

Statistische Methoden

Marianne Müller

25. September 2003

Inhaltsverzeichnis

1. Deskriptive Statistik	5
2. Zufallsvariablen	7
2.1. Zusammenhang: Wirklichkeit–Modell	7
2.2. Diskrete Zufallsvariablen	7
2.3. Stetige Zufallsvariablen	9
2.4. Erwartungswert und Varianz	12
2.5. Kovarianz und Korrelation	14
2.6. Anwendungsbereiche von verschiedenen Wahrscheinlichkeitsmodellen	14
3. Schätzungen	15
3.1. Grenzwertsätze	15
3.2. Vertrauensintervalle	15
4. Statistische Tests	19
4.1. Begriffe und Vorgehensweise	19
4.2. Tests für Lageparameter	20
4.3. Welcher Test soll benutzt werden?	21
4.4. Dualität zwischen Tests und Vertrauensintervallen	22
5. Zusammenhang zwischen zwei kategoriellen Variablen	23
5.1. 2×2 -Kreuztabelle, Kontingenztafel	23
5.2. Chiquadrat-Test auf Unabhängigkeit	23
5.3. $r \times s$ -Kontingenztafeln	24
5.4. Bemerkungen zum Chiquadrat–Test	25
5.5. McNemar’s Test für gepaarte Daten	25
5.6. Chiquadrat–Anpassungstest	25
6. Einfache lineare Regression	27
6.1. Das Modell	27
6.2. Methode der Kleinsten Quadrate	27
6.3. Tests und Vertrauensintervalle	28
6.4. Varianzanalyse	28
6.5. Residuenanalyse	29
7. Multiple lineare Regression	31
7.1. Das Modell	31
7.2. Tests und Vertrauensintervalle	32
7.3. Modelldiagnostik	35
7.4. Modellwahl	36
8. Versuchsplanung	39

9. Varianzanalyse	41
9.1. Ein-Weg-Varianzanalyse	41
9.2. Vollständiges Blockdesign	43
9.3. Multi-Faktor-Experimente	43
A. Matrizen und Vektoren	45
A.1. Definition	45
A.2. Rechnen mit Matrizen	45
A.3. Lineare Unabhängigkeit und inverse Matrizen	46
A.4. Zufallsvektoren und Kovarianzmatrizen	46

1. Deskriptive Statistik

Die deskriptive Statistik (beschreibende Statistik, explorative Datenanalyse) versucht, das Wesentliche eines Zahlenhaufens zu beschreiben, um die Daten zu verstehen oder präsentieren zu können. Daten bestehen aus Messungen oder Beobachtungen an mehreren Versuchseinheiten, z. B. Personen oder Tiere. Die Grössen oder Merkmale, die erfasst werden, heissen Variablen (sie variieren zwischen den Versuchseinheiten).

Zu allererst interessiert die Verteilung einer Variablen: welche Werte werden wie oft angenommen. Dazu macht man eine Häufigkeitstabelle und stellt diese graphisch dar mit einem Kuchen- oder Balkendiagramm, bzw. mit einem Histogramm. Andere Darstellungsmöglichkeiten sind Stem-and-Leaf-Plot und Boxplot. Die Form der Verteilung sollte in diesen Graphiken erkennbar werden: symmetrisch, links- oder rechtsschief, bimodal.

Um die mittlere Lage und die Streuung einer Variablen zu beschreiben, werden statistische Kennzahlen berechnet, wie z. B. arithmetisches Mittel, Median, Quartilsdifferenz und Standardabweichung. Kennzahlen werden auch Statistiken genannt.

- **Lagemasse:**

- arithmet. Mittel $\bar{x} = \frac{x_1 + x_2 + \dots + x_n}{n} = \frac{1}{n} \sum_{i=1}^n x_i$
- Median : 50% aller Beobachtungen sind kleiner gleich diesem Wert.
- Modus: der häufigste Wert.
- Quartile, Perzentile: Das 1. Quartil Q_1 teilt die Daten im Verhältnis 25 : 75. Das 2. Quartil ist der Median und das 3. Quartil Q_3 wird so bestimmt, dass 75% aller Werte kleiner und 25% grösser als Q_3 sind. Das k. Perzentil unterteilt die Daten im Verhältnis k zu 100-k.

- **Streuungsmaße:**

- Spannweite = Maximum – Minimum
- Varianz, Standardabweichung:

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



- Quartilsdifferenz: $IQR = Q_3 - Q_1$

Bei symmetrisch verteilten Daten hat die Standardabweichung zusammen mit \bar{x} eine spezielle Bedeutung:


Etwa 95% aller Einzelmessungen liegen innerhalb von $\pm 2 \cdot s$ um \bar{x} herum; 2,5% der Werte sind kleiner als $\bar{x} - 2 \cdot s$ und 2,5% der Werte sind grösser als $\bar{x} + 2 \cdot s$.

Welche numerische oder graphische Beschreibung den Daten angemessen ist, hängt vor allem vom Typ der Daten ab: Nominal- oder Ordinaldaten, bzw. diskrete oder stetige Daten.

Fischgattungen: Pie- und Barchart



Histogramm




```
> stem(fish$length3)
```

N = 159 Median = 29.4 Quartiles = 23.1, 39.7

Decimal point is 1 place to the right of the colon

```
0 : 9
1 : 122223333334
1 : 55666677899
2 : 000111122222333333333333344444444
2 : 555555666677778889999999999
3 : 001111234444
3 : 5555666667777888999999999
4 : 0000011111111222223344
4 : 555556666789
5 : 1
5 : 5
6 : 044
6 : 8
```

Definition des Boxplots



2. Zufallsvariablen

2.1. Zusammenhang: Wirklichkeit–Modell

Wirklichkeit	Modell
Stichprobe	Population
Daten	Zufallsvariable
diskret	diskret
stetig	stetig
rel. Häufigkeit	Wahrscheinlichkeit
Häufigkeitstabelle	Wahrscheinlichkeitsverteilung
Stabdiagramm	Stabdiagramm
Histogramm	Dichte
empir. Verteilungsfunktion	Verteilungsfunktion
empir. Kennzahlen	theoret. Kennzahlen
Mittelwert \bar{x}	Erwartungswert $E(X)$
Varianz s^2	Varianz $Var(X)$

Eine *Zufallsvariable* (random variable) ist eine quantitative Variable, deren Wert durch das zufällige Ergebnis von Experimenten oder Beobachtungen bestimmt wird. Zufallsvariablen bilden ein Modell für die beobachteten Grössen, die Daten.

Es gibt *diskrete* (discrete) und *stetige* (continuous) Zufallsvariablen. Diskrete Zufallsvariablen haben nur eine endliche oder abzählbare Anzahl möglicher Werte, stetige Zufallsvariablen können alle Werte innerhalb eines Intervalls der reellen Zahlen annehmen.

2.2. Diskrete Zufallsvariablen

Die *Wahrscheinlichkeitsverteilung* p (probability function) ist definiert durch:

$$\begin{array}{c|cccc} X & x_1 & x_2 & \dots & x_k \\ \hline p & p(x_1) & p(x_2) & \dots & p(x_k) \end{array} \quad p(x_i) := P(X = x_i), \quad \sum p(x_i) = 1.$$

Die *kumulative Verteilungsfunktion* F (cumulative distribution function) ist definiert durch:

$$F(x) = P(X \leq x), \quad -\infty < x < \infty.$$

F ist monoton wachsend, $\lim_{x \rightarrow -\infty} F(x) = 0$ und $\lim_{x \rightarrow \infty} F(x) = 1$.

Uniforme Verteilung

Eine Verteilung, bei der alle Werte die gleiche Wahrscheinlichkeit haben, heisst *uniform*.

$$\begin{array}{c|cccc} X & x_1 & x_2 & \dots & x_n \\ \hline p & 1/n & 1/n & \dots & 1/n \end{array}.$$




Abbildung 2.1.: Binomialverteilungen

Bernoulli Verteilung

Ein Experiment habe zwei mögliche Ausgänge, „Erfolg“ und „Misserfolg“, mit den Wahrscheinlichkeiten p und $1 - p$.

$$X = \begin{cases} 0 & : \text{„Misserfolg“} \\ 1 & : \text{„Erfolg“} \end{cases}$$

X	0	1
p(x)	1-p	p

Binomialverteilung

Es werden n voneinander unabhängige Versuche gemacht. Jeder einzelne Versuch hat zwei mögliche Ausgänge, „Erfolg“ und „Misserfolg“. Die Wahrscheinlichkeit p für einen Erfolg ist konstant. Die Anzahl Erfolge X hat dann eine Binomialverteilung $\mathcal{B}(n, p)$ und die Wahrscheinlichkeit für k Erfolge ist gegeben durch:

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

Geometrische Verteilung

Es werden unabhängige Versuche durchgeführt. Jeder einzelne Versuch hat zwei mögliche Ausgänge, „Erfolg“ und „Misserfolg“. Die Wahrscheinlichkeit p für einen Erfolg ist konstant. X ist die Anzahl Versuche bis und mit dem ersten Erfolg.

$$P(X = k) = (1 - p)^{k-1} p \quad \text{für } k = 1, 2, 3, \dots$$

Negative Binomialverteilung

Es werden unabhängige Versuche durchgeführt. Jeder einzelne Versuch hat zwei mögliche Ausgänge, „Erfolg“ und „Misserfolg“. Die Wahrscheinlichkeit p für einen Erfolg ist konstant.




