

Wahrscheinlichkeitsrechnung und Statistik - Zusammenfassung

Patrick Pletscher

22. September 2003

1 Wahrscheinlichkeiten

1.1 Ereignisraum

Der *Ereignisraum* Ω umfasst alle möglichen Ausgänge eines Zufallsexperiments.

Ein *Elementarereignis* ω ist ein Element $\omega \in \Omega$

Ein Ereignis A ist eine Teilmenge von Ω , d.h. eine Kombination von Elementarereignissen $A \subset \Omega$

A^c (Komplement) ist das Ereignis, dass A nicht eintritt.

\mathcal{A} ist die Klasse der beobachteten Ereignisse. Falls Ω endlich ist, dann ist \mathcal{A} die Menge aller Teilmengen von Ω , d.h. die Potenzmenge.

1.2 Das Wahrscheinlichkeitsmass

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

$P(A) \doteq$ 'die Wahrscheinlichkeit, dass A eintritt'

Axiome der Wahrscheinlichkeitstheorie

A1 $0 \leq P(A) \leq 1$ für alle $A \subset \Omega$

A2 $P(\Omega) = 1$

A3 Sei A_1, A_2, \dots eine Folge disjunkter Ereignisse, dann $P(\cup_{i=1}^{\infty} A_i) = \sum_{i=1}^{\infty} P(A_i)$

Weitere Rechenregeln

$$P(A^c) = 1 - P(A)$$

$$P(\emptyset) = 0$$

$$A \subset B \Rightarrow P(A) \leq P(B)$$

$$P(A \cup B) = P(A) + P(B) - P(A \cap B)$$

$$P(A \cup B) = 1 - (P(\bar{A}) + P(\bar{B}))$$

und \rightarrow Multiplikation

1.3 Berechnung von W'keiten in endlichen Räumen

$$P(A) = \frac{|A|}{|\Omega|}$$

Exkurs in die Kombinatorik

Permutationen ohne Zurücklegen

Aus n Objekten sind $k \leq n$ herauszugreifen, wobei die Reihenfolge eine Rolle spielen soll.

$$\# \text{ Mögl.} = \frac{n!}{(n-k)!}$$

Permutationen mit Zurücklegen

Gegeben sind n Objekte. Wieviele Folgen der Länge k können gebildet werden, falls jedes Objekt beliebig oft gewählt werden darf.

$$\# \text{ Mögl.} = n^k$$

Kombinationen ohne Zurücklegen

Gegeben eine Menge mit n Elementen. Wieviele Teilmengen mit $k \leq n$ Elementen kann man daraus bilden?

$$\# \text{ Mögl.} = \frac{n!}{(n-k)!k!} = \binom{n}{k}$$

Bsp: Lotto (6 aus 45)

$$A = \{6 \text{ Richtige}\} = \binom{45}{6}$$

$$B = \{4 \text{ Richtige}\} = \binom{6}{4} \binom{39}{2}$$

1.4 Bedingte W'keiten

Seien A, B Ereignisse, $P(A) > 0$

Def.: Die *bedingte W'keit*, dass A gegeben B eintritt, ist

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

Multiplikationssatz

Sei $P(A) > 0$: Dann

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

Satz von der totalen W'keit

Gegeben seien Ereignisse A_1, \dots, A_n mit $P(A_i) > 0$.

Def.: Die A_i bilden eine Zerlegung von Ω , falls

1. $A_i \cap A_j = \emptyset$ für $i \neq j$, paarw. disj.

$$2. \Omega = \bigcup_{i=1}^n A_i$$

Dann gilt für $B \subset \Omega$ dass

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

Satz von Bayes

$$P(A|B) = \frac{P(A \cap B)}{P(B)} = \frac{P(B|A) \cdot P(A)}{P(B|A) \cdot P(A) + P(B|A^c) \cdot P(A^c)}$$

Allgemeine Formel von Bayes

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

1.5 Unabhängigkeit

Seien $A, B \subset \Omega$ zwei Ereignisse.

Def. A und B sind *unabhängig*, falls $P(A \cap B) = P(A)P(B)$

Falls $P(A) > 0$:

A, B unabh. $\Leftrightarrow P(B|A) = P(B)$

Falls $P(B) > 0$:

A, B unabh. $\Leftrightarrow P(A|B) = P(A)$

Allgemeine Definition der Unabhängigkeit

n Ereignisse A_1, \dots, A_n heißen *unabhängig*, falls für jede Wahl von je m Ereignissen

$$A_{k_1}, \dots, A_{k_m}, \{k_1, \dots, k_m\} \subset \{1, \dots, n\},$$

stets gilt:

$$P(A_{k_1} \cap \dots \cap A_{k_m}) = P(A_{k_1}) \cdot \dots \cdot P(A_{k_m})$$

2 Zufallsvariable

2.1 Begriff der ZV

Es sei Ω ein Ereignisraum. Eine ZV auf Ω ist eine Funktion $\Omega \rightarrow \mathbb{R}$.

Wir nennen eine ZV diskret, falls sie endliche oder abzählbar viele Werte annimmt.

2.2 Wahrscheinlichkeits- und Verteilungsfunktion

Def. Die W'keitsfunktion der diskreten ZV X ist die Funktion

$$p(x) = \begin{cases} P(X = x) & \text{falls } x \in \omega \\ 0 & \text{sonst} \end{cases}$$

ω : Wertebereich von X

Verteilungsfunktion F: $F(x) = P(X \leq x)$

Für diskrete ZV ist

$$F(x) = \sum p(x_i)$$

$x_i : x_i \in \omega, x_i \leq x$

Die Verteilungsfunktion ist:

- rechtsstetig
- $\lim_{x \rightarrow -\infty} F(x) = 0, \lim_{x \rightarrow +\infty} F(x) = 1$

2.3 Einige wichtige diskrete Verteilungen

1. Uniforme Verteilung (Gleichverteilung)

$$\omega = \{x_1, \dots, x_n\}$$

$$p(x_i) = P(X = x_i) = \frac{1}{n} \text{ Bsp: Würfeln mit einem Würfel}$$

2. Bernoulli-Verteilung

X nimmt nur die Werte 0 und 1 an

$$P(X = 1) = p$$

$$P(X = 0) = 1 - p$$

$$P(X) = p^x \cdot (1 - p)^{1-x}, x = 0, 1$$

$$X \sim Be(p)$$

3. Binomialverteilung

X="Anzahl Erfolge bei n Versuchen"

$$p(k) = \binom{n}{k} p^k (1 - p)^{n-k}$$

$$X \sim B(n, p)$$

Approx. durch Poisson

Multinomialverteilung

$$P[X_1 = x_1, X_2 = x_2, X_3 = x_3] = \frac{n!}{x_1! x_2! x_3!} p_1^{x_1} p_2^{x_2} p_3^{x_3}$$

