H}_0: \sigma^2 = \sigma_0^2$ mit Wahrsch. α eines Fehlers 1. Art durch folgenden Verwerfungsraum V bestimmt:

30.2

$$V = \left\{ (x_1, \dots, x_n) : \frac{(n-1)S_n^2}{\sigma_0^2} \notin \left(\chi_{n-1, \frac{\alpha}{2}}^2, \chi_{n-1, 1-\frac{\alpha}{2}}^2 \right) \right\}$$

Beweis: Satz 28.2 \Rightarrow Vtlg. von $\frac{(n-1)S_n^2}{\sigma_0^2} \sim \chi_{n-1}^2$

Rest analog zum vorigen Beweis.

Bem.: Kritischer Bereich $(-\infty, \chi_{n-1, \frac{\alpha}{2}}^2] \cup [\chi_{n-1, 1-\frac{\alpha}{2}}^2, \infty)$

30.3 Zwei-Stichproben-Problem

Frage: Haben 2 SG_n dieselbe Normalverteilung?

Gegeben: 2 Messreihen x_1, \dots, x_m
 y_1, \dots, y_n

30.3

t-Test für die Gleichheit der Erwartungswerte

Ist X_1, \dots, X_m eine SP einer $N(\mu_x, \sigma^2)$ und Y_1, \dots, Y_n eine SP einer $N(\mu_y, \sigma^2)$ und sind die SP_n unabhängig,

so gilt

$$T = \frac{\overline{X}_m - \overline{Y}_n - \mu_x + \mu_y}{\sqrt{\left(\frac{1}{m} + \frac{1}{n}\right) \frac{(m-1)S_m^2 + (n-1)S_n^2}{m+n-2}}} \sim t_{m+n-2}$$

(ohne Beweis)

Ein Test für $\mathcal{H}_0: \mu_x = \mu_y$ mit Wahrsch. α eines Fehlers 1. Art:

$$\text{verwerfen falls } t = \left| \frac{\overline{X}_m - \overline{Y}_n}{\sqrt{\left(\frac{1}{m} + \frac{1}{n}\right) \frac{(m-1)S_m^2 + (n-1)S_n^2}{m+n-2}}} \right| \geq t_{m+n-2; 1-\frac{\alpha}{2}}$$

30.4

F-Test für die Gleichheit der Varianzen

Def.: Die F-Verteilung mit m und n Freiheitsgraden, i.Z. $F_{m,n}$ hat folgende Dichtefunktion

$$f(x|m,n) = \frac{\Gamma\left(\frac{m+n}{2}\right) m^{\frac{m}{2}} n^{\frac{n}{2}} x^{\frac{m}{2}-1}}{\Gamma\left(\frac{m}{2}\right) \Gamma\left(\frac{n}{2}\right) (m+n)^{\frac{m+n}{2}}} I_{(0,\infty)}(x)$$

$F_{m,n;p}$... p-Fraktiles der $F_{m,n}$ (tabelliert)

Es gilt: Ist X_1, \dots, X_m SP von $X \sim N(\mu_x, \sigma_x^2)$ und Y_1, \dots, Y_n SP von $Y \sim N(\mu_y, \sigma_y^2)$, unabhängige SP_n

$$\Rightarrow \frac{S_x^2/\sigma_x^2}{S_y^2/\sigma_y^2} \sim F_{m-1, n-1}$$

30.5

Test: Ein Test für $\mathcal{H}_0: \sigma_x^2 = \sigma_y^2$ mit Wahrsch. α eines Fehlers 1. Art durch die Teststatistik

$$T = \frac{S_x^2}{S_y^2}$$

Entscheidungsregel: \mathcal{H}_0 verwerfen, falls für 2 konkrete SP $_n$ x_1, \dots, x_m und y_1, \dots, y_n gilt

$$\frac{\Delta_x^2}{\Delta_y^2} \notin (F_{m-1, n-1; \frac{\alpha}{2}} , F_{m-1, n-1; 1-\frac{\alpha}{2}})$$

Bem.: Für mehr als 2 Messreihen Bartlett-Test

31. DER CHIQUADRAT-ANPASSUNGSTEST

Ein asymptotisches Verfahren bei größeren SP $_n$

Problem: Hat eine empirisch gegebene SG eine bestimmte Verteilung bzw. bestimmten Verteilungstyp

31.1 Einfache Hypothesen

Satz: Ist X_1, X_2, \dots eine unbeschränkte SP von $X \sim W$ auf (M_x, \mathcal{L}) und A_1, \dots, A_r eine Zerlegung von M_x mit $A_j \in \mathcal{L} \forall j=1(1)r$, so gilt mit den Bezeichnungen

$$w_j = W(A_j) \text{ für } j=1(1)r$$

$Y_j^{(n)}$ = absolute Häufigkeit von A_j nach n Beobachtungen

$$\lim_{n \rightarrow \infty} W \left\{ Z_n = \sum_{j=1}^r \frac{[Y_j^{(m)} - n w_j]^2}{n w_j} \leq \chi_{r-1, p}^2 \right\} = p \quad \forall p \in (0, 1)$$

d.h. Z_n ist asymptotisch nach χ_{r-1}^2 verteilt.