Abbildung 2.2.: Poissonverteilungen mit a) $\lambda = 0.5$, b) $\lambda = 2$, c) $\lambda = 4$, d) $\lambda = 8$

X ist die Anzahl Misserfolge bis r Erfolge eingetreten sind.

$$P(X = k) = \binom{k+r-1}{k} p^r (1-p)^k \quad \text{für } k = 0, 1, 2, \dots$$

Poissonverteilung

Betrachte die absolute Häufigkeit, mit der ein bestimmtes Ereignis eintritt. Wenn die Ereignisse unabhängig voneinander mit einer konstanten Rate λ passieren, dann hat die Anzahl Ereignisse X eine Poissonverteilung $\mathcal{P}(\lambda)$. Die Wahrscheinlichkeit für k Ereignisse pro Zeiteinheit ist:

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

Für n gross und p klein ist die Poissonverteilung eine Näherung für die Binomialverteilung mit $\lambda = np$.

Ein Prozess, der innerhalb eines festen zeitlichen oder räumlichen Intervalls eine Anzahl Ereignisse erzeugt, die einer Poissonverteilung folgt, heisst *Poissonprozess*.

2.3. Stetige Zufallsvariablen

Die *Dichte* f (density) ist eine stückweise stetige Funktion mit $f(x) \geq 0$ und $\int_{-\infty}^{\infty} f(x) dx$. Wenn X eine stetige Zufallsvariable mit Dichte f ist, dann gilt:

$$P(a < X < b) = \int_a^b f(x) dx \quad \text{für } a < b.$$

Die *kumulative Verteilungsfunktion* F (cumulative distribution function) ist definiert durch:

$$F(x) = P(X \leq x), \quad -\infty < x < \infty.$$

Es gilt:

$$F(x) = \int_{-\infty}^x f(t) dt$$

Das α -Quantil x_α ist definiert durch: $F(x_\alpha) = \alpha$. Für $\alpha = 1/2$ erhält man den *Median*, für $\alpha = 1/4$ und $\alpha = 3/4$ das 1. und das 3. *Quartil*.

Uniforme Verteilung

Die Dichte einer uniformverteilten Zufallsvariablen ist:

$$f(x) = \frac{1}{b-a} \quad \text{für } a \leq x \leq b.$$

Die Verteilungsfunktion ist:

$$F(x) = \begin{cases} 0, & x < a \\ \frac{x-a}{b-a}, & a \leq x \leq b \\ 1, & x > b. \end{cases}$$

Exponentialverteilung

Modell für Warte- oder Ueberlebenszeiten. Wird in einem Poissonprozess mit Parameter λ statt der Anzahl Ereignisse in einem bestimmten Zeitintervall die Dauer bis zum Eintreten des nächsten Ereignisses betrachtet, so ist diese Dauer exponentialverteilt, $Exp(\lambda)$. Die Exponentialverteilung ist *gedächtnislos* (memoryless).

Die Dichte einer exponentialverteilten Zufallsvariablen ist:

$$f(x) = \lambda e^{-\lambda x} \quad \text{für } x \geq 0, \quad \lambda > 0.$$

Die Verteilungsfunktion ist:

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

Gammaverteilung

Die Dichte einer gammaverteilten Zufallsvariablen ist:

$$f(x) = \frac{\lambda^\alpha}{\Gamma(\alpha)} x^{\alpha-1} e^{-\lambda x} \quad \text{für } x \geq 0, \quad \alpha > 0, \lambda > 0.$$

Die Gammafunktion $\Gamma(x)$ ist definiert durch: $\Gamma(x) = \int_0^\infty u^{x-1} e^{-u} du \quad x > 0$.

Es gilt: $\Gamma(1) = 1$, $\Gamma(\alpha) = (\alpha-1)\Gamma(\alpha-1)$ für $\alpha > 1$, $\Gamma(\alpha) = (\alpha-1)!$, wenn α eine ganze Zahl grösser als 1 ist.

Normalverteilung

Die Normalverteilung ist das weitaus häufigste Modell für Messdaten. Entwickelt wurde sie als Modell für Messfehler, sie passt aber oft auch in andern Situationen recht gut. Das




Abbildung 2.3.: Exponentialverteilungen mit $\lambda = 0.5$ (- · - ·), $\lambda = 1$ (·····), $\lambda = 2$ (—)




Abbildung 2.4.: Gammaverteilungen mit $\lambda = 1$ und a) $\alpha = 0.5$ (—) und $\alpha = 1$ (···),
b) $\alpha = 5$ (—) und $\alpha = 10$ (···)




Abbildung 2.5.: Dichtekurven von $\mathcal{N}(0, 1)$, $\mathcal{N}(3, 4)$ und $\mathcal{N}(7, 1/4)$

hat sich empirisch gezeigt und ein mathematisches Resultat, der *Zentrale Grenzwertsatz*, bestätigt das. Ein grosser Teil der statistischen Methoden setzt Normalverteilung voraus. Die Dichte einer Zufallsvariablen mit Normalverteilung $\mathcal{N}(\mu, \sigma^2)$ ist gegeben durch:

$$f(x) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{1}{2}\left(\frac{x-\mu}{\sigma}\right)^2} \quad -\infty < x < +\infty, \quad -\infty < \mu < +\infty, \quad \sigma > 0.$$

Die spezielle Normalverteilung $\mathcal{N}(0, 1)$ heisst *Standardnormalverteilung*. Für Dichte und kumulative Verteilungsfunktion verwendet man in diesem Fall die Bezeichnungen ϕ und Φ .

Chiquadrat-Verteilung

Seien $Z_1, \dots, Z_n \sim \mathcal{N}(0, 1)$, iid. Dann hat $X = Z_1^2 + Z_2^2 + \dots + Z_n^2$ eine Chiquadrat-Verteilung mit n Freiheitsgraden, $X \sim \chi_n^2$.

t-Verteilung

Seien $Z \sim \mathcal{N}(0, 1)$ und $X \sim \chi_n^2$ unabhängige Zufallsvariablen. Dann hat $T = \frac{Z}{\sqrt{X/n}}$ eine t -Verteilung mit n Freiheitsgraden, $T \sim t_n$.

F-Verteilung

Seien $X_1 \sim \chi_n^2$ und $X_2 \sim \chi_m^2$ unabhängige Zufallsvariablen. Dann hat $F = \frac{X_1/n}{X_2/m}$ eine F -Verteilung mit n und m Freiheitsgraden, $F \sim F_{n,m}$.

2.4. Erwartungswert und Varianz

Sei X eine diskrete Zufallsvariable mit Wahrscheinlichkeitsfunktion p . Der *Erwartungswert* von X (expected value, mean) ist definiert als:

$$E(X) = \sum_i x_i p(x_i),$$

falls die Summe existiert. Oft wird der Erwartungswert mit μ bezeichnet.

Sei X eine stetige Zufallsvariable mit Dichte f . Der Erwartungswert $E(X)$ von X ist definiert als:

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

falls das Integral existiert.

Sei X eine Zufallsvariable mit Erwartungswert $E(X)$. Dann ist die *Varianz* von X (variance) gegeben durch:

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

falls der Erwartungswert existiert. Die *Standardabweichung* von X (standard deviation) ist die Wurzel aus der Varianz. Oft wird die Varianz mit σ^2 und die Standardabweichung mit σ bezeichnet.

Wenn X diskret ist, gilt mit $E(X) = \mu$:

$$Var(X) = \sum_i (x_i - \mu)^2 p(x_i),$$

für X stetig:

$$Var(X) = \int_{-\infty}^{\infty} (x - \mu)^2 f(x) dx.$$

Rechenregeln

Seien X_1 und X_2 Zufallsvariablen und a, b konstante Zahlen. Dann gilt:

$$\begin{aligned} E(X_1 + X_2) &= E(X_1) + E(X_2) \\ E(a + bX_1) &= a + bE(X_1) \\ Var(X_1 + X_2) &= Var(X_1) + Var(X_2), \text{ falls } X_1 \text{ und } X_2 \text{ unabhängig sind} \\ Var(a + bX_1) &= b^2 Var(X_1). \end{aligned}$$