4. Die geometrische Verteilung

X="Anzahl der Versuche, bis ein Erfolg eintritt"

$$p(k) = P(X = k) = (1 - p)^{k-1} p$$

5. Die negativbinomiale Verteilung

X="Anzahl Versuche, bis ich r-mal erfolgreich bin"

$$P(X = k) = \binom{k-1}{r-1} p^r (1 - p)^{k-r}$$

6. Die hypergeometrische Verteilung

n Gegenstände in einer Urne, r vom Typ I und n-r vom Typ II, ich ziehe m davon (ohne Zurücklegen)

$$P(X = k) = \frac{\binom{r}{k} \binom{n-r}{m-k}}{\binom{n}{m}}$$

Bsp: Lotto, 6 aus 45, W'keit eines Vierers:

$$n=45, r=6, m=6, k=4$$

7. Die Poisson-Verteilung

X="Anzahl Ereignisse in einem Zeitintervall (Anrufe, gedruckte Files)"

X ist Poisson-verteilt mit Parameter λ , falls

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

Wertebereich $W = 1, \dots, \infty$

$$\lambda = E[X] = n \cdot p$$

2.4 Stetige Zufallsvariablen

Sind ZV, die Werte in einem Intervall W annehmen können.

z.B.: $W = \mathbb{R}, W = \mathbb{R}^+, W = [0, 1]$

Definition

Sei X eine ZV mit *Verteilungsfunktion* oder *W'keitsfunktion* $F(x) = P[X \leq x]$.

Falls es eine Funktion $f(x)$ gibt, so dass

$F(x) = \int_{-\infty}^x f(y)dy$ für alle $x \in W$, dann heisst $f(x)$ die Dichte von X .

Eigenschaften

- $f(x) \geq 0$ für alle x
- $f(x)$ ist stetig oder stückweise stetig
- $\int_{-\infty}^{\infty} f(x)dx = 1$, weil $\lim_{x \rightarrow \infty} F(x) = 1$
- $a < b$: $P[a < X \leq b] = P[X \leq b] - P[X \leq a] = F(b) - F(a) = \int_a^b f(x)dx$
- $P[X = a] = 0$

Satz

An allen Stellen, an denen $f(x)$ stetig ist, gilt:
 $F'(x) = f(x)$

Beispiele

1. Gleichverteilung (Uniform Distribution): $X \sim U(0, 1)$

$$f(x) = \begin{cases} 1 & \text{für } x \in [0, 1] \\ 0 & \text{sonst} \end{cases}$$

$$F(x) = \begin{cases} 0 & \text{für } x < 0 \\ x & \text{für } x \in [0, 1] \\ 1 & \text{für } x > 1 \end{cases}$$

2. Exponentialverteilung $X \sim Exp(\lambda)$

$\lambda > 0$

$$f(x) = \begin{cases} \lambda e^{-\lambda x} & \text{für } x > 0 \\ 0 & \text{sonst} \end{cases}$$

$$F(x) = \begin{cases} \int_0^x f(y)dy = \int_0^x \lambda e^{-\lambda y} dy = 1 - e^{-\lambda x} & \text{für } x > 0 \\ 0 & \text{für } x < 0 \end{cases}$$

Die Exp-Verteilung ist gedächtnislos.
 Ein Ankunftsprozess, bei dem die Zeiten zwischen den Ankünften Exponentiell-verteilt ist, heisst Poisson-Prozess. λ heisst dann die (Ankunfts)Rate des Poisson-Prozess.

3. Die Normalverteilung / Gauss-Verteilung $X \sim N(\mu, \sigma^2)$

$$f(x) = \frac{1}{\sqrt{2\pi}\sigma} \exp\left\{-\frac{1}{2}\left(\frac{x-\mu}{\sigma}\right)^2\right\}$$

μ = "Mean", Mittelwert, $-\infty < \mu < \infty$
 σ = Standardabweichung, $\sigma > 0$
 σ^2 = Varianz

$F(x) = \int_{-\infty}^x f(y)dy$: keine geschlossene Form, aber Tabellen

Standardisierte NV:

$$\mu = 0, \sigma = 1$$

Wenn $X \sim N(\mu, \sigma^2)$ dann ist $\frac{x-\mu}{\sigma} \sim N(0, 1)$

$$P[X \leq x'] = P\left[\frac{x-\mu}{\sigma} \leq \frac{x'-\mu}{\sigma}\right] = \Phi\left(\frac{x'-\mu}{\sigma}\right)$$

$$\Phi(-x) = 1 - \Phi(x)$$

2.5 Transformation von ZV

Sei X eine ZV mit Verteilungsfkt. $F_X(x)$ und Dichte $f_X(x)$.

Gesucht: Verteilung und Dichte von $Y = g(X)$

Satz

Wenn $X \sim N(\mu, \sigma^2)$ und $Y = aX + b$, dann gilt $Y \sim N(a\mu + b, a^2\sigma^2)$

Satz

Sei X stetig, mit Dichte $f_X(x)$, Verteilung $F_X(x)$. Sei $Y = g(X)$, mit g diff'bar, streng monoton steigend/fallend auf einem Intervall I , wobei $f_X(x) = 0$ für $x \notin I$ ($I = \mathbb{R}$ ist zugelassen).

Dann ist die Dichte von Y

$$f_Y(y) = \begin{cases} f_X(g^{-1}(y)) \cdot \left|\frac{d}{dy}g^{-1}(y)\right| & \\ 0 & \text{sonst} \end{cases}$$

wobei g^{-1} die Umkehrfkt. von g und $y \in \{g(x)|x \in I\}$

und die Verteilungsfkt. von Y ist

$$F_Y(y) = \begin{cases} F_X(g^{-1}(y)) & \text{für } g \text{ steigend} \\ 1 - F_X(g^{-1}(y)) & \text{für } g \text{ fallend} \end{cases}$$

$y \in \{g(x)|x \in I\}$

Lognormale Verteilung

$X \sim N(\mu, \sigma^2)$, $Y = e^x$
 $g(x) = e^x$, $g^{-1}(y) = \ln y$, $I = \mathbb{R}$

Satz

Sei $U \sim U(0, 1)$.