Test: Mit den voranstehenden Bezeichnungen ist ein Test für $\mathcal{H}_0: X \sim W$ durch den Verwerfungsraum

$$V = \{ (x_1, \dots, x_n) : z_n \geq \chi_{r-1, 1-\alpha}^2 \} \text{ gegeben,}$$

dessen Wahrscheinlichkeit eines Fehlers 1. Art für $n \rightarrow \infty$ gegen α konvergiert.

Begründung: Bei richtiger \mathcal{H}_0 ist die Teststatistik Z_n asymptotisch χ_{r-1}^2 -verteilt ($n \rightarrow \infty$)

Bem.: Bei Anwendung soll für A_1, \dots, A_r gelten:

$$n w_j \geq 5 \quad \forall j = 1(1)r$$

Beispiel: Es soll getestet werden, ob 100 "zufällig" aus $[0, 1]$ gewählte Zahlen x_1, \dots, x_{100} nach $U_{0,1}$ verteilt angesehen werden können. Ü

31.2 Zusammengesetzte Parameterhypothesen

Problem: Hat eine empir. geg. SG einen bestimmten parametrischen Verteilungstyp

$$X_1, \dots, X_n, \dots \text{ SP von } X, \quad X \sim W_\theta, \quad \theta \in \Theta$$

$$\mathcal{H}_0: X \sim W_\theta, \quad \theta = (\theta_1, \dots, \theta_s) \quad s\text{-dim Parameter}$$

Satz: Ist X_1, \dots, X_n, \dots eine unbeschr. SP von $X \sim W_\theta$ mit $\theta \in \Theta \subseteq \mathbb{R}^s$, wobei Θ ein offenes, nicht ausgeartetes s -dimensionales Intervall ist und A_1, \dots, A_r eine Zerlegung von M_X in Ereignisse, wobei $r > s+1$,

$$w_j(\theta) := W_\theta(A_j), \quad j=1(1)r$$

$Y_j^{(n)} :=$ absolute Häuf. von A_j nach n Beob. von X und

\exists die plausiblen Schätzwerte $\hat{\theta}^{(n)}$ für θ , so gilt:

$$\lim_{n \rightarrow \infty} W \left\{ Z_n = \sum_{j=1}^r \frac{[Y_j^{(n)} - n w_j(\hat{\theta}^{(n)})]^2}{n w_j(\hat{\theta}^{(n)})} \leq \chi_{r-s-1}^2, p \right\} = p \quad \forall p \in (0,1)$$

d.h. Z_n ist asymptotisch nach χ_{r-s-1}^2 verteilt

(ohne Beweis, 1900)

Chiquadrattest für zusammengesetzte Hypothesen:

Ein Test für die zusammengesetzte $\mathcal{H}_0: X \sim W_\theta, \theta \in \Theta$ dessen Wahrsch. eines Fehlers 1. Art mit $n \rightarrow \infty$ gegen α konvergiert, ist durch folgenden Verwerfungsräum V gegeben:

$$V = \{ (x_1, \dots, x_n) : z_n(x_1, \dots, x_n) \geq \chi_{r-s-1}^2, 1-\alpha \}$$

B3: Testen, ob Wartezeiten eine $Ex_\tau, \tau \in (0,1)$ haben

Beispiel: Testen, ob die Anzahl von Ausfällen eines Computertyps in einem bestimmten Zeitraum eine Poisson-Verteilung hat

32. KLASSISCHE REGRESSIONSRECHNUNG

Beschreibung kausaler, nicht deterministischer Zusammenhänge mit Stochastischen Modellen

B4: Abhängigkeit des Bremsweges von der Geschwindigkeit (Kovariable, Einflussgröße)

x ... Geschwindigkeit (-- " --)

Y_x ... Bremsweg (SG) abhängige Größe

Stoch. Modell $Y_x = \underbrace{\psi(x)}_{\text{det.}} + \underbrace{U_x}_{\text{stoch.}}$

$EY_x = \psi(x)$ Regressionsfunktion 2. Art

32.1

32.1 Lineare Regressionsfunktionen

$Y_x \sim W_\theta$ mit $\theta \in \mathbb{R}$ oder $\theta \in \mathbb{R}^k$, d.h.

$$\theta = \begin{pmatrix} \theta_1 \\ \vdots \\ \theta_k \end{pmatrix}$$

$$\psi(x) = E_{\theta} Y_x = \psi(x, \theta)$$

Auch die Einflussgröße x kann ein Vektor $\underline{x} = \begin{pmatrix} x_1 \\ \vdots \\ x_k \end{pmatrix}$ sein

Def.: Eine Regressionsfunktion heißt lineare Regressionsfunktion, wenn sie als Funktion der unbekanntesten Parameter linear ist.