Zusammenstellung der wichtigsten Verteilungen

Verteilung	$P(X = k)$ bzw. $f(x)$	Wertebereich	$E(X)$	$Var(X)$
Binomial	$\binom{n}{k} p^k (1-p)^{n-k}$	$k = 0, 1, \dots, n$	np	$np(1-p)$
Neg. Binomial	$\binom{k+r-1}{k} p^r (1-p)^k$	$k = 0, 1, \dots$	$r \frac{1-p}{p}$	$r \frac{1-p}{p^2}$
Geometrisch	$(1-p)^{k-1} p$	$k = 1, 2, \dots$	$\frac{1}{p}$	$\frac{1-p}{p^2}$
Poisson	$\frac{\lambda^k e^{-\lambda}}{k!}$	$k = 0, 1, \dots$	λ	λ
Uniform	$\frac{1}{b-a}$	$a < x < b$	$\frac{a+b}{2}$	$\frac{(b-a)^2}{12}$
Normal	$\frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{1}{2}\left(\frac{x-\mu}{\sigma}\right)^2}$	$-\infty < x < \infty$	μ	σ^2
Gamma	$\frac{\lambda^\alpha}{\Gamma(\alpha)} x^{\alpha-1} e^{-\lambda x}$	$x > 0$	$\frac{\alpha}{\lambda}$	$\frac{\alpha}{\lambda^2}$
Exponential	$\lambda e^{-\lambda x}$	$x > 0$	$\frac{1}{\lambda}$	$\frac{1}{\lambda^2}$
Chiquadrat	$f(x) = \frac{1}{2^{\frac{n}{2}} \Gamma(\frac{n}{2})} x^{\frac{n}{2}-1} e^{-x/2}$	$x > 0$	n	$2n$
t	$f(x) = \frac{\Gamma[\frac{n+1}{2}]}{\sqrt{n\pi} \Gamma(\frac{n}{2})} \left(1 + \frac{x^2}{n}\right)^{-\frac{n+1}{2}}$	$-\infty < x < \infty$	0	$\frac{n}{n-2}$
F	$f(x) = \frac{\Gamma[\frac{n+m}{2}]}{\Gamma(\frac{n}{2}) \Gamma(\frac{m}{2})} \left(\frac{n}{m}\right)^{\frac{n}{2}} x^{\frac{n}{2}-1} \left(1 + \frac{n}{m}x\right)^{-\frac{n+m}{2}}$	$x > 0$	$\frac{n}{n-2}$	

2.5. Kovarianz und Korrelation

Seien X und Y gemeinsam verteilte Zufallsvariablen mit Erwartungswerten μ_X und μ_Y . Dann ist die *Kovarianz* von X und Y (covariance) gegeben durch:

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

falls der Erwartungswert existiert.

Seien X_1, X_2, Y_1 und Y_2 Zufallsvariablen und a, b, c und d konstante Zahlen, dann gilt:

$$\begin{aligned} \text{Cov}(X_1 + X_2, Y_1 + Y_2) &= \text{Cov}(X_1, Y_1) + \text{Cov}(X_1, Y_2) + \text{Cov}(X_2, Y_1) + \text{Cov}(X_2, Y_2) \\ \text{Cov}(a + bX_1, c + dY_1) &= bd\text{Cov}(X_1, Y_1). \end{aligned}$$

Daraus folgt:

$$\text{Var}(aX_1 + bX_2) = a^2\text{Var}(X_1) + b^2\text{Var}(X_2) + 2ab\text{Cov}(X_1, X_2).$$

Seien X und Y gemeinsam verteilte Zufallsvariablen mit Varianzen verschieden von Null. Dann ist die *Korrelation* von X und Y (correlation) gegeben durch:

$$\rho = \frac{\text{Cov}(X, Y)}{\sqrt{\text{Var}(X)\text{Var}(Y)}}.$$

Es gilt: $-1 \leq \rho \leq 1$ und $\rho = \pm 1$ für $Y = a + bX$.

2.6. Anwendungsbereiche von verschiedenen Wahrscheinlichkeitsmodellen

Verteilung	Beispiele
Diskret Uniform	Würfeln, einstellige Zufallszahlen
Bernoulli	Spezialfall der Binomial ($n = 1$)
Binomial	Anzahl Uebertragungsfehler in einer Sequenz fester Länge, Anzahl defekte Stücke unter n Einheiten, Anzahl Bluter unter n Knaben, Anzahl Mädchen unter n Kindern, Anzahl von Objekten, die regulär verteilt sind (zeitlich oder räumlich)
Geometrisch	Anzahl gekaufte Lose bis zu einem Gewinn
Hypergeometrisch	„Ziehen ohne Zurücklegen“, Capture-Recapture
Negative Binomial	Anzahl von Objekten, die geklumpt verteilt sind (zeitlich oder räumlich), Anzahl Corn-Flakes-Käufe
Poisson	Anzahl Todesfälle pro Jahr, Bakterien in 10ml Lösung, Fahrzeuge vor einer Ampel, Telephonanrufe pro 5 Min.
Stetig Uniform	„Zufallszahl zwischen 0 und 1“
Exponential	Warte- oder Überlebenszeiten zwischen Ereignissen, die poissonverteilt sind („ohne Gedächtnis“), Aufnahmezeiten von neurologischen Rezeptoren
Gamma	Warte- oder Ueberlebenszeiten „mit Klumpung“, Zeit zwischen zwei Erdbeben
Normal	Messfehler, Längenmessungen, Mittelwerte (ZGS)

3. Schätzungen

Statistiken werden benutzt, um entsprechende Parameter der Population zu schätzen. Eine Schätzung, die aus einer einzelnen Zahl besteht, heisst Punktschätzung.

Wegen der Stichprobenvariabilität ergibt sich je nach Stichprobe ein anderer Wert. Es ist wichtig zu wissen, wie stark diese Schwankungen sein können, um die Genauigkeit der Schätzung beurteilen zu können.

3.1. Grenzwertsätze

Gegeben sei eine Population mit Mittelwert μ und Standardabweichung σ . Der Mittelwert einer Zufallsstichprobe X_1, \dots, X_n vom Umfang n aus dieser Population kann als Zufallsvariable \bar{X} betrachtet werden. Für die Wahrscheinlichkeitsverteilung von \bar{X} gilt dann:

$$\mu_{\bar{x}} = \mu \quad \text{und} \quad \sigma_{\bar{x}} = \sigma/\sqrt{n} \tag{3.1}$$

Im Mittel liegt die Schätzung richtig, sie ist erwartungstreu, und die Streuung nimmt mit zunehmendem n ab.

Mit Hilfe des Gesetzes der grossen Zahl und dem Zentralen Grenzwertsatz kann diese Aussage noch präzisiert werden.

Satz 1 (Gesetz der grossen Zahl) *Seien X_1, X_2, \dots, X_n unabhängige Zufallsvariablen mit $E(X_i) = \mu$ und $Var(X_i) = \sigma^2$. Sei $\bar{X}_n = 1/n \sum_{i=1}^n X_i$. Dann gilt für ein beliebiges $\epsilon > 0$:*

$$P(|\bar{X}_n - \mu| > \epsilon) \rightarrow 0 \quad \text{für } n \rightarrow \infty.$$

Für genügend grosses n liegt also \bar{X} nahe bei μ .

Satz 2 (Zentraler Grenzwertsatz) *Seien X_1, X_2, \dots, X_n unabhängige Zufallsvariablen mit $E(X_i) = \mu$, $Var(X_i) = \sigma^2$ und gemeinsamer Verteilungsfunktion F . Dann nähert sich die Verteilung des Mittelwerts \bar{X}_n der X_i für wachsendes n der Normalverteilung an:*

$$\lim_{n \rightarrow \infty} P\left(\frac{\bar{X}_n - \mu}{\sigma/\sqrt{n}} \leq x\right) = \Phi(x) \quad -\infty < x < \infty.$$

\bar{X} ist genähert normalverteilt für grosses n .

3.2. Vertrauensintervalle

Vertrauensintervall für μ

Wegen des Zentralen Grenzwertsatzes gilt mindestens genähert :

$$P(-1.96 \leq \frac{\bar{X} - \mu}{\sigma/\sqrt{n}} \leq 1.96) = 0.95,$$




Abbildung 3.1.: Simulation von 100 Vertrauensintervallen um $\mu = 0$

d. h.

$$P(\mu - 1.96\sigma/\sqrt{n} \leq \bar{X} \leq \mu + 1.96\sigma/\sqrt{n}) = 0.95.$$

Nun ist

$$\mu - 1.96\sigma/\sqrt{n} \leq \bar{X} \leq \mu + 1.96\sigma/\sqrt{n}$$

äquivalent zu

$$\bar{X} - 1.96\sigma/\sqrt{n} \leq \mu \leq \bar{X} + 1.96\sigma/\sqrt{n}.$$

Wenn σ bekannt ist, kann man also eine Stichprobe ziehen, \bar{x} berechnen, zusammen mit σ in der obigen Ungleichung einsetzen und dann erhält man ein 95%-*Vertrauensintervall* oder *Konfidenzintervall* (confidence interval) für den unbekannt Parameter μ :

$$\bar{x} \pm 1.96\sigma/\sqrt{n} \tag{3.2}$$

Man kann **nicht** sagen, dass μ mit einer Wahrscheinlichkeit von 95% im berechneten Intervall liegt. Der Parameter μ ist eine Konstante und nicht zufällig. Aus einer Stichprobe berechnet man den Mittelwert \bar{x} und daraus die Intervallgrenzen. Auch die Intervallgrenzen sind also fest und nicht zufällig. Entweder liegt μ im Intervall oder nicht.

Zufällig ist der Wert, den die Zufallsvariable \bar{X} annimmt. Jede Stichprobe liefert ein etwas anderes \bar{x} und damit ein etwas anderes Intervall $\bar{x} \pm 1.96\sigma/\sqrt{n}$. 95% der so erzeugten Intervalle enthalten tatsächlich μ , die restlichen 5% nicht.