Sei $F(x)$ eine stetige, streng monoton wachsende Verteilungsfunktion. Setze

$$X := F^{-1}(U)$$

Dann gilt:

$$P[X \leq x] = F(x)$$

Definition

- Der Wert $F^{-1}(p)$ (für $p \in (0, 1)$) heisst das p -Quantil der Verteilung F

- $F^{-1}(0.5)$ heisst der Median der Verteilung F .

3 Gemeinsame Verteilung mehrerer ZV

Seien X_1, \dots, X_n Zufallsvariablen.

Dann ist $F(x_1, \dots, x_n) = P[X_1 \leq x_1, \dots, X_n \leq x_n]$

3.1 Stetige ZV

Falls wir $F(x_1, \dots, x_n)$ folgendermaßen darstellen können $F(x_1, \dots, x_n) = \int_{-\infty}^{x_1} \dots \int_{-\infty}^{x_n} f(y_1, \dots, y_n) dy_n \dots dy_1$ dann heisst $f(x_1 \dots x_n)$ die Dichte von $(X_1 \dots X_n)$

Eigenschaften

- $P[(X_1 \dots X_n) \in A] = \iint_A f(\vec{x}) d\vec{x} = \int \dots \int_{(x_1 \dots x_n) \in A} f(x_1, \dots, x_n) dx_1 \dots dx_n$
- $\int_{-\infty}^{\infty} \dots \int_{-\infty}^{\infty} f(x_1, \dots, x_n) dx_n \dots dx_1 = 1$
- $f(x_1, \dots, x_n) = \frac{\partial^n}{\partial x_1 \dots \partial x_n} F(x_1 \dots x_n)$

3.2 Randverteilungen

Gegeben sei die gemeinsame Verteilung von X und Y: $F(x, y)$. Die Randverteilung von X ist: $F_X(x) = P[X \leq x] = P[X \leq x; Y \in (-\infty, \infty)] = \lim_{y \rightarrow \infty} F(x, y)$

Diskrete ZV: $Y \in \{y_1, y_2, \dots\}$
Die W'keitsfkt. der Randverteilung von X ist $p_X(x) = \sum_j p(x, y_j)$

Stetige ZV: Die Dichte der RV von X ist $f_X(x) = \frac{d}{dx} F_X(x) = \frac{d}{dx} \int_{-\infty}^x [\int_{-\infty}^{\infty} f(x', y') dy'] dx' = \int_{-\infty}^{\infty} f(x, y') dy'$

Beispiel
 $f(x, y) = \begin{cases} 6(x-y) & \text{für } 0 \leq y \leq x \leq 1 \\ 0 & \text{sonst} \end{cases}$
 $f_X(x) = \int_0^x f(x, y) dy$
 $f_Y(y) = \int_y^1 f(x, y) dx$

3.3 Unabhängigkeit von ZV

Die ZV X_1, \dots, X_n sind unabhängig, falls $F(x_1, \dots, x_n) = F_{X_1}(x_1) \cdot F_{X_2}(x_2) \cdot \dots \cdot F_{X_n}(x_n)$ für alle $(x_1 \dots x_n) \in \mathbb{R}^n$

1. Diskreter Fall: $(X_1 \dots X_n)$ unabh. $\Leftrightarrow p(x_1 \dots x_n) = P_{X_1} \cdot \dots \cdot P_{X_n}(x_n)$
2. Stetiger Fall: $f(x_1 \dots x_n) = f_{X_1}(x_1) \cdot \dots \cdot f_{X_n}(x_n)$

X, Y unabhängig ($F(x, y) = F_X(x) \cdot F_Y(y)$) $\Leftrightarrow f(x, y) = f_X(x) \cdot f_Y(y)$

Wichtige Mehrdimensionale Verteilungen

1. die mehrdimensionale Normalverteilung (stetige Verteilung)

Dichte: $f(x, y) = \frac{1}{2\pi\sigma_X\sigma_Y\sqrt{1-\rho^2}} \cdot \exp\left\{-\frac{1}{2(1-\rho^2)\left[\left(\frac{x-\mu_X}{\sigma_X}\right)^2 + \left(\frac{y-\mu_Y}{\sigma_Y}\right)^2 - \frac{2\rho(x-\mu_X)(y-\mu_Y)}{\sigma_X\sigma_Y}\right]}\right\}$
 $-1 < \rho < +1$ Korrelation zw. X und Y.

Randverteilung $f_X(x) = \frac{1}{\sigma_X\sqrt{2\pi}} \exp\left(-\frac{1}{2}\left(\frac{x-\mu_X}{\sigma_X}\right)^2\right)$
Unabhängigkeit von X und Y, genau dann, wenn $\rho = 0$

2. Die Multinomiale Verteilung (diskret)
Es werden n unabhängige Experimente durchgeführt. Es gibt jeweils r mögliche Ergebnisse mit W'keit p_1, \dots, p_r . $\sum_{i=1}^r p_i = 1$.

Sei N_i die Anzahl der Ergebnisse "i". Die Vtlg. von $[N_1, \dots, N_r]$ heisst Multinomialvltg.

$p(N_1 = n_1, \dots, N_r = n_r) = \binom{n}{n_1 \dots n_r} p_1^{n_1} \dots p_r^{n_r}$
 $\binom{n}{n_1 \dots n_r} = \frac{n!}{n_1! \dots n_r!}$: Multinomialkoeffizient
RV von N_i :

$p_{N_i}(n_i) = P[N_i = n_i] = \binom{n}{n_i} p_i^{n_i} (1 - p_i)^{n - n_i}$
 $p(n_1 \dots n_r) \neq \prod_{i=1}^r p_{N_i}(n_i) \Leftrightarrow$ keine Unabh.

3. Mehrdim. Verteilungen mit U(0,1)-RV
 $F(x, y) = \exp(-[(-\ln x)^\beta + (-\ln y)^\beta]^{\frac{1}{\beta}})$
 $x, y \in]0, 1], \beta \geq 1$
RV: $F_X(x) = F(x, y = 1) = x$: U(0,1)-Vrtlg. (Y genauso)

3.4 Bedingte Verteilungen

Diskrete ZV

X, Y ZV diskret mit gemeinsamer W'keitsfkt. $p(x, y)$
Def. Die bedingte W'keitsfkt. von X unter der Bedingung, dass $Y=y$ ist, ist $p_{X|Y}(x|y) = P[X = x|Y = y] = P[X = x, Y = y]/P[Y = y]$

Bem:

- $\sum_i p_{X|Y}(x_i, y) = \frac{\sum_i p(x_i, y)}{p_Y(y)} = 1$
- Wenn $p_{X|Y}(x|y) = p_X(x)$ für alle x, y, dann sind X und Y unabh.