32.2

Beispiele: 1) $\theta = \begin{pmatrix} \alpha \\ \beta \end{pmatrix}$, $\psi(x, \theta) = \alpha + \beta x$

2) $\theta = \begin{pmatrix} \theta_0 \\ \theta_1 \\ \vdots \\ \theta_k \end{pmatrix}$, $\psi(x, \theta) = \theta_0 + \theta_1 x + \theta_2 x^2 + \dots + \theta_k x^k$
polynomische Regression

3) für vektorielle Einflussgrößen $\underline{x} = (x_1, \dots, x_k)$
und Parametervektor $\theta = \begin{pmatrix} \theta_1 \\ \vdots \\ \theta_k \end{pmatrix}$

$\psi(\underline{x}, \theta) = \theta_1 x_1 + \theta_2 x_2 + \dots + \theta_k x_k = \underline{x} \theta$
multiple Regression

32.3

Bem.: Die Regressionsparameter müssen aus Beobachtungen (x_i, y_i) , $i = 1(1)n$ bzw. bei Vektorgrößen \underline{x} aus Beobachtungen $(x_{i1}, \dots, x_{ik}, y_i)$, $i = 1(1)n$ geschätzt werden.

32.2 Regressionsgeraden

$x \in \mathbb{R}$, $\psi(x, \alpha, \beta) = \alpha + \beta x \quad \forall x \in (a, b)$


Voraussetzung: $Y_x = \alpha + \beta x + U_x$ mit konst. Varianz

$\text{Var } U_x \equiv \sigma^2 \quad \forall x \in (a, b) \dots$ Homoskedastizität

Daten (x_i, y_i) , $i = 1(1)n$, mindestens 2 verschiedene x_i

32.4

$y = \hat{\alpha} + \hat{\beta}x$ Ausgleichsgerade



Bem.: Keine Stoch.

$$AQS = \sum_{i=1}^n (y_i - \alpha - \beta x_i)^2$$

32.5

Frage: Liefert die Ausgleichsrechnung, d.h. suche jene Werte $\hat{\alpha}$ und $\hat{\beta}$, sodass

$$\sum_{i=1}^n (y_i - \hat{\alpha} - \hat{\beta} x_i)^2 = \min_{\alpha, \beta} \sum_{i=1}^n (y_i - \alpha - \beta x_i)^2$$

auch statistisch sinnvolle Schätzungen für α und β ?

Def.: Schätzfunktionen A und B für die Parameter α und β der Regressionsgeraden heißen linear, wenn sie folgende Form haben:

$$A = \sum_{i=1}^n c_i Y_i \quad \text{und} \quad B = \sum_{i=1}^n d_i Y_i$$

wobei Y_i steht für Y_{x_i}

32.6

Satz von Gauß-Markoff: Mit den Bezeichnungen dieses Abschnitts mit einer SP (x_i, Y_i) , $i = 1(1)n$ und unter folgenden Voraussetzungen (1) bis (4)

- (1) x_1, \dots, x_n sind nicht alle gleich
- (2) Y_1, \dots, Y_n sind unkorreliert
- (3) $\text{Var } Y_i \equiv \sigma^2$, d.h. alle Varianzen sind gleich
- (4) $\mathbb{E} Y_i = \alpha + \beta x_i$ $\forall i = 1(1)n$ mit reellen Konstanten α, β wobei α, β und σ^2 unbekannt sind,

gilt:

Die effizienten linearen Schätzfunktionen A und B für α und β sind folgende

$$A = \frac{\left(\sum_{i=1}^n x_i^2\right)\left(\sum_{i=1}^n Y_i\right) - \left(\sum_{i=1}^n x_i\right)\left(\sum_{i=1}^n x_i Y_i\right)}{n\left(\sum_{i=1}^n x_i^2\right) - \left(\sum_{i=1}^n x_i\right)^2}$$

$$B = \frac{n\left(\sum_{i=1}^n x_i Y_i\right) - \left(\sum_{i=1}^n x_i\right)\left(\sum_{i=1}^n Y_i\right)}{n\left(\sum_{i=1}^n x_i^2\right) - \left(\sum_{i=1}^n x_i\right)^2}$$

und diese ergeben für konkrete Beobachtungspaare (x_i, y_i) , $i = 1(1)n$ die Werte $\hat{\alpha}$ und $\hat{\beta}$ der Ausgleichsgeraden $y = \hat{\alpha} + \hat{\beta}x$, Schätzwerte für α und β .