Vertrauensintervall für Proportion p

Sei p der Anteil der Stimmbevölkerung, der für Kandidat A ist und \hat{p} = der entsprechende Anteil in einer „repräsentativen“ Stichprobe vom Umfang n , also eine Schätzung für p .

Gegeben seien Zufallsvariablen X_1, \dots, X_n mit

$$X_i = \begin{cases} 1 & \text{Person } i \text{ ist für A} \\ 0 & \text{sonst} \end{cases} \quad \sum X_i \sim \mathcal{B}(n, p),$$

$$\hat{p} = \frac{\sum X_i}{n}$$

Wegen dem Zentralen Grenzwertsatz ist $\hat{p} \stackrel{as}{\approx} \mathcal{N}(p, \frac{p(1-p)}{n})$, $\sigma_{\hat{p}} = \sqrt{\frac{p(1-p)}{n}}$.

Deshalb gilt: $P\left(p - 1.96\sqrt{\frac{p(1-p)}{n}} < \hat{p} < p + 1.96\sqrt{\frac{p(1-p)}{n}}\right) \approx 0.95$

$P\left(\hat{p} - 1.96\sqrt{\frac{p(1-p)}{n}} < p < \hat{p} + 1.96\sqrt{\frac{p(1-p)}{n}}\right) \approx 0.95$

Für genügend grosses n ist $\hat{p} \pm 1.96\sqrt{\frac{\hat{p}(1-\hat{p})}{n}}$ ein 95%-Vertrauensintervall für p .

Vertrauensintervall für μ , σ unbekannt

Satz 3 Seien $X_1, \dots, X_n \sim \mathcal{N}(\mu, \sigma^2)$ iid und $S^2 = \frac{1}{n-1} \sum (X_i - \bar{X})^2$ die Stichprobenvarianz.

Dann hat

$$\frac{\bar{X} - \mu}{S/\sqrt{n}}$$

eine t -Verteilung mit $n - 1$ Freiheitsgraden.

Nun gilt also

$$P(-t_{0.975} \leq \frac{\bar{X} - \mu}{s/\sqrt{n}} \leq t_{0.975}) = 0.95$$

$$\iff$$

$$P(\mu - t_{0.975} s/\sqrt{n} \leq \bar{X} \leq \mu + t_{0.975} s/\sqrt{n}) = 0.95$$

Aber:

$$\mu - t_{0.975} s/\sqrt{n} \leq \bar{X} \leq \mu + t_{0.975} s/\sqrt{n} \iff \bar{X} - t_{0.975} s/\sqrt{n} \leq \mu \leq \bar{X} + t_{0.975} s/\sqrt{n}$$

Ein 95% Vertrauensintervall für den unbekannt Parameter μ ist also

$$\bar{x} \pm t_{0.975} s/\sqrt{n}$$

4. Statistische Tests

4.1. Begriffe und Vorgehensweise

Allgemein	Beispiel
1. Problem formulieren: <i>Nullhypothese</i> H_0 festlegen	
2. Alternativen bestimmen: <i>Alternativhypothese</i> H_A	
3. zu beobachtende Grösse festlegen: <i>Teststatistik</i> T	
4. Wahrscheinlichkeitsverteilung von T unter H_0 bestimmen	
5. Menge aller "extremen" Beobachtungen definieren: <i>Verwerfungsbereich</i> K mit <i>Signifikanzniveau</i> α	
6. Daten erheben, Wert von T berechnen: $T = t$	
7. <i>P-Wert</i> berechnen	
8. Entscheidung: t im Verwerfungsbereich: verwerfe H_0 t im Annahmehbereich: behalte H_0 bei	

Erläuterungen:

1. Wir nehmen an, dass kein Effekt oder Unterschied vorhanden ist und versuchen Evidenz gegen diese Annahme, die *Nullhypothese* H_0 , zu finden. Die Nullhypothese ist das zu überprüfende Modell und besteht meistens aus einer Verteilungsannahme und einer Aussage über einen Parameter.
2. Weil man Evidenz **gegen** und nicht für etwas sucht, entspricht die Alternativhypothese der *Arbeitshypothese*. Die Nullhypothese möchte man möglichst widerlegen.
3. Die Teststatistik basiert meistens auf einer Schätzung des Parameters, der in Null- und Alternativhypothese auftritt.
5. Das Signifikanzniveau α (significance level) ist gleich der Wahrscheinlichkeit, ein „extremes“ Resultat zu erhalten, unter der Annahme, dass H_0 stimmt. Je grösser also α gewählt wird, desto grösser ist der Verwerfungsbereich und umgekehrt. Üblich sind $\alpha = 5\%$ oder $\alpha = 1\%$. Das Komplement zum Verwerfungsbereich heisst *Annahmehbereich*.
7. Der *P-Wert* (p-value) ist die Wahrscheinlichkeit, dass in einem neuen Versuch ein mindestens so extremes Resultat herauskommt, unter der Annahme, dass H_0 richtig

ist. Der P -Wert ist **nicht** die Wahrscheinlichkeit, dass H_0 richtig ist. Einer Hypothese kann gar keine Wahrscheinlichkeit zugeordnet werden, sie ist entweder richtig oder falsch.

8. Der Wert von T ist genau dann im Verwerfungsbereich, wenn der P -Wert $\leq \alpha$. In diesem Fall wird die Nullhypothese abgelehnt oder verworfen. H_0 wird als statistisch widerlegt betrachtet. Der Test ist (statistisch) signifikant.

Wenn der P -Wert $> \alpha$ ist, dann liegt der Wert von T im Annahmebereich und die Daten sprechen zu wenig gegen H_0 . H_0 kann nicht verworfen werden. Der Test ist nicht signifikant.

Fehler 1. Art: H_0 wird verworfen, obschon H_0 richtig wäre. Die Wahrscheinlichkeit eines Fehlers 1. Art ist α und wird auf 5% oder 1% festgelegt.

Fehler 2. Art: H_0 wird beibehalten, obschon H_A stimmt. Die Wahrscheinlichkeit eines Fehlers 2. Art wird meist mit β bezeichnet.

Macht: $1 - \beta$ ist die Wahrscheinlichkeit, eine wahre Alternativhypothese zu erkennen und heisst die *Macht* des Tests (power).

Beispiel: Vergleich von zwei Betriebssystemen

Braucht die Installation von Linux mehr Zeit? 15 InformatikerInnen richteten je zwei Netzwerke ein (Betriebssystem, Applikationen, Peripheriegeräte).

Benötigte Zeit in Minuten:

Inf. Nr.	Linux	WinNT	Diff. d
1	154	145	9
2	164	162	2
3	198	156	42
4	168	152	16
5	180	168	12
6	172	157	15
7	142	155	-13
8	165	140	25
9	172	145	27
10	158	160	-2
11	170	165	5
12	148	174	-26
13	188	138	50
14	145	142	3
15	146	149	-3

4.2. Tests für Lageparameter

z-Test

Seien X_1, \dots, X_n unabhängig normalverteilt mit Erwartungswert μ und bekannter Varianz σ^2 . Betrachte die folgenden Hypothesen:

$$H_0: \mu = \mu_0$$

$$H_A: \mu \neq \mu_0.$$

Die Teststatistik des z -Tests ist:

$$Z = \frac{\bar{X} - \mu_0}{\sigma/\sqrt{n}}, \quad \text{unter } H_0 \text{ standardnormalverteilt.}$$

t-Test für eine Stichprobe

Seien X_1, \dots, X_n unabhängig normalverteilt mit Erwartungswert μ und unbekannter Varianz. Betrachte die folgenden Hypothesen:

$$H_0: \mu = \mu_0$$

$$H_A: \mu \neq \mu_0.$$

Die Teststatistik des t -Tests ist:

$$t = \frac{\bar{X} - \mu_0}{S/\sqrt{n}}, \quad \text{unter } H_0 \text{ t-verteilt mit } n - 1 \text{ Freiheitsgraden (degrees of freedom).}$$

Vorzeichentest (sign test)

Seien X_1, \dots, X_n iid mit Median m .

$$H_0: m = \mu_0$$

$$H_A: m \neq \mu_0.$$

Zur Berechnung der Teststatistik T wird von jedem Wert μ_0 subtrahiert. Dann ist T die Anzahl positiver (oder negativer) Beobachtungen; $T \sim \mathcal{B}(n, 0.5)$.

Wilcoxon-Test (Rangsummentest, signed rank test)

Seien X_1, \dots, X_n iid stetige, symmetrisch verteilte Zufallsvariablen mit Median m .

$$H_0: m = \mu_0$$

$$H_A: m \neq \mu_0.$$

Zuerst wird von allen Beobachtungen μ_0 subtrahiert. Die Werte werden dann dem Absolutbetrag nach geordnet und die zugehörigen Ränge bestimmt. Sind mehrere Werte gleich gross, werden die Ränge gemittelt.

Die Teststatistik ist die Rangsumme aller positiven (oder negativen) Werte T^+ (oder T^-).

Es gibt Tabellen mit den kritischen Werten; für $n > 30$ Normalapproximation.