Stetige ZV

Seien X, Y stetige ZV mit gem. Dichte $f(x, y)$
Def. Die bedingte Dichte von Y, gegeben $X=x$, ist $f_{Y|X}(y|x) = \frac{f(x, y)}{f_X(x)}$, wenn $0 < f_X(x) < \infty$ sonst $f_{Y|X}(y|x) = 0$

Bem:

- $\int_{-\infty}^{\infty} f_{Y|X}(y|x)dy = 1$
- $f_{Y|X}(y|x) = f_Y(y)$ für alle $x,y \Leftrightarrow X$ und Y sind unabh.

3.5 Funktionen von ZV

X,Y ZV mit bekannter gem. Vtlg.

Was ist die Vtlg. der Summe X+Y?

1. Diskreter Fall
 $Z = X + Y$
 $p_Z(z) = \sum_i p(x_i, z - x_i)$
 Falls X,Y unabhängig:
 $p_Z(z) = \sum_i p_X(x_i)p_Y(z - x_i)$ (Faltung von X,Y)
2. stetiger Fall
 X,Y Dichtefkt. $f(x,y)$ sind gegeben. $Z=X+Y$
 $f_Z(z) = \int_{-\infty}^{+\infty} f(x, z - x)dx$
 Falls X,Y unabhängig:
 $f_Z(z) = \int_{-\infty}^{+\infty} f_X(x)f_Y(z - x)dx$

4 Erwartungswert

4.1 Definition und Eigenschaften

Diskrete ZV

X sei diskrete ZV mit W'keitsfunktion $p(x)$. Dann ist der EW von X def. durch $E[X] = \sum_i x_i p(x_i)$ falls die Reihe absolut konvergiert.

1. Bernoulli Verteilung ($X \sim Be(p)$)
 $E[X] = 1 \cdot p + 0 \cdot (1 - p) = p$
2. Geometrische Verteilung ($X \sim Nb(1, p)$)
 $E[X] = \frac{1}{p}$
3. Poisson Verteilung ($X \sim P_\lambda(x)$)
 $E[X] = \lambda \sum_{k=1}^{\infty} \frac{e^{-\lambda} \lambda^k}{k!}$

Stetige ZV

X sei stetig verteilt mit Dichtefkt. f_X . Dann ist $E[X] = \int_{-\infty}^{+\infty} x f_X(x)dx$, falls das Integral absolut konvergiert.

1. Uniforme Verteilung ($X \sim U(0, 1)$)
 $E[X] = \int_0^1 x dx = [\frac{1}{2}x^2]_0^1 = \frac{1}{2}$
2. Normale Verteilung ($X \sim N(\mu, \sigma^2)$)
 $E[X] = \mu$
3. Cauchy Verteilung
 $f(x) = \frac{1}{\pi} \frac{1}{1+x^2}, -\infty < x < +\infty$
 $E[X] = +\infty$

4.2 Funktionen von ZV

Satz

Sei $Y = g(X)$. Falls X diskret mit W'keitsfkt. $p(x)$ ist, dann ist $E[g(X)] = \sum_i g(x_i)p_x(x_i)$, falls die Summe absolut konvergiert.

Falls X stetig verteilt ist mit Dichtefkt. f , dann ist $E[g(X)] = \int_{-\infty}^{+\infty} g(x)f(x)dx$ falls das Integral konvergiert.

Satz

Seien X_1, \dots, X_n, Y ZV mit $Y = g(X_1, \dots, X_n)$. Falls X_1, \dots, X_n diskret sind mit $p(x_1, \dots, x_n)$, dann $E[Y] = \sum_{X_1} \dots \sum_{X_n} g(x_1, \dots, x_n)p(x_1, \dots, x_n)$ stetiger Fall:

$$E[Y] = \int_{-\infty}^{+\infty} g(x_1, \dots, x_n)f(x_1, \dots, x_n)dx_1 \dots dx_n$$

falls das Integral absolut konvergiert.

Korollar zum Satz

Seien X,Y unabh. ZV
 Dann $E[g(X)h(Y)] = E[g(X)]E[h(Y)]$

4.3 Linearkombinationen von ZV

Satz

Der E'wert ist ein linearer Operator, d.h. X_1, \dots, X_n seien ZV mit E'werten $E[X_1], \dots, E[X_n]$. Sei $Y = a_i + \sum_{i=1}^n b_i X_i$. Dann ist $E[Y] = a_i + \sum_{i=1}^n b_i E[X_i]$.

4.4 Varianz und Standardabweichung

Definition

X sei eine ZV mit E'wert $E[X]$. Dann heisst $var(X) = E[(X - E[X])^2]$ die Varianz von X (falls $var(X) < +\infty$). Es gilt aber auch $var(X) = E[X^2] - (E[X])^2$, was meist einfacher zu berechnen ist. Es gilt: $var(X) > 0!$

$\sigma(X) = \sqrt{var(X)}$ heisst Standardabweichung.

X diskret:

$$var(X) = \sum_i (x_i - \mu)^2 p(x_i), \mu = E[X]$$

X stetig:

$$var(X) = \int_{-\infty}^{+\infty} (x - \mu)^2 f(x)dx, \mu = E[X]$$

$$E[X^2] = E[X]^2 + var(X)$$

Satz

Sei X eine ZV mit $var(X) < +\infty$, $a, b \in \mathbb{R}$. Dann ist $var(a + bX) = b^2 var(X)$

1. Bernoulli-Verteilung $X \sim Be(p)$

$$E[X] = p$$

$$\text{var}(X) = p(1-p)$$

2. Binomial Verteilung $X \sim B(n, p)$

$$E[X] = np$$

$$\text{var}(X) = np(1-p)$$

3. Normalverteilung $X \sim N(\mu, \sigma)$

$$E[X] = \mu$$

$$\text{var}(x) = \sigma^2$$

4. Uniforme Verteilung $U \sim U(0, 1)$

$$E[X] = \frac{1}{2}$$

$$\text{var}(U) = \frac{1}{12}$$

5. $X \sim \text{Poisson}(\mu)$

$$E[X] = \mu$$

$$\text{var}(X) = \mu$$

6. Geometrische Verteilung

$$E[X] = \frac{1}{p}$$

$$\text{var}(X) = \frac{1-p}{p^2}$$

7. Exponential Verteilung

$$E[X] = \frac{1}{\lambda}$$

$$\text{var}(X) = \frac{1}{\lambda^2}$$

Gamma Funktion

$$\alpha > 0 \quad \Gamma(\alpha) = \int_0^{\infty} u^{\alpha-1} e^{-u} du$$

$$\alpha \in \mathbb{R}^+ : \Gamma(\alpha) = (\alpha-1)!$$

$$\alpha > 0 : \Gamma(\alpha) = (\alpha-1)\Gamma(\alpha-1)$$

$$\Gamma\left(\frac{1}{2}\right) = \sqrt{\pi}, \quad \Gamma\left(\frac{3}{2}\right) = \frac{1}{2}\sqrt{\pi}$$