Für die SF_n A und B gilt:

$$\text{Var } A = \frac{\sum_{i=1}^n x_i^2}{n \left(\sum_{i=1}^n x_i^2 \right) - \left(\sum_{i=1}^n x_i \right)^2} \sigma^2$$

$$\text{Var } B = \frac{n}{n \left(\sum_{i=1}^n x_i^2 \right) - \left(\sum_{i=1}^n x_i \right)^2} \sigma^2$$

$$\text{Cov}(A, B) = - \frac{\sum_{i=1}^n x_i}{n \left(\sum_{i=1}^n x_i^2 \right) - \left(\sum_{i=1}^n x_i \right)^2} \sigma^2$$

32.9

Eine unverzerrte SF für σ^2 ist

$$S^2 := \frac{\sum_{i=1}^n (Y_i - A - Bx_i)^2}{n-2}$$

(o. Bew.)

Bem.: Ein analoger Satz gilt für multiple lineare Regressionsmodelle

32.10

VII

ELEMENTE DER BAYES-STATISTIK

Hier alle unbekanntes Größen durch SG_n beschrieben, auch Parameter θ von Stoch. Modellen $X \sim W_\theta, \theta \in \Theta$

$\tilde{\theta} \sim \pi(\cdot)$ auf Θ vor Erhebung von Daten D

$\pi(\cdot)$ heißt A-priori-Verteilung von $\tilde{\theta}$

Nach Beobachtung von D neue Verteilung $\pi(\cdot|D)$

33. BAYES'sches THEOREM

$X \sim f(\cdot|\theta), \theta \in \Theta, \pi(\cdot)$ A-priori-Vtlg. von $\tilde{\theta}$

SP x_1, \dots, x_n

Die durch $X_1 = x_1, \dots, X_n = x_n$ bedingte Vtlg. von $\tilde{\theta}$,

i.Z. $\pi(\cdot | x_1, \dots, x_n)$ heißt A-posteriori-Verteilung.

33.1 Diskreter Fall

$X \sim p(\cdot|\theta), \theta \in \{\theta_1, \dots, \theta_k\}$, a-priori $\pi(\theta_j), j=1(1)k$

Daten x_1, \dots, x_n von X_1, \dots, X_n SP von X

A-posteriori - Wahrscheinlichkeiten der θ_j :

$\{\theta_1\}, \{\theta_2\}, \dots, \{\theta_k\}$ Zerlegung von $\Theta = \{\theta_1, \dots, \theta_k\}$

$$\pi(\theta_j | x_1, \dots, x_n) = W\{\tilde{\theta} = \theta_j | X_1 = x_1, \dots, X_n = x_n\}$$

$$= \frac{W\{X_1 = x_1, \dots, X_n = x_n, \tilde{\theta} = \theta_j\}}{W\{X_1 = x_1, \dots, X_n = x_n\}}$$

wegen der Def. von bedingten Wahrsch. diskreter Größen gilt

$$W\{X_1 = x_1, \dots, X_n = x_n, \tilde{\theta} = \theta_j\} = w(x_1, \dots, x_n | \theta_j) W\{\tilde{\theta} = \theta_j\}$$

und

$$W\{X_1 = x_1, \dots, X_n = x_n\} = \sum_{j=1}^k w(x_1, \dots, x_n | \theta_j) \pi(\theta_j)$$

33.2

Daher gilt das sog. Bayes'sche Theorem (diskret):

$$\pi(\theta_j | x_1, \dots, x_n) = \frac{w(x_1, \dots, x_n | \theta_j) \pi(\theta_j)}{\sum_{j=1}^k w(x_1, \dots, x_n | \theta_j) \pi(\theta_j)} \quad \forall j = 1(1)k$$

Im Fall einfacher SP_n gilt wegen der Unabhängigkeit

$$w(x_1, \dots, x_n | \theta_j) = \prod_{i=1}^n p(x_i | \theta_j)$$

Bem.: Plausibilitätsfunktion $l(\theta; x_1, \dots, x_n)$

$$\Rightarrow w(x_1, \dots, x_n | \theta_j) \pi(\theta_j) = \pi(\theta_j) l(\theta; x_1, \dots, x_n)$$