4.3. Welcher Test soll benutzt werden?

Im Betriebssystembeispiel wird von den drei Tests auf Lageparameter einer signifikant und zwei nicht. Was nun? Nehmen wir das für uns günstigste Ergebnis und vergessen den Rest? Die verschiedenen Tests haben ganz unterschiedliche Voraussetzungen:

z-Test:	Daten sind normalverteilt, σ^2 ist bekannt, unabh. Beobachtungen
t-Test:	Daten sind normalverteilt, unabh. Beobachtungen
Wilcoxon-Test:	Daten sind stetig und symmetrisch verteilt, unabh. Beobachtungen
Vorzeichentest:	unabh. Beobachtungen

Die Null- und Alternativhypothese sind entsprechend:

H_0 : die obigen Voraussetzungen und $\mu = \mu_0$ oder $m = \mu_0$

H_A : die obigen Voraussetzungen und $\mu \neq \mu_0$ oder $m \neq \mu_0$

Der z-Test ist praktisch kaum je benutzbar, weil σ fast immer unbekannt ist. Der t-Test reagiert auf Ausreisser sehr empfindlich, weil \bar{x} und s empfindlich sind. Er ist hingegen robust (unempfindlich) gegen kleinere Abweichungen von der Normalverteilung, insbesondere für grösseres n . Die Robustheit bezieht sich aber nur auf das Signifikanzniveau α . Die Macht des

t-Tests kann ziemlich drastisch abnehmen. Der Wilcoxon-Test hat unter exakter Normalverteilung eine etwas kleinere Macht als der t-Test, bei Abweichungen von der Normalverteilung ist er aber deutlich effizienter (mächtiger) als der t-Test. Der Vorzeichen-Test ist eher ineffizient.

Empfehlung:

Falls die Daten stetig und symmetrisch sind den Wilcoxon-Test benutzen, sonst den Vorzeichen-Test. Falls der t-Test benutzt wird, den Normalplot anschauen.

t-Test für zwei unabhängige Stichproben

Seien X_1, \dots, X_n unabhängig normalverteilt mit Erwartungswert μ_X und Varianz σ^2 und Y_1, \dots, Y_m unabhängig normalverteilt mit Erwartungswert μ_Y und Varianz σ^2 . Die Y_i seien unabhängig von den X_i .

$$H_0: \mu_X = \mu_Y$$

$$H_A: \mu_X \neq \mu_Y.$$

Die Teststatistik des t-Tests ist:

$$t = \frac{\bar{X} - \bar{Y}}{S_p \sqrt{\frac{1}{n} + \frac{1}{m}}} \quad \text{mit } S_p^2 = \frac{(n-1)S_X^2 + (m-1)S_Y^2}{n+m-2}$$

Unter H_0 ist t t-verteilt mit $n + m - 2$ Freiheitsgraden.

Mann-Whitney-Test (Rangsummentest, rank sum test)

Seien X_1, \dots, X_n iid stetige Zufallsvariablen mit Erwartungswert μ_X und Y_1, \dots, Y_m iid stetige Zufallsvariablen mit Erwartungswert μ_Y . Die Y_i seien unabhängig von den X_i .

$$H_0: \mu_X = \mu_Y$$

$$H_A: \mu_X \neq \mu_Y.$$

Bestimme die Rangsummen $T^{(1)}$ der X_i und $T^{(2)}$ der Y_i in der „gemeinsamen“ Stichprobe. Setze

$$U^{(1)} = T^{(1)} - \frac{n(n+1)}{2}, \quad U^{(2)} = T^{(2)} - \frac{m(m+1)}{2} \quad \text{und } U = \min(U^{(1)}, U^{(2)}).$$

Die kritischen Werte für U sind tabelliert.

4.4. Dualität zwischen Tests und Vertrauensintervallen

Bei einem Test lautet die Frage: „Welche Beobachtungen sind vereinbar mit H_0 , bzw. einem Parameterwert μ_0 ?“ Der Annahmebereich liefert die Antwort.

Umgekehrt wird bei einem Vertrauensintervall gefragt: „Welche Parameter sind vereinbar mit den Beobachtungen?“ Alle diese Parameterwerte bilden dann das Vertrauensintervall.

Satz 4 (Dualitätssatz) *Ein Test mit Signifikanzniveau α verwirft $H_0 : \mu = \mu_0$ genau dann nicht, wenn μ_0 innerhalb des $(1 - \alpha)100\%$ -Vertrauensintervalls liegt.*

5. Zusammenhang zwischen zwei kategoriellen Variablen

5.1. 2×2-Kreuztabelle, Kontingenztafel

Beispiel: Desinfektion

Joseph Lister, brit. Arzt im 19. Jh., experimentierte mit Karbolsäure, um die hohe Todesrate durch postoperative Infektionen nach Amputationen zu senken.

Eine 2×2-Kreuztabelle, oder *Kontingenztafel*, zeigt die 75 Operationen:

Desinfektion	überlebt		Total
	ja	nein	
ja	34	6	40
nein	19	16	35
Total	53	22	75

X	Y		Total
	1	2	
1	n_{11}	n_{12}	$n_{1.}$
2	n_{21}	n_{22}	$n_{2.}$
Total	$n_{.1}$	$n_{.2}$	$n_{..}$

Verschiedene relative Häufigkeiten:

Gemeinsame Häufigkeit: der Anteil der Beobachtungen mit $X = 1$ und $Y = 1$ an der Gesamtzahl Beobachtungen.

Randhäufigkeit, marginale Häufigkeit: der Anteil der Beobachtungen mit $X = 1$ an der Gesamtzahl Beobachtungen.

Bedingte Häufigkeit: der Anteil der Beobachtungen mit $Y = 1$ unter den Beobachtungen mit $X = 1$.

Besteht ein Zusammenhang zwischen X und Y ? Vergleiche die bedingten Häufigkeiten miteinander.

5.2. Chiquadrat-Test auf Unabhängigkeit

Gemeinsame Verteilung von X und Y : $p_{ij} = P(X = i, Y = j)$ mit $i = 1, 2, j = 1, 2$.

Randverteilungen: $p_{i.} = P(X = i) = \sum_j p_{ij}$ und $p_{.j} = P(Y = j) = \sum_i p_{ij}$.

X	Y		Total
	1	2	
1	p_{11}	p_{12}	$p_{1.}$
2	p_{21}	p_{22}	$p_{2.}$
Total	$p_{.1}$	$p_{.2}$	1

Wenn X und Y unabhängig sind, so gilt:

$$P(X = i, Y = j) = P(X = i)P(Y = j), \text{ d. h. } p_{ij} = p_{i.} \cdot p_{.j}$$

Null- und Alternativhypothese:

$H_0 : p_{ij} = p_{i.} \cdot p_{.j}$ kein Zusammenhang zwischen X und Y
 $H_A : p_{ij} \neq p_{i.} \cdot p_{.j}$ es gibt einen Zusammenhang zwischen X und Y

Erwartete Häufigkeiten unter H_0 :

X	Y		Total
	1	2	
1	$\frac{n_{1.} \cdot n_{.1}}{n_{..}}$	$\frac{n_{1.} \cdot n_{.2}}{n_{..}}$	$n_{1.}$
2	$\frac{n_{2.} \cdot n_{.1}}{n_{..}}$	$\frac{n_{2.} \cdot n_{.2}}{n_{..}}$	$n_{2.}$
Total	$n_{.1}$	$n_{.2}$	$n_{..}$

Die Testgrösse basiert auf den Abweichungen zwischen beobachteten (O_k) und erwarteten Häufigkeiten (E_k) in den einzelnen Zellen k: $X^2 = \sum_{k=1}^4 \frac{(O_k - E_k)^2}{E_k} = \sum_{ij} \frac{(n_{ij} - n_{i.} \cdot n_{.j} / n_{..})^2}{n_{i.} \cdot n_{.j} / n_{..}}$.

X^2 ist unter H_0 genähert χ^2 -verteilt mit einem Freiheitsgrad. Näherung ist gut, wenn $n_{..} \geq 30$ und alle **erwarteten** Häufigkeiten ≥ 5 .

Der χ^2 -Test ist ein einseitiger Test! Mit $\alpha = 5\%$ wird H_0 verworfen, wenn $X^2 > 3.84$.

5.3. $r \times s$ -Kontingenztafeln

Die kategoriellen Variablen X und Y haben r und s Ausprägungen.

Nullhypothese H_0 : kein Zusammenhang zwischen X und Y

Testgrösse basiert wieder auf den Abweichungen zwischen beobachteten (O_k) und erwarteten Häufigkeiten (E_k): $X^2 = \sum_{k=1}^{rs} \frac{(O_k - E_k)^2}{E_k}$.

X^2 hat unter H_0 genähert eine χ^2 -Verteilung mit $(r - 1)(s - 1)$ Freiheitsgraden.

Näherung ist gut, falls $n_{..} \geq 30$, die meisten erwarteten Häufigkeiten ≥ 4 und höchstens 20% aller erwarteten Häufigkeiten zwischen 1 und 4 sind.

Beispiel: Umfrage zum Umweltschutz

Bildung	Beeinträchtigung				Total
	1	2	3	4	
1	212	85	38	20	355
2	434	245	85	35	799
3	169	146	74	30	419
4	79	93	56	21	249
5	45	69	48	20	182
Total	939	638	301	126	2004

H_0 : „Es gibt keinen Zusammenhang zwischen Beeinträchtigung und Bildung“.