4.5 Kovarianz und Korrelation

$$\mu_X = E[X], \quad \mu_Y = E[Y]$$

$$\text{cov}(X, Y) = E[(x - \mu_X)(Y - \mu_Y)]$$

$$\text{cov}(X, Y) = E[XY] - \mu_X \mu_Y$$

$$E[XY] = \iint xyf(x, y) dx dy \text{ falls gem. Dichtefkt.}$$

$$E[XY] = E[X] \cdot E[Y] \text{ falls unabh.}$$

Rechenregeln

1. X, Y unabh. $\Rightarrow \text{cov}(X, Y) = 0$

Die Umkehrung gilt aber nicht.

2. $\text{cov}(X, X) = \text{var}(X)$

3. $\text{cov}(aX, Y) = a \cdot \text{cov}(X, Y)$

4. $\text{cov}(X + Y, Z) = \text{cov}(X, Z) + \text{cov}(Y, Z)$

5. $\text{cov}(X + Y, Z + W) = \text{cov}(X, Z) + \text{cov}(X, W) + \text{cov}(Y, Z) + \text{cov}(Y, W)$

6. $\text{cov}(X, a) = 0$ für $a \in \mathbb{R}$

$$7. \text{cov}\left(a + \sum_{i=1}^n b_i X_i, c + \sum_{j=1}^m d_j Y_j\right) = \sum_{i=1}^n \sum_{j=1}^m b_i d_j \text{cov}(X_i, Y_j)$$

$$8. \text{var}\left(a + \sum_{i=1}^n b_i X_i\right) = \sum_{i=1}^n \sum_{j=1}^n b_i b_j \text{cov}(X_i, X_j)$$

$$9. \text{var}(X + Y) = \text{var}(X) + \text{var}(Y) + 2\text{cov}(X, Y)$$

10. Falls X_1, \dots, X_n unabh.:

$$\text{var}\left(\sum_{i=1}^n X_i\right) = \sum_{i=1}^n \text{var}(X_i)$$

im Gegensatz dazu gilt immer: $E\left[\sum_{i=1}^n x_i\right] =$

$$\sum_{i=1}^n E[X_i]$$

X, Y seien ZV mit endlichen Varianzen. Dann heisst

$$P_{XY} = \rho(X, Y) = \frac{\text{cov}(X, Y)}{\sqrt{\text{var}(X)\text{var}(Y)}}$$

die *Korrelation*.

Eigenschaften

- $\rho(X, Y) \in [-1, 1]$
- falls $\rho(X, Y) = \pm 1$ dann $P[Y = aX + b] = 1$ für $a, b \in \mathbb{R}, b \neq 0$
- $\rho(X, Y) \approx \pm 1 \Rightarrow X$ und Y sind stark linear abhängig
- $\rho(X, Y) \approx 0 \Rightarrow X$ und Y sind schwach linear abhängig

5 Grenzwertsätze

Seien X_1, \dots, X_n unabh. ZV, mit $E[X_i] = \mu$ und $\text{var}(X_i) = \sigma^2 < +\infty$.

Dann gilt:

$$\lim_{n \rightarrow \infty} P(|\bar{X}_n - \mu| \geq \epsilon) = 0 \quad \forall \epsilon > 0$$

5.1 Zentraler Grenzwertsatz

X_1, X_2, \dots Folge identisch verteilter, unabh. ZV mit $E[X_i] = \mu, \text{var}(X_i) = \sigma^2 < \infty$

$$s_n = \sum_{i=1}^n x_i; \text{ Standardisierung: } \frac{s_n - \mu n}{\sqrt{n}\sigma}$$

$$\text{Standardisierung: } U = \frac{X - \mu}{\sigma} \sim N(0, 1)$$

Zentraler Grenzwertsatz

$\lim_{n \rightarrow \infty} P\left(\frac{s_n - \mu n}{\sqrt{n}\sigma} \leq x\right) = \Phi(x)$, Φ ist die Vertfkt. der $N(0, 1)$ -Verteilung. Kann auch so geschrieben werden:

$$\lim_{n \rightarrow \infty} P\left(\frac{\bar{X} - \mu}{\sigma/\sqrt{n}} \leq x\right) \sim N(0, 1)$$

Beispiel Gesucht ist x, so dass $P\left[\sum_{i=1}^{120} I_i > x\right] = 0.95$

Aus dem ZGS folgt:

$$0.05 = 1 - P\left[\sum_{i=1}^{120} I_i > x\right] = P\left[\sum_{i=1}^{120} I_i \leq x\right] =$$

$$P\left[\frac{\sum_{i=1}^{120} I_i - 120E[I]}{\sqrt{120 \text{Var}(I)}} \leq \frac{x - 120E[I]}{\sqrt{120 \text{Var}(I)}}\right] \approx \Phi\left(\frac{x - 120E[I]}{\sqrt{120 \text{Var}(I)}}\right)$$

Monte-Carlo-Integration

$\int_0^1 f(x) dx$ sei numerisch zu berechnen

Generiere unabh. auf $[0, 1]$ gleichverteilte ZV.

U_1, \dots, U_n und berechne $f(\bar{U}) = \frac{1}{n} \sum_{i=1}^n f(u_i)$.

Sei $\text{var}(f(U_i))$ endlich.

Nach dem Gesetz der grossen Zahlen gilt:

$$\lim_{n \rightarrow \infty} \frac{1}{n} \sum_{i=1}^n f(U_i) = E[f(U_i)] = \int_0^1 f(x) dx$$

$E[g(x)] = \int_{-\infty}^{\infty} g(x) \cdot f_x(x) dx$, wobei $f_x(x)$ die Dichte von x ist.

5.2 Normalapproximation der Binomialverteilung

Falls gilt $np(1-p) > 9$ so kann $B(n; p)$ durch $N(\mu = np; \sigma = \sqrt{np(1-p)})$ approximiert werden, sonst falls $np \leq 10$ und $n \geq 1500p$ durch $Poiss(\lambda = np)$.