Da $\sum_{j=1}^k \pi(\theta_j) l(\theta; x_1, \dots, x_n)$ nach Beobachtung der

konkreten SP x_1, \dots, x_n eine Konstante ist

33.3

gilt $\pi(\theta_j | x_1, \dots, x_n) = \frac{1}{C} \pi(\theta_j) \ell(\theta_j; x_1, \dots, x_n) \quad \forall j = 1(1)k$

In Kurzschreibweise:

$$\pi(\theta_j | x_1, \dots, x_n) \propto \pi(\theta_j) \ell(\theta_j; x_1, \dots, x_n) \quad \forall \theta_j \in \Theta$$

33.2 Kontinuierlicher Fall

$X \sim f(\cdot | \theta)$, $\theta \in \Theta$, $\tilde{\theta} \sim \pi(\cdot)$ A-priori-Dichte

SP X_1, \dots, X_n ; für gegebenen Parameter θ ist

$g(x_1, \dots, x_n | \theta) = \prod_{i=1}^n f(x_i | \theta)$ Dichte der SP

Gesucht: Verteilung von $\tilde{\theta} | X_1 = x_1, \dots, X_n = x_n$

33.4

Lösung: Bedingte Dichte $\pi(\cdot | x_1, \dots, x_n)$

Gemeinsame Dichte von $(X_1, \dots, X_n, \tilde{\theta})$ ist

$$g(x_1, \dots, x_n, \theta) = \left[\prod_{i=1}^n f(x_i | \theta) \right] \pi(\theta)$$

Randdichte von X_1, \dots, X_n ist

$$\int_{\Theta} g(x_1, \dots, x_n, \theta) d\theta = \int_{\Theta} \pi(\theta) \ell(\theta; x_1, \dots, x_n) d\theta, \text{ dies ist}$$

nach Beobachtung von konkreten x_1, \dots, x_n eine Konstante. Daher gilt für die A-posteriori-Dichte des Parameters

33.5

$$\pi(\theta | x_1, \dots, x_n) = \frac{\pi(\theta) \mathcal{L}(\theta; x_1, \dots, x_n)}{\int_{\Theta} \pi(\theta) \mathcal{L}(\theta; x_1, \dots, x_n) d\theta} = \frac{1}{C} \pi(\theta) \mathcal{L}(\theta; x_1, \dots, x_n)$$

In Kurzschreibweise:

$$\pi(\theta | x_1, \dots, x_n) \propto \pi(\theta) \mathcal{L}(\theta; x_1, \dots, x_n) \quad \theta \in \Theta$$

Bem.: Für allgemeinere Daten D gilt auch

$$\pi(\theta | D) \propto \pi(\theta) \mathcal{L}(\theta; D) \quad \theta \in \Theta$$

Kurzform des Bayes'schen Theorems

33.6

34. SUFFIZIENZ UND KONJUGIERTE VERTEILUNGSFAMILIEN

Welche Information aus den beobachteten Daten D ist hinreichend (suffizient) zur Berechnung der A-posteriori-Verteilung?

Kann man die Berechnung der ApoV vereinfachen?

34.1 Suffiziente Statistiken

B3: Wartezeit $X \sim \text{Ex}_\tau$, ApoV (Dichte) $\pi(\cdot)$,

Daten x_1, \dots, x_n ,
$$\mathcal{L}(\tau; x_1, \dots, x_n) = \prod_{i=1}^n \frac{1}{\tau} e^{-\frac{x_i}{\tau}}$$

34.1

$$\Rightarrow \text{ApoD } \pi(\tau|x_1, \dots, x_n) \propto \pi(\tau) \frac{1}{\tau^n} e^{-\frac{1}{\tau} \sum_{i=1}^n x_i}$$

$$\Rightarrow \sum_{i=1}^n x_i \text{ hinreichend}$$

Def.: Ist $X \sim f(\cdot|\theta)$, $\theta \in \Theta$ SM mit kontin. Parameter und X_1, \dots, X_n SP von X , so heißt eine Statistik $S = s(X_1, \dots, X_n)$ suffizient für θ , falls die ApoD von den Daten x_1, \dots, x_n nur über $s(x_1, \dots, x_n)$ abhängt.