Die unter H_0 erwarteten Häufigkeiten sind:

Bildung	Beeinträchtigung			
	1	2	3	4
1	166.3	113.0	53.3	22.3
2	374.4	254.4	120.0	50.2
3	196.3	133.4	62.9	26.3
4	116.7	79.3	37.4	15.7
5	85.3	57.9	27.3	11.4

5.4. Bemerkungen zum Chiquadrat-Test

Immer Absolutzahlen verwenden, keine Prozentzahlen oder sonst irgendwie standardisierte Zahlen nehmen.

Beobachtungen müssen unabhängig sein. Bei z. B. gepaarten Daten ist *McNemar's Test* statt dem χ^2 - Test durchzuführen.

Für Kategorien mit einer Rangordnung gibt es den Chiquadrattest auf Trend.

Bei zu kleinen Anzahlen ist *Fisher's exakter Test* durchzuführen.

5.5. McNemar's Test für gepaarte Daten

1980	1982		Total
	RaucherIn	NichtraucherIn	
RaucherIn	620	97	717
NichtraucherIn	76	1317	1393
Total	696	1414	2110

H_0 : „kein Zusammenhang zwischen Jahr und Rauchverhalten“ oder „Zwischen 1980 und 1982 begannen gleichviele Personen neu zu rauchen wie RaucherInnen aufhörten“.

H_A : „Es gibt eine Änderungstendenz in eine Richtung“.

Betrachte nur diejenigen Personen, die sich verändern. Es gibt $r = 97$ Raucherinnen, die aufhörten und $s = 76$ NichtraucherInnen, die mit Rauchen angingen. Die Teststatistik ist:

$$X^2 = \frac{(|r - s| - 1)^2}{r + s} \text{ und ist } \chi^2\text{-verteilt mit 1 fg}$$

Wir haben also $X^2 = 2.31 < 3.84$, H_0 kann nicht verworfen werden.

5.6. Chiquadrat-Anpassungstest

Stimmt eine beobachtete Häufigkeitsverteilung mit einer theoretischen Verteilung überein?

Die Testgrösse $X^2 = \sum_{k=1}^r \frac{(O_k - E_k)^2}{E_k}$ ist χ^2 -verteilt mit ν Freiheitsgraden, wobei $\nu = \text{Anz. Klassen} - 1 - \text{Anz. geschätzter Parameter}$.

Beispiel: Kreuzungsversuch:

Nachkommen mit drei Phänotypen mit W'keiten $\frac{1}{4}$, $\frac{1}{2}$ und $\frac{1}{4}$. Sind die beobachteten Häufigkeiten unter 150 Nachkommen mit dem Erbgesetz vereinbar?

Phänotyp	beobachtet (O_k)	erwartet (E_k)
I	29	37.5
II	77	75
III	44	37.5
Total	150	150

Beispiel: Poissonverteilung für die Anzahl Bakterien

Anz. Bakterien pro Fläche	Anzahl Flächen	
	beobachtet	erwartet
0	34	32.8
1	68	82.1
2	112	102.6
3	94	85.5
4	55	53.4
5	21	26.7
6	12	11.1
7+	4	5.7
Total	400	399.9

6. Einfache lineare Regression

6.1. Das Modell

$$y_i = \beta_0 + \beta_1 x_i + \epsilon_i \quad i = 1, \dots, n$$

y_i ist die Zielvariable der i -ten Beobachtung.


x_i ist die erklärende Variable der i -ten Beobachtung. x_i ist eine feste, nicht zufällige Grösse. β_0, β_1 sind unbekannte *Parameter*, die sog. Regressionskoeffizienten. Diese sollen mit Hilfe der vorhandenen Daten geschätzt werden.

ϵ_i ist der *zufällige Rest* oder *Fehler*, d. h. die zufällige Abweichung von y_i von der Geraden. Es wird vorausgesetzt, dass $E(\epsilon_i) = 0$, $Var(\epsilon_i) = \sigma^2$ ist und dass $Cov(\epsilon_i, \epsilon_j) = 0$ für $i \neq j$.

6.2. Methode der Kleinsten Quadrate

Residuen: $r_i = y_i - (\beta_0 + \beta_1 x_i)$

Minimiere $Q(\beta_0, \beta_1) = \sum_{i=1}^n r_i^2 = \sum_{i=1}^n (y_i - (\beta_0 + \beta_1 x_i))^2$



Normalgleichungen:

$$\begin{aligned} n\beta_0 + \beta_1 \sum_{i=1}^n x_i &= \sum_{i=1}^n y_i \\ \beta_0 \sum_{i=1}^n x_i + \beta_1 \sum_{i=1}^n x_i^2 &= \sum_{i=1}^n y_i x_i \end{aligned}$$

Least Squares-Lösung:

$$\hat{\beta}_1 = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sum_{i=1}^n (x_i - \bar{x})^2}, \quad \hat{\beta}_0 = \bar{y} - \hat{\beta}_1 \bar{x}$$

Regressionsgerade:

$$\hat{y} = \hat{\beta}_0 + \hat{\beta}_1 x$$

Eigenschaften der LS-Schätzer

- erwartungstreu $E(\hat{\beta}_0) = \beta_0$ und $E(\hat{\beta}_1) = \beta_1$
- BLUE** Best Linear Unbiased Estimator

$$\text{Var}(\hat{\beta}_0) = \sigma^2 \left(\frac{1}{n} + \frac{\bar{x}^2}{\sum (x_i - \bar{x})^2} \right) \quad \text{Var}(\hat{\beta}_1) = \frac{\sigma^2}{\sum (x_i - \bar{x})^2}$$

Schätzung für σ^2 :

$$\hat{\sigma}^2 = \text{MSE} = \frac{SSE}{n-2}$$

6.3. Tests und Vertrauensintervalle

Vor: ϵ_i normalverteilt und unabhängig.

Das Modell kann nun so geschrieben werden:

$$y_i \sim N(\beta_0 + \beta_1 x_i, \sigma^2), \quad y_i \text{ und } y_j \text{ unabhängig für } i \neq j$$

t-Test für $H_0 : \beta_1 = \beta$ gegen $H_A : \beta_1 \neq \beta$:

$$t^* = \frac{\hat{\beta}_1 - \beta}{\text{se}(\hat{\beta}_1)} = \frac{\hat{\beta}_1 - \beta}{\sqrt{\hat{\sigma}^2 / \sum (x_i - \bar{x})^2}}$$

t^* hat eine t -Verteilung mit $n - 2$ Freiheitsgraden. Die Grösse $\text{se}(\hat{\beta}_1)$ heisst *Standardfehler* (standard error) von $\hat{\beta}_1$. Verwerfe H_0 , wenn $|t^*| > t_{97.5\%, n-2}$.

Ein 95%-Vertrauensintervall für β_1 ist:

$$\hat{\beta}_1 \pm t_{97.5\%, n-2} \cdot \sqrt{\hat{\sigma}^2 / \sum (x_i - \bar{x})^2}$$

Ein 95%-Vertrauensintervall für $\beta_0 + \beta_1 x_0$ ist

$$\hat{\beta}_0 + \hat{\beta}_1 x_0 \pm t_{97.5\%, n-2} \cdot \hat{\sigma} \sqrt{\frac{1}{n} + \frac{(x_0 - \bar{x})^2}{\sum (x_i - \bar{x})^2}}$$

Ein 95%-Prognoseintervall für y_0 ist

$$\hat{\beta}_0 + \hat{\beta}_1 x_0 \pm t_{97.5\%, n-2} \cdot \hat{\sigma} \sqrt{1 + \frac{1}{n} + \frac{(x_0 - \bar{x})^2}{\sum (x_i - \bar{x})^2}}$$

6.4. Varianzanalyse

Zerlegung der Quadratsummen:

$$\sum_{i=1}^n (y_i - \bar{y})^2 = \sum_{i=1}^n (\hat{y}_i - \bar{y})^2 + \sum_{i=1}^n (y_i - \hat{y}_i)^2$$

$$SST = SSR + SSE$$

total sum of squares = regression sum of squares + error sum of squares

Mean square of ... = $\frac{\text{sum of squares of ...}}{\text{Freiheitsgrade}}$

F-Test für $H_0 : \beta_1 = 0$ mit der Teststatistik:

$$F^* = \frac{SSR/1}{SSE/(n-2)} = \frac{MSR}{MSE}$$

F^* hat unter H_0 eine F-Verteilung mit 1 und $n - 2$ Freiheitsgraden. Verwerfe H_0 , wenn $F^* > F_{95\%, 1, n-2}$

Anova-Tabelle:

Source of Variation	Sum of squares	Degrees of Freedom	Mean square	F^*
Regression	SSR	1	MSR	MSR/MSE
Residual	SSE	$n - 2$	MSE	
Total	SST	$n - 1$		

Bestimmtheitsmass R^2 : Anteil an der Gesamtvariabilität, der „durch die Regression erklärt wird“:

$$R^2 = 1 - \frac{SSE}{SST}$$

Es gilt $R^2 = r^2$, wobei r die Korrelation zwischen x und y ist.