Beispiel

VB auf α Niveau für Binomialvrtlg.

$$\frac{X - np}{\sqrt{np(1-p)}} \sim N(0, 1)$$

$$\Rightarrow \{X > \Phi^{-1}(1 - \alpha) \cdot \sqrt{n\hat{p}(1 - \hat{p})} + n\hat{p}\}$$

6 Statistik

Definition

Eine *Stichprobe* vom Umfang n ist eine Folge X_1, \dots, X_n von unabh., ident. verteilten ZV. Eine Statistik ist eine ZV $g(X_1, \dots, X_n)$, wobei $g: \mathbb{R}^n \rightarrow \mathbb{R}$

6.1 empirischer Mittelwert und empirische Varianz

Für eine Stichprobe X_1, \dots, X_n , $n \geq 2$

$$\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$$

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

Satz

Falls die X_i EW μ und $\text{var} \sigma^2$ haben, so ist $E[\bar{X}] = \mu$, $\text{var}(\bar{X}) = \frac{\sigma^2}{n}$. \bar{X} ist eine ZV, μ eine Zahl. Man sagt, \bar{X} ist ein Schätzer von μ .

Satz

Falls die X_i $N(\mu, \sigma^2)$ -verteilt sind, so ist $\bar{X} \sim N(\mu, \frac{\sigma^2}{n})$ -verteilt.

Satz

Sei $\text{var}(X_i) = \sigma^2$. Dann $E[S^2] = \sigma^2$. Man sagt, der Schätzer S^2 habe keinen Bias.

6.2 χ^2 Verteilung

Satz

Falls $X \sim N(0, 1)$, dann ist $X^2 \sim \Gamma(\frac{1}{2}, \frac{1}{2})$. Diese Verteilung nennt man χ_1^2 -Verteilung. Lies: chi-Quadrat mit 1 Freiheitsgrad.

Satz

Seien X_1, \dots, X_n unabh. ident. verteilt, $X_i \sim \chi_1^2$. Dann ist $V = X_1 + \dots + X_n$ χ_n^2 -verteilt. χ_n^2 ist eine $\Gamma(\frac{n}{2}, \frac{1}{2})$ -Verteilung. D.h., die Dichte ist

$$f(t) = \frac{1}{\Gamma(\frac{n}{2} 2^{n/2})} t^{\frac{n}{2}-1} e^{-\frac{t}{2}} \quad t \geq 0$$

Falls $V \sim \chi_n^2$, dann $E[V] = n$, $\text{var}(V) = 2n$

Satz

Seien X_1, \dots, X_n eine Stichprobe von $N(\mu, \sigma^2)$ -verteilten ZV. Dann ist $\frac{(n-1)S^2}{\sigma^2} \sim \chi_{n-1}^2$

6.3 t Verteilung

Satz

Sei X_1, \dots, X_n eine Stichprobe aus einer $N(\mu, \sigma^2)$ -Population. Dann ist $t = \frac{\bar{X} - \mu}{S/\sqrt{n}} \sim t_{n-1}$ verteilt. Dichte der t-Verteilung: $f(x) = \frac{\Gamma(\frac{n+1}{2})}{\sqrt{\pi n} \Gamma(\frac{n}{2})} \cdot (1 + \frac{x^2}{n})^{-\frac{n+1}{2}}$.

6.4 F Verteilung

U und V unabh. χ^2 ZV mit m bzw. n Freiheitsgraden, so wird die Verteilung:

$$W = \frac{U/m}{V/n}$$

als F Verteilung mit m und n Freiheitsgraden bezeichnet, geschrieben $F_{m,n}$

7 Konfidenzintervalle ...

7.1 ... für unbekanntes Mittelwert μ einer Normalverteilung bei bekannter Varianz σ^2

Vertrauensniveau $(1 - \alpha)$ wählen (z.B. 0.95)

Eine Stichprobe

1. Verteilung ist gleich $Z = \frac{\bar{X} - \mu}{\sigma/\sqrt{n}} \sim N(0, 1)$

2. Konfidenzintervall

a) *zweiseitig*

$$P[q_{\frac{\alpha}{2}} \leq \frac{\bar{X} - \mu}{\sigma/\sqrt{n}} \leq q_{1-\frac{\alpha}{2}}] = 1 - \alpha$$

$$\Rightarrow [\bar{X} - q_{1-\frac{\alpha}{2}} \cdot \frac{\sigma}{\sqrt{n}} \leq \mu \leq \bar{X} + q_{\frac{\alpha}{2}}]$$

b) nach oben

$$P\left[\frac{\bar{X}-\mu}{\sigma/\sqrt{n}} \leq q_{1-\alpha}\right] = 1 - \alpha$$

c) nach unten

$$P[q_\alpha \leq \frac{\bar{X}-\mu}{\sigma/\sqrt{n}}] = 1 - \alpha$$

Zwei Stichproben (Differenz der Mittelwerte)

gleich wie eine Stichprobe, aber mit folgender Verteilung:

$$\frac{(\bar{X} - \bar{Y}) - (\mu_X - \mu_Y)}{\sqrt{\frac{\sigma_X^2}{m} + \frac{\sigma_Y^2}{n}}} \sim N(0, 1)$$

7.2 ... für unbekanntem Mittelwert μ einer Normalverteilung bei unbekannter Varianz σ^2

Vertrauensniveau $(1 - \alpha)$ wählen (z.B. 0.95)

Eine Stichprobe

1. Verteilung ist gleich $T = \frac{\bar{X}-\mu}{S/\sqrt{n}} \sim t_{n-1}$

2. Konfidenzintervall

a) zweiseitig

$$P[t_{n-1, \frac{\alpha}{2}} \leq T \leq t_{n-1, 1-\frac{\alpha}{2}}] = 1 - \alpha \\ \Rightarrow [\bar{X}_n - t_{n-1, 1-\frac{\alpha}{2}} \cdot \frac{S}{\sqrt{n}} \leq \mu \leq \bar{X}_n + t_{n-1, 1-\frac{\alpha}{2}} \cdot \frac{S}{\sqrt{n}}]$$

b) nach oben

$$P[T \leq t_{n-1, 1-\alpha}] = 1 - \alpha$$

c) nach unten

$$P[t_{n-1, \alpha} \leq T] = 1 - \alpha$$

Zwei Stichproben (Differenz der Mittelwerte)

gleich wie eine Stichprobe, aber mit folgender Verteilung:

$$\frac{(\bar{X} - \bar{Y}) - (\mu_X - \mu_Y)}{S_P \sqrt{\frac{1}{m} + \frac{1}{n}}} \sim t_{m+n-2}$$

wobei S_P :

$$S_P^2 = \frac{(m-1)S_X^2 + (n-1)S_Y^2}{m+n-2}$$

die gepoolte Varianz ist

falls $m=n$ und Stichproben nicht unbedingt unabh.:

$$D_i = X_i - Y_i \\ \frac{\bar{D} - (\mu_X - \mu_Y)}{S_D/\sqrt{n}} \sim t_{n-1}$$

7.3 ... für unbekanntem Varianz σ^2 einer Normalverteilung

Vertrauensniveau $(1 - \alpha)$ wählen (z.B. 0.95)

Eine Stichprobe

$$\frac{S^2}{\sigma^2} (n-1) \sim \chi_{n-1}^2$$

Zwei Stichproben

$$\frac{S_X^2/\sigma_X^2}{S_Y^2/\sigma_Y^2} \sim F_{(m-1, n-1)}$$

Wobei m (n) Anz. Experimente für ZV X (Y).