Beispiele: 1) s.o.

$$2) X \sim N(\mu, \sigma^2) \Rightarrow \left(\sum_{i=1}^n X_i, \sum_{i=1}^n X_i^2 \right) \text{ suffizient}$$

$$3) X \sim A_\theta \Rightarrow \sum_{i=1}^n X_i \text{ suffizient für } \theta \quad (\text{s.u. 34.2})$$

34.2

34.2 Konjugierte Verteilungsfamilien

B1: Anteil θ , die Familie der sog. Beta-Verteilungen hat folgende Eigenschaft: Für $\pi(\cdot) \in \mathcal{F}$ und bel. Beob. x_1, \dots, x_n ist auch $\pi(\cdot|x_1, \dots, x_n) \in \mathcal{F}$

Def.: $T \sim \text{Be}(a, b)$ Beta-Verteilung, falls $M_T = [0, 1]$ und die Dichtefunktion ist

$$f(t) = \frac{\Gamma(a+b)}{\Gamma(a)\Gamma(b)} t^{a-1} (1-t)^{b-1} I_{[0,1]}(t)$$

Fortsetzung von B1: Für $X \sim A_\theta \hat{=} p(\cdot|\theta)$ gilt

$$p(x|\theta) = \theta^x (1-\theta)^{1-x} I_{\{0,1\}}(x)$$

34.3

$$\begin{aligned}
 \ell(\theta; x_1, \dots, x_n) &= \prod_{i=1}^n \theta^{x_i} (1-\theta)^{1-x_i} I_{\{0,1\}}(x_i) I_{[0,1]}(\theta) \\
 &= \theta^{\sum_{i=1}^n x_i} (1-\theta)^{n - \sum_{i=1}^n x_i} I_{\{0,1\}}(x_i) I_{[0,1]}(\theta)
 \end{aligned}$$

Für $\pi(\cdot) \triangleq \text{Be}(a,b)$ folgt daher wegen $x_i \in \{0,1\}$

$$\begin{aligned}
 \pi(\theta | x_1, \dots, x_n) &\propto \pi(\theta) \ell(\theta; x_1, \dots, x_n) = \\
 &= \theta^{a-1} (1-\theta)^{b-1} I_{[0,1]}(\theta) \theta^{\sum_{i=1}^n x_i} (1-\theta)^{n - \sum_{i=1}^n x_i} \\
 &= \theta^{a + \sum_{i=1}^n x_i - 1} (1-\theta)^{b + n - \sum_{i=1}^n x_i - 1} I_{[0,1]}(\theta)
 \end{aligned}$$





Dichtetf. der $\text{Be}(a + \sum_{i=1}^n x_i, b + n - \sum_{i=1}^n x_i)$

24.4

Def: Eine Familie \mathcal{F} von W -Vtlgen für den Parameter θ eines SM $X \sim W_\theta$, $\theta \in \Theta$ heißt zum Modell konjugierte A-priori-Familie, falls für jede $\text{AprV} \in \mathcal{F}$ und beliebige Daten auch die $\text{ApoV} \in \mathcal{F}$.

Bsp: $X \sim P_\mu$, $\mu > 0$, die GammaVtlgen $\text{Gam}(a, \frac{1}{b})$ bilden eine dazu konjugierte A-priori-Familie \ddot{U}

24.5



35. VERWENDUNG DER A-POSTERIORI-VTLG.

In der ApoV alle wesentliche Information enthalten

$$X \sim f(\cdot|\theta), \theta \in \Theta, \pi(\cdot), \text{ Daten } D, \pi(\cdot|D)$$

35.1 Prädiktivverteilungen

Prognose für $X|D$: Randverteilung von X aus der gemeinsamen Vtlg. von $(X, \tilde{\theta}) \sim f(x|\theta)\pi(\theta|D)$

$$f(x|D) = \int_{\Theta} f(x|\theta)\pi(\theta|D)d\theta \quad \forall x \in M_X$$

$f(\cdot|D)$ heißt Prädiktivdichte für X

35.2 A-posteriori - Bayes - Schätzer

Schätzwert $\hat{\theta}$ für $\theta \in \mathbb{R}$

Def.: Der A-posteriori - Bayes - Schätzer ist, falls er existiert, der Erwartungswert von $\tilde{\theta}|D$,

$$\hat{\theta} = \int_{\Theta} \theta \pi(\theta|D) d\theta$$

Für Vektorparameter $\theta = (\theta_1, \dots, \theta_k)$ und gerafften Parameter $\tau(\theta) \in \mathbb{R}$ ist der ApoBS für $\tau(\theta)$

$$\widehat{\tau(\theta)} := \mathbb{E}_D \tau(\tilde{\theta}) = \int_{\Theta} \tau(\theta) \pi(\theta|D) d\theta$$

falls \exists

35.2

B1: Für $\pi(\cdot) \cong U_{0,1}$ ist der ApoBS für den Anteil θ nach Beob. von x_1, \dots, x_n folgendermaßen

$$\pi(\theta|x_1, \dots, x_n) \propto \theta^{\sum_{i=1}^n x_i} (1-\theta)^{n - \sum_{i=1}^n x_i} I_{[0,1]}(\theta)$$

$$\hat{\theta} = \frac{\int_0^1 \theta \cdot \theta^{\sum x_i} (1-\theta)^{n - \sum x_i} d\theta}{\int_0^1 \theta^{\sum x_i} (1-\theta)^{n - \sum x_i} d\theta} = \dots = \frac{\sum_{i=1}^n x_i + 1}{n+2}$$