6.5. Residuenanalyse


Modellannahmen:

- Zusammenhang zwischen y und x genähert linear.
- ϵ_i haben Erwartungswert 0.
- ϵ_i haben Varianz σ^2 .
- ϵ_i sind unkorreliert.
- ϵ_i sind normalverteilt.


Residuenplots:

- Normalplot
- Plot von r_i gegen \hat{y}_i
- Plot von r_i gegen x_i
- Plot von r_i gegen i


Normalplots




rechtsschief




linksschief




dickschwaenzig




duennschwaenzig




(a) ideal



(b) nichtkonstante Varianz



(c) nichtkonstante Varianz



(d) Nichtlinearität

7. Multiple lineare Regression

Beispiel: Luftverschmutzung und Mortalität

Um den Einfluss der Luftverschmutzung auf die allgemeine Mortalität zu untersuchen, wurden in einer US-Studie (finanziert von General Motors) Daten aus 60 verschiedenen Regionen zusammengetragen. Neben der altersstandardisierten Mortalität und der Belastung durch CO , NOx und SO_2 wurden verschiedene demographische und meteorologische Variablen erfasst.

Eine einfache lineare Regression von Mortalität auf SO_2 zeigt, dass mit zunehmender SO_2 -Konzentration die allgemeine Sterblichkeit signifikant ansteigt. Aber auch der Zusammenhang zwischen Mortalität und allgemeinem Bildungsstand, Bevölkerungsdichte, %-Nichtweisse, Einkommen, Niederschlagsmenge usw. ist jeweils signifikant.

Statt viele einzelne einfache Regressionen zu rechnen, ist es besser, den Zusammenhang mit mehreren erklärenden Variablen gleichzeitig zu untersuchen.

7.1. Das Modell

$$y_i = \beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + \dots + \beta_p x_{ip} + \epsilon_i \quad i = 1, \dots, n$$

y_i : Zielvariable

x_{i1}, \dots, x_{ip} : erklärende Variablen, fest.

β_0, \dots, β_p : unbekannte Parameter, Regressionskoeffizienten.

ϵ_i : zufälliger Rest oder Fehler. $E(\epsilon_i) = 0$, $Var(\epsilon_i) = \sigma^2$ und $Cov(\epsilon_i, \epsilon_j) = 0$ für $i \neq j$.

Für ϵ_i normalverteilt gilt $y_i \sim N(\beta_0 + \beta_1 x_{i1} + \dots + \beta_p x_{ip}, \sigma^2)$ und $Cov(y_i, y_j) = 0$ für $i \neq j$.

in Matrixschreibweise:

$$\mathbf{y} = \mathbf{X}\boldsymbol{\beta} + \boldsymbol{\epsilon}$$

\mathbf{y} : Zielvariablenvektor der Länge n .

\mathbf{X} : Designmatrix der Dimension $n \times (p + 1)$.

$\boldsymbol{\beta}$: Parametervektor der Länge $p + 1$.

$\boldsymbol{\epsilon}$: Fehlervektor, $E(\boldsymbol{\epsilon}) = \mathbf{0}$ und $Cov(\boldsymbol{\epsilon}) = \sigma^2 \mathbf{I}$.

Für ϵ_i normalverteilt gilt $\mathbf{y} \sim N(\mathbf{X}\boldsymbol{\beta}, \sigma^2 \mathbf{I})$.

Die Regressionsgleichungen von drei einfachen linearen Regressionen sind

$$\hat{y} = 886.85 + 16.73 \cdot \log SO_2$$

$$\hat{y} = 887.06 + 4.49 \cdot \% \text{-Nichtweisse}$$

$$\hat{y} = 849.53 + 2.37 \cdot \text{Niederschlag}$$

$$\hat{y} = 776.22 + 16.9 \cdot \log SO_2 + 3.66 \cdot \% \text{-Nichtweisse} + 1.73 \cdot \text{Niederschlag}$$

Interpretation der Regressionskoeffizienten?

$\hat{\beta}_j$ gibt die Veränderung in y bei einem Anstieg von x_j um eine Einheit an, vorausgesetzt alle andern Variablen bleiben konstant.

Methode der kleinsten Quadrate

Gesucht sind $\hat{\beta}_0, \hat{\beta}_1, \dots, \hat{\beta}_p$ so, dass

$$Q = \sum_{i=1}^n r_i^2 = \sum_{i=1}^n (y_i - (\beta_0 + \beta_1 x_{i1} + \dots + \beta_p x_{ip}))^2 \text{ minimal wird.}$$

Normalgleichungen:

$$\begin{aligned} \frac{\partial Q}{\partial \beta_0} &= -2 \sum_{i=1}^n (y_i - (\beta_0 + \dots + \beta_p x_{ip})) = 0 & \mathbf{X}^t(\mathbf{y} - \mathbf{X}\hat{\boldsymbol{\beta}}) &= \mathbf{0} \\ \frac{\partial Q}{\partial \beta_1} &= -2 \sum_{i=1}^n (y_i - (\beta_0 + \dots + \beta_p x_{ip}))x_{i1} = 0 & \text{oder} & \\ \vdots & \vdots & & \\ \frac{\partial Q}{\partial \beta_p} &= -2 \sum_{i=1}^n (y_i - (\beta_0 + \dots + \beta_p x_{ip}))x_{ip} = 0 & \mathbf{X}^t\mathbf{X}\hat{\boldsymbol{\beta}} &= \mathbf{X}^t\mathbf{y} \end{aligned}$$

Least-Squares-Schätzungen:

$$\hat{\boldsymbol{\beta}} = (\mathbf{X}^t\mathbf{X})^{-1}\mathbf{X}^t\mathbf{y}$$

$E(\hat{\boldsymbol{\beta}}) = \boldsymbol{\beta}$ und $Cov(\hat{\boldsymbol{\beta}}) = \sigma^2(\mathbf{X}^t\mathbf{X})^{-1}$
mit Normalverteilung: $\hat{\boldsymbol{\beta}} \sim N(\boldsymbol{\beta}, \sigma^2(\mathbf{X}^t\mathbf{X})^{-1})$

Schätzung für σ^2 :

$$SSE = \sum r_i^2 = (\mathbf{y} - \hat{\mathbf{y}})^t(\mathbf{y} - \hat{\mathbf{y}}) \quad \hat{\sigma}^2 = \frac{SSE}{n - p - 1} = MSE$$

Geschätzte Werte und Residuen:

$$\hat{\mathbf{y}} = \mathbf{X}\hat{\boldsymbol{\beta}} = \mathbf{X}(\mathbf{X}^t\mathbf{X})^{-1}\mathbf{X}^t\mathbf{y} = \mathbf{H}\mathbf{y} \quad \mathbf{r} = \mathbf{y} - \hat{\mathbf{y}} = (\mathbf{I} - \mathbf{H})\mathbf{y} \quad \mathbf{H} \text{ heisst } \mathbf{Hat-Matrix}$$

7.2. Tests und Vertrauensintervalle

ANOVA-Tabelle:

Source	Sum of squares	df	Mean square	F^*
Regres	$SSR = \sum (\hat{y}_i - \bar{y})^2$	p	MSR	MSR/MSE
Resid	$SSE = \sum (y_i - \hat{y}_i)^2$	$n - 1 - p$	MSE	
Total	$SST = \sum (y_i - \bar{y})^2$	$n - 1$		

Globaler F-Test:

$$H_0 : \beta_1 = \beta_2 = \dots = \beta_p = 0 \quad \text{gegen} \quad H_A : \text{mindestens ein } \beta_j \neq 0$$

Testgrösse $F^* = MSR/MSE$ hat unter H_0 eine F-Verteilung mit p und $n - p - 1$ Freiheitsgraden. Verwerfe H_0 , wenn $F^* > F_{95\%, p, n-p-1}$.