7.4 ... für unbekanntem Parameter p einer Binomialverteilung

1. Verteilung ist gleich $Z = \frac{n\hat{p}-np}{\sqrt{n\hat{p}(1-\hat{p})}} \sim N(0, 1)$,

wobei $\hat{p} = \frac{k}{n}$ k = Anz. Erfolge bei n Versuchen.

2. Konfidenzintervall $[\hat{p} - \frac{q_{1-\frac{\alpha}{2}}}{n} \sqrt{n\hat{p}(1-\hat{p})} \leq p \leq \hat{p} + \frac{q_{\frac{\alpha}{2}}}{n} \sqrt{n\hat{p}(1-\hat{p})}]$

8 Schätztheorie

Ein Schätzer ist *erwartungstreu*, falls $E[\hat{\theta}] = \theta$.

8.1 Maximum Likelihood

Sei X_1, \dots, X_n eine Stichprobe des Umfangs n einer Dichte $f(x, \theta)$, dann ist die gemeinsame Dichte von (X_1, \dots, X_n) die Likelihood-Funktion.

• X diskret:

$$L(\Theta) = \prod_{i=1}^n P(X_i = x_i)$$

• X stetig:

$$L(\Theta) = \prod_{i=1}^n f(x_i)$$

Wähle Θ so dass die Realisierungen X_1, \dots, X_n am wahrscheinlichsten sind. Um die Berechnung zu vereinfachen: logarithmiere, so ergibt sich aus dem Produkt eine Summe. $l(\Theta) = \log L(\Theta)$. Differenziere danach und setze gleich 0. $\frac{\partial}{\partial \Theta} l(\Theta) \stackrel{!}{=} 0$. Löse danach nach $\Theta \Rightarrow \hat{\Theta}_{ML}$

8.2 Momentenmethode

Berechne für $X \sim F(\Theta)$:

• $E[X]$ hängt von Θ ab (da $f(x)$ oder $P(X = x_i)$ von Θ abhängen).

$$E[X] = \int_{-\infty}^{\infty} x f(x) dx \text{ oder } E[X] = \sum_{i=1}^n x_i P(X = x_i)$$

• $\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$

Danach setze $E[X] = \bar{X}$ und löse nach $\Theta \Rightarrow \hat{\Theta}_{MM}$

p -tes Moment: Setze auch noch $E[X^2] = \bar{X}^2 \dots E[X^p] = \bar{X}^p \Rightarrow p$ -Gleichungen, löse nach Θ

9 Testen von Hypothesen

9.1 Neyman-Pearson Paradigma

Nullhypothese H_0 :

Die zu zeigende Aussage, meist also $\mu = \mu_0$

Alternative H_A :

Was gilt, falls H_A nicht gilt:

$\mu \neq \mu_0, \mu > \mu_0, \mu < \mu_0$

Fehler 1. Art (α):

Verwerfung von H_0 , obwohl H_0 richtig.
 $\alpha = P(\text{Fehler 1. Art})$

Fehler 2. Art (β):

Keine Ablehnung von H_0 , obwohl H_0 falsch.
 $\beta = P(\text{Fehler 2. Art})$

Macht $\text{Macht} = 1 - \beta$. W'keit, dass H_0 verworfen wird, wenn es tatsächlich falsch ist.

Man versucht α möglichst klein, und $1 - \beta$ möglichst gross zu wählen. Dazu wird α fixiert. Danach konstruiert man dazu einen Test mit möglichst grosser Macht.

Beispiel Macht, wenn μ_X, σ_X gleich wirklicher Mittelwert bzw. Varianz und G die zuvor ausgerechnete Grenze des VB's ist:

$$\text{Macht} = 1 - P(\text{Fehler 2. Art}) = 1 - P(X \leq G) = 1 - P\left(\frac{X - \mu_x}{\sigma_x} \leq \frac{G - \mu_x}{\sigma_x}\right) = 1 - \Phi\left(\frac{G - \mu_x}{\sigma_x}\right)$$

9.2 Neyman-Pearson Lemma

$$\text{Likelihood ratio} = \frac{f_0(x)}{f_A(x)}$$

$$\rho_L = \begin{cases} 1 & \text{wenn } \frac{f_0(x)}{f_A(x)} < K_\alpha \\ 0 & \text{wenn } \frac{f_0(x)}{f_A(x)} > K_\alpha \end{cases}$$

K_α muss so gewählt sein, dass $E_0[\rho_L] = \alpha$

Der Likelihood-Test ρ_L ist der mächtigste Test unter den Tests ρ^* mit Signifikanzlevel $\alpha^* \leq \alpha$

9.3 Der t-Test

Mittelwert bei unbekanntem σ

Modellannahmen:

- $X_i \sim N(\mu, \sigma)$
- X_i unabhängig
- μ, σ unbekannt

Wir wollen testen, ob $\mu = \mu_0$ oder Alternative.

Für den t-Test gilt:

$$T = \sqrt{n} \frac{\bar{X} - \mu_0}{S}$$

Unter $H_0: T \sim t_{n-1}$

Verwerfungsbereich:

- $H_A: \mu \neq \mu_0$
 $VB = \{|T| \geq t_{n-1, 1-\frac{\alpha}{2}}\}$
- $H_A: \mu > \mu_0$
 $VB = \{T > t_{n-1, 1-\alpha}\}$
- $H_A: \mu < \mu_0$
 $VB = \{T < t_{n-1, \alpha}\}$

Falls T bzw. $|T|$ in VB $\Rightarrow H_0$ verwerfen, sonst H_0 beibehalten.