35.3

35.3 HPD - Bereiche

$\theta \in \Theta \subseteq \mathbb{R}^k$, $D = x_1, \dots, x_n \Rightarrow \pi(\cdot|D)$
vorgegebene Wahrscheinlichkeit $1-\alpha$ (Sicherheit)


Def.: Ein HPD-Vertrauensbereich ist eine Teilmenge

$\Theta^* \subseteq \Theta$, mit $\int_{\Theta^*} \pi(\theta|D) d\theta = 1-\alpha$

und auf Θ^* ist $\pi(\theta|D)$ größtmöglich, d.h.

$\pi(\theta|D) \geq C \quad \forall \theta \in \Theta^*$, wobei C die größtmögliche Konstante ist

35.4



35.3 HPD - Bereiche

$\theta \in \Theta \subseteq \mathbb{R}^k$, $D = x_1, \dots, x_n \Rightarrow \pi(\cdot | D)$
vorgegebene Wahrscheinlichkeit $1 - \alpha$ (Sicherheit)

Def.: Ein HPD - Vertrauensbereich ist eine Teilmenge $\Theta^* \subseteq \Theta$, mit

$$\int_{\Theta^*} \pi(\theta | D) d\theta = 1 - \alpha$$

und auf Θ^* ist $\pi(\theta | D)$ größtmöglich, d.h.

$\pi(\theta | D) \geq C \quad \forall \theta \in \Theta^*$, wobei C die größtmögliche Konstante ist

35.4

35.4 A-posteriori - Wahrscheinlichkeiten von statistischen Hypothesen

$X \sim W_\theta$, $\theta \in \Theta$, $\pi(\cdot)$, $(x_1, \dots, x_n) = D$, $\pi(\cdot | D)$

Parameterhypothesen $\mathcal{H}_0: \theta \in \Theta_0 \subset \Theta$

$\mathcal{H}_1: \theta \in \Theta_1 \subset \Theta \setminus \Theta_0$

ApoW der Hypothesen

$$\alpha_0 := W\{\tilde{\theta} \in \Theta_0 | D\}$$

$$\alpha_1 := W\{\tilde{\theta} \in \Theta_1 | D\}$$

Def.: Relative Plausibilität $\frac{\alpha_1}{\alpha_0}$

35.5

Bem.: Für kontinuierlichen Parameterraum Θ gilt

$$W\{\Theta_j | D\} = \int_{\Theta_j} \pi(\theta|D) d\theta \quad \text{für } j=0 \text{ bzw. } 1$$

und

$$\frac{\alpha_1}{\alpha_0} = \frac{\int_{\Theta_1} \pi(\theta|D) d\theta}{\int_{\Theta_0} \pi(\theta|D) d\theta} = \frac{\int_{\Theta_1} \pi(\theta) l(\theta, D) d\theta}{\int_{\Theta_0} \pi(\theta) l(\theta, D) d\theta} \quad \ddot{U}$$

35.6

36. BAYES'sche ENTSCHEIDUNGEN

Entscheidungen oft mit Nutzen bzw. Verlust verbunden.

B1: Warenlieferung N Stück, θ Schlechtanteil

G Gewinn für jedes gute Stück

K Verlust für jedes schlechte Stück

d_0 Entscheidung Annahme der Lieferung

d_1 Entscheidung Ablehnung der Lieferung

$L(\theta, d_j)$ Verlust für Schlechtanteil und Entscheidung d_j

$$\Rightarrow L(\theta, d_0) = \theta \cdot N \cdot K - (1-\theta) \cdot N \cdot G$$

$$L(\theta, d_1) = (1-\theta) \cdot N \cdot G$$

36.1

θ unbekannt, beschrieben durch SG $\tilde{\theta} \sim \pi(\cdot)$
Erhebung einer SP $D = (x_1, \dots, x_n) \Rightarrow \pi(\cdot | D)$ von $\tilde{\theta}$
Entscheidungskriterium: Zu erwartender Verlust

$$E_{\pi(\cdot | D)} L(\tilde{\theta}, d_j)$$

Def.: Die Bayes'sche Entscheidung ist jene, die
kleineren a-posteriori zu erwartenden Verlust
hat.