Multiples Bestimmtheitsmass:

$$R^2 = \frac{SSR}{SST} = 1 - \frac{SSE}{SST} \quad adjR^2 = 1 - \left(\frac{n-1}{n-p-1} \right) \frac{SSE}{SST}$$

Tests von individuellen Parametern:

$$H_0 : \beta_j = 0 \quad \text{gegen} \quad H_A : \beta_j \neq 0$$

Teststatistik

$$t^* = \frac{\hat{\beta}_j}{se(\hat{\beta}_j)} = \frac{\hat{\beta}_j}{\hat{\sigma} \sqrt{(\mathbf{X}^t \mathbf{X})_{jj}^{-1}}}$$

hat unter H_0 eine t -Verteilung mit $n-p-1$ Freiheitsgraden. Verwerfe H_0 , wenn $|t^*| > t_{97.5\%, n-p-1}$.

$$95\% \text{-Vertrauensintervall für } \beta_j : \quad \hat{\beta}_j \pm t_{97.5\%, n-p-1} \cdot \hat{\sigma} \sqrt{(\mathbf{X}^t \mathbf{X})_{jj}^{-1}}$$

$$95\% \text{-Vertrauensintervall für } E(y_0) : \quad \hat{y}_0 \pm t_{97.5\%, n-p-1} \cdot \hat{\sigma} \sqrt{\mathbf{x}_0^t (\mathbf{X}^t \mathbf{X})^{-1} \mathbf{x}_0} \quad \text{wobei}$$

$$\mathbf{x}_0^t = (1 x_{01} x_{02} \cdots x_{0p})^t$$

$$95\% \text{-Prognoseintervall für eine zukünftige Beobachtung: } \hat{y}_0 \pm t_{97.5\%, n-p-1} \cdot \hat{\sigma} \sqrt{1 + \mathbf{x}_0^t (\mathbf{X}^t \mathbf{X})^{-1} \mathbf{x}_0}$$

Beispiel: Luftverschmutzungsstudie

Call: `lm(formula = mort ~ log(so2) + nonwhite + rain, data = smsa)`

Residuals:

Min	1Q	Median	3Q	Max
-75.9671	-25.0296	0.5792	20.7507	128.3527

Coefficients:

	Estimate	Std. Error	tvalue	Pr(> t)
(Intercept)	776.225	21.248	36.532	< 2e-16 ***
log(so2)	16.949	3.348	5.060	4.84e-06 ***
nonwhite	3.665	0.586	6.248	5.98e-08 ***
rain	1.732	0.456	3.796	0.000363 ***

Residual standard error: 38.17 on 56 df Multiple R-Squared: 0.6428,

Adjusted R-squared: 0.6237 F-statistic: 33.6 on 3 and 56 df, p-value: 1.48e-012

Modell mit allen sozialen und meteorolog. Variablen

jantemp	Mittlere Januar-Temperatur in Fahrenheit
julytemp	Mittlere Juli-Temperatur in Fahrenheit
relhum	Mittlere relative Luftfeuchtigkeit um 13 Uhr
rain	Mittlere jährl. Niederschlagsmenge in inches
educ	Median der absolvierten Schuljahre aller über 25jährigen
dens	Bevölkerungsdichte pro Quadratmeile

nonwhite	Anteil der nichtweissen Bevölkerung in %
wc	Anteil "white-collar worker" in %
pop	Bevölkerung
house	Mittlere Anzahl Personen pro Haushalt
income	Median des Einkommens

```
Call: lm(formula = mort ~ educ + jantemp +
julytemp + relhum + rain + dens + nonwhite +
wc + pop + house + income + log(so2),
data = smsa, na.action = na.omit)
```

Residuals:

Min	1Q	Median	3Q	Max
-70.915	-20.941	-2.773	18.859	105.931

Coefficients:

	Estimate	Std.Error	t value	Pr(> t)	
(Intercept)	1.16e+03	2.94e+02	3.96	0.00026	***
educ	-1.11e+01	9.45e+00	-1.17	0.24698	
jantemp	-1.67e+00	7.93e-01	-2.10	0.04079	*
julytemp	-1.17e+00	1.94e+00	-0.60	0.55021	
relhum	7.02e-01	1.11e+00	0.63	0.52864	
rain	1.22e+00	5.49e-01	2.23	0.03074	*
dens	5.62e-03	4.48e-03	1.25	0.21594	
nonwhite	5.08e+00	1.01e+00	5.02	8.3e-06	***
wc	-1.93e+00	1.26e+00	-1.52	0.13462	
pop	2.07e-06	4.05e-06	0.51	0.61180	
house	-2.22e+01	4.04e+01	-0.55	0.58607	
income	2.43e-04	1.33e-03	0.18	0.85562	
log(so2)	6.83e+00	5.43e+00	1.26	0.21426	

Residual standard error: 36.2 on 46 df

Multiple R-Squared: 0.733,

Adjusted R-squared: 0.664

F-statistic: 10.5 on 12 and 46 df,

p-value: 1.42e-009

Multicollinearität:

Sind x_1 und x_2 korreliert, dann ändern sich die geschätzten Koeffizienten, je nachdem welche Variablen im Modell sind. Es ist möglich, dass der globale F -Test signifikant ist und alle einzelnen t -Tests sind nicht signifikant.

Partielle F-Tests:

Effekt von $p - q$ Variablen gemeinsam testen. Partitioniere Parametervektor und Designmatrix :

$$\beta = \begin{bmatrix} \beta_1 \\ \beta_2 \end{bmatrix} = \begin{pmatrix} \beta_0 \\ \beta_1 \\ \vdots \\ \beta_q \\ \beta_{q+1} \\ \vdots \\ \beta_p \end{pmatrix} \quad \text{und} \quad \mathbf{X} = \begin{bmatrix} \mathbf{X}_1 & \mathbf{X}_2 \end{bmatrix},$$

Modell: $\mathbf{y} = \mathbf{X}\beta + \epsilon = \mathbf{X}_1\beta_1 + \mathbf{X}_2\beta_2 + \epsilon$

Teste auf $H_0 : \beta_2 = \mathbf{0}$ gegen $H_1 : \beta_2 \neq \mathbf{0}$

Testgrösse

$$F^* = \frac{(SSR_{H_1} - SSR_{H_0})/(p - q)}{SSE_{H_1}/(n - p - 1)}$$

hat unter H_0 eine F -Verteilung. Verwerfe H_0 , wenn $F^* > F_{95\%, p-q, n-p-1}$.

7.3. Modelldiagnostik

Residuenplot:

Normalplot der Residuen r_i

Residuen r_i gegen geschätzte y -Werte \hat{y}_i

Residuen r_i gegen eine erklärende Variable x_i des Modells

Residuen r_i gegen eine neue Variable x'_i , die nicht im Modell ist

Residuen r_i gegen den Index i

Ausreisser und einflussreiche Beobachtungen:

Ausreisser: Beobachtung mit grossem Residuum

einflussreiche Beobachtung: Beobachtung mit grossem Einfluss auf Parameterschätzungen

Hebelpunkt: Beobachtung mit extremen x -Werten

Leverages: Diagonalelemente h_{ii} der Hat-Matrix \mathbf{H} . Messen, wie extrem Beobachtungen bezüglich der x -Variablen sind. Es gilt $0 \leq h_{ii} \leq 1$. Hebelpunkte: $h_{ii} > 2(p + 1)/n$.

Gefährlich, wenn r_i und h_{ii} gross. Betrachte Plot r_i gegen h_{ii} .

Cook's Distanz:

$$D_i = \frac{\sum (\hat{y}_j - y_{j(i)})^2}{(p + 1)\hat{\sigma}^2} = \frac{h_{ii}}{1 - h_{ii}} \cdot \frac{r_i^{*2}}{p + 1}$$

$$r_i^* = \frac{r_i}{\hat{\sigma}\sqrt{1 - h_{ii}}} \quad \text{heisst studentisiertes Residuum}$$

Punkte mit $D_i > 1$ sollten genauer untersucht werden.

7.4. Modellwahl

Es gibt verschiedene Strategien, das „beste“ Modell zu finden und verschiedene Kriterien, was das „beste“ Modell ist. Meistens gibt es allerdings, gleich nach welchem Kriterium, nicht ein „bestes“ Modell, sondern mehrere gleich „gute“.

Strategien

Rückwärts-Elimination

Bei der Rückwärts-Elimination (backward elimination) beginnt man mit dem vollständigen Modell, d. h. mit allen zur Verfügung stehenden, erklärenden Variablen. Man eliminiert diejenige Variable mit dem kleinsten F -Wert, sofern dieser kleiner als eine vorgegebene Schranke von z. B. $F_{OUT} = 3$ ist. Dann berechnet man eine neue Regression und eliminiert die nächst unwichtigste Variable im Modell, bis keine Variable mehr einen F -Wert unterhalb der Schranke besitzt. Diese Strategie ist nur durchführbar, wenn die Anzahl vorhandener erklärender Variablen deutlich kleiner ist als die Anzahl Beobachtungen.

Vorwärts-Selektion

Bei der Vorwärts-Selektion (forward selection) beginnt man mit dem „leeren“ Modell (keine erklärende Variablen) und nimmt schrittweise jeweils die wichtigste, zusätzliche Variable in das Modell auf, solange diese eine vorgegebene Schranke von z. B. $F_{IN} = 3$ überschreitet. Die Vorwärtsselektion braucht viel weniger Rechenaufwand als die Rückwärtsmethode.

Schrittweise Regression

Die schrittweise Regression (stepwise regression) ist eine Kombination von Vorwärts- und Rückwärtsstrategie. Man beginnt vorwärts, überprüft nach jeder Aufnahme einer neuen Variable aber die F -Werte der anderen Variablen. Es ist also möglich, dass einmal aufgenommene Variablen wieder eliminiert werden, oder dass eliminierte Variablen später wieder aufgenommen werden.

„Alle Gleichungen“

Bei diesem Verfahren wird unter allen Regressionsmodellen mit den vorhandenen erklärenden Variablen das „beste“ gesucht (all subsets). Die Zahl der Modelle wächst mit der Anzahl Variablen allerdings ziemlich schnell an. Bsp: mit 10 Variablen gibt es $2^{10} = 1024$ Modelle. Intelligente Algorithmen ersparen es sich, alle Modelle durchzurechnen.

Gütekriterien

In Frage kommen die folgenden Größen:

1. Maximales Korrigiertes Bestimmtheitsmass :

$$adjR^2 = 1 - \frac