2-Stichproben t-Test

$$T = \frac{(\bar{X} - \bar{Y}) - (\mu_X - \mu_Y)}{S_P \sqrt{\frac{1}{m} + \frac{1}{n}}} \sim t_{m+n-2} \quad \text{Wobei}$$

$$S_P^2 = \frac{(m-1)S_X^2 + (n-1)S_Y^2}{m+n-2} \quad \text{die gepoolte Varianz ist.}$$

9.4 Der z-Test

Mittelwert bei bekanntem σ

Modellannahmen:

- $X_i \sim N(\mu, \sigma)$
- X_i unabhängig
- μ unbekannt, σ bekannt

Wir wollen testen, ob $\mu = \mu_0$ oder Alternative.

Verteilung:

$$\frac{\bar{X} - \mu}{\sigma/\sqrt{n}} \sim N(0, 1)$$

Verwerfungsbereich:

- $H_A: \mu \neq \mu_0$
 $VB = \{|\frac{\bar{X} - \mu_0}{\sigma/\sqrt{n}}| > q_{1-\frac{\alpha}{2}}\}$
- $H_A: \mu > \mu_0$
 $VB = \{\frac{\bar{X} - \mu_0}{\sigma/\sqrt{n}} > q_{1-\alpha}\}$
- $H_A: \mu < \mu_0$
 $VB = \{\frac{\bar{X} - \mu_0}{\sigma/\sqrt{n}} < q_\alpha\}$

9.5 Likelihood-Ratio Tests für Multinomialverteilungen

m Zellen, n Beobachtungen \Rightarrow Histogramm

$-2 \ln \Lambda = 2 \sum_{i=1}^m x_i \ln(\frac{x_i}{E_i})$ ist χ^2 -verteilt mit $m - 1 - k$ Freiheitsgraden, wobei k die Anz. freier Parameter in H_0 ist.

χ^2 Anpassungstest

- Modellannahme: $X \sim F$, F irgend eine Verteilungsfkt.
- Nullhypothese $H_0 : F = Pois(\lambda)$
- Alternative $H_A : F \neq Pois(\lambda)$
- Die Teststatistik ist gegeben durch die χ^2 Teststatistik: man bildet die quadrierten Differenzen zwischen den beobachteten Häufigkeiten ($Beob_i$) und den erwarteten Häufigkeiten (Erw_i), man teilt durch die erwarteten Häufigkeiten (Erw_i) und summiert über alle möglichen Klassen.

$n =$ Anz. Klassen

$$\chi^2 = \sum_{i=0}^n \frac{(Beob_i - Erw_i)^2}{Erw_i}$$

Unter H_0 ist die Teststatistik χ^2 -verteilt mit f Freiheitsgraden, wobei

$f =$ Anz. Klassen - 1 - Anzahl geschätzter Parameter

- Entscheidung:
VB = $\{\chi^2 > \chi_{f,p}^2\}$

Vorzeichen Test

Modellannahme: D_i unabhängig mit Median \tilde{m}

Nullhypothese: $\tilde{m} = 0$

Alternative: $\tilde{m} \neq 0$

Teststatistik: $T = \sum_{i=1}^n 1_{\{D_i > 0\}}$

Unter H_0 : $T \sim Bin(n, p)$

Beispiel für $T = 7$ und $n = 10$

$$2P[T \geq 7] = 2 \sum_{i=7}^{10} P[T = i] = 0.34$$

Da $0.34 > 0.05$ wird H_0 beibehalten auf 5% Test

10 Methode der kleinsten Quadrate und lineare Regression

Beobachtungen:

$\{(x_i, y_i) \mid i = 1 \dots n\}$

y = die abhängige Variable, "zu erklärende Variable"

x = die unabhängige Variable, "erklärende Variable"

Ansatz:

Der Zusammenhang zw. x und y ist linear, d.h.

$$y = \beta_0 + \beta_1 x$$

Abweichung (Residuum) des i -ten Punktes:

$$e_i = y_i - (\beta_0 + \beta_1 x_i)$$

Ergebnis:

$$\hat{\beta}_0 = \frac{(\sum_{i=1}^n x_i^2)(\sum_{i=1}^n y_i) - (\sum_{i=1}^n x_i)(\sum_{i=1}^n x_i y_i)}{n \sum_{i=1}^n x_i^2 - (\sum_{i=1}^n x_i)^2}$$

$$\hat{\beta}_1 = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sum_{i=1}^n (x_i - \bar{x})^2}$$

10.1 Statistisches Modell

$$y_i = \beta_0 + \beta_1 x_i + e_i$$

e_i : Beobachtungsfehler

Voraussetzungen:

1. e_i sind unabhängig
2. $E[e_i] = 0$
3. $var(e_i) = \sigma^2$
4. x_i sind fest

Varianz

$$var(\hat{\beta}_0) = \frac{\sigma^2 \sum_{i=1}^n x_i^2}{n \sum_{i=1}^n x_i^2 - (\sum_{i=1}^n x_i)^2}$$

$$var(\hat{\beta}_1) = \frac{n \sigma^2}{n \sum_{i=1}^n x_i^2 - (\sum_{i=1}^n x_i)^2} = \frac{\sigma^2}{\sum_{i=1}^n (x_i - \bar{x})^2}$$

Korrelation

$$cov(\hat{\beta}_0, \hat{\beta}_1) = \frac{-\sigma^2 \sum_{i=1}^n x_i}{n \sum_{i=1}^n x_i^2 - (\sum_{i=1}^n x_i)^2}$$

Bemerkungen

- $\hat{e}_i := y_i - \hat{\beta}_0 - \hat{\beta}_1 x_i$
- $S^2 = \frac{\sum_{i=1}^n (\hat{e}_i)^2}{n-2}$ ist bias-freier Schätzer für σ^2
- Setze S^2 ein in Formel für $var(\hat{\beta}_0)$ bzw. $var(\hat{\beta}_1)$ und erhalte: $s_{\hat{\beta}_0}^2$ bzw. $s_{\hat{\beta}_1}^2$.
- Wenn e_i normalverteilt sind, dann sind $\hat{\beta}_0, \hat{\beta}_1$ auch normalverteilt, und $\frac{\hat{\beta}_0 - \beta_0}{s_{\hat{\beta}_0}}$ und $\frac{\hat{\beta}_1 - \beta_1}{s_{\hat{\beta}_1}}$ sind t -verteilt mit $n-2$ Freiheitsgraden.

Korrelation und Regression

$$S_{XX} = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2 \text{ "Varianz von X"}$$

$$S_{YY} = \frac{1}{n} \sum_{i=1}^n (y_i - \bar{y})^2 \text{ "Varianz von Y"}$$

$$S_{XY} = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y}) \text{ "Kovarianz von X und Y"}$$

Der Korrelationskoeffizient von X und Y ist:

$$r = \frac{S_{XY}}{\sqrt{S_{XX} S_{YY}}}$$