Beispiel: Ü

VIII ERGÄNZUNGEN

37. UNSCHARFE INFORMATION

Sowohl Beobachtungen SG_n als auch A-priori-Verteilungen sind oft nicht exakt, also unscharf (engl. fuzzy).

37.1 Unscharfe Zahlen

Jede exakte reelle Zahl x_0 ist eindeutig charakterisiert durch die Indikatorfunktion $I_{\{x_0\}}(\cdot)$.

Def.: Eine unscharfe Zahl x^* ist bestimmt durch ihre sog. charakterisierende Funktion $\xi(\cdot)$, die folgende Eigenschaften haben muss:



- (1) $\xi: \mathbb{R} \rightarrow [0,1]$
- (2) $\exists x_0 \in \mathbb{R}: \xi(x_0) = 1$
- (3) $\forall \delta \in (0,1]$ ist $B_\delta(x^*) := \{x \in \mathbb{R}: \xi(x) \geq \delta\}$ ein abgeschlossenes endliches Intervall $[a_\delta, b_\delta]$ genannt δ -Schnitt

Bem.: Unscharfe Zahlen sind Spezialfälle sog. unscharfer Mengen (= fuzzy sets, ensembles flous)

Bem.: Char. F_n sind etwas anderes als Dichten


$\int_{\mathbb{R}} \xi(x) dx$ ist das Maß der Unscharfe

Charakterisierende Funktionen




Spezialfälle charakterisierender Funktionen

$$\xi(x) = \mathbf{I}_{\{x_0\}}(x)$$



$$\xi(x) = \mathbf{I}_{[a,b]}(x)$$



37.2 Unschärfe Stichproben

Konkrete SP_n kontinuierlicher SG_n sind endliche Folgen x_1^*, \dots, x_n^* von unschärpen Zahlen.

Um Verfahren der schließenden Statistik zu adaptieren, ist die Kombination von x_1^*, \dots, x_n^* zu einem sog. unschärpen Vektor im Stichprobenraum notwendig.

X mit Merkmalraum M_X , Stichprobenraum M_X^n

Spezialfall $M_X \subseteq \mathbb{R}$, $M_X^n \subseteq \mathbb{R}^n$

37.5

Ein unschärfer Vektor \underline{x}^* ist durch seine sog. vektorcharakterisierende Funktion $\int: \mathbb{R}^n \rightarrow [0, 1]$ festgelegt.

Die Kombination von $\int_1(\cdot), \dots, \int_n(\cdot)$ erfolgt folgendermaßen:

$$\int(x_1, \dots, x_n) := \min_{i=1(1)n} \int_i(x_i) \quad \forall (x_1, \dots, x_n) \in \mathbb{R}^n$$

Bem.: δ -Schnitte von $\int(\cdot, \dots, \cdot)$:

$$C_\delta(\underline{x}^*) = \bigcap_{i=1}^n C_\delta(x_i^*) \quad \forall \delta \in (0, 1]$$

37.6

37.3 Verallgemeinerte Schätzungen

Schätzfunktion $\mathcal{N}: M_x^n \rightarrow \Theta$

bei exakten Beobachtungen x_1, \dots, x_n

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

Für unscharfe Beobachtungen x_1^*, \dots, x_n^*
und kombin. unscharfen Vektor \underline{x}^* mit $\text{vcF } \int(\cdot, \dots, \cdot)$
ergibt $\mathcal{N}(x_1^*, \dots, x_n^*)$ einen unscharfen Wert $\hat{\theta}^*$

Die char. F. von $\hat{\theta}^*$ erhält man mittels des
sog. Erweiterungsprinzips aus der FST:

37.7

Für die c.F. $\psi(\cdot)$ von $\hat{\theta}^*$ gilt mit $\underline{x} = (x_1, \dots, x_n) \in \mathbb{R}^n$

$$\psi(\theta) = \begin{cases} \sup \{ \int(\underline{x}) : \mathcal{N}(\underline{x}) = \theta \} & \text{falls } \mathcal{N}^{-1}(\theta) \neq \emptyset \\ 0 & \text{falls } \mathcal{N}^{-1}(\theta) = \emptyset \end{cases} \quad \forall \theta \in \Theta$$

Bem.: 1) Für $\theta \in \mathbb{R}$ und stetige Funktion $\mathcal{N}(\cdot, \dots, \cdot)$
ist obiges $\psi(\cdot)$ eine c.F. einer unscharfen
Zahl.

2) Für Vektorparameter erhält man ein unscharfes
Element (unscharfe Teilmenge) von Θ .

37.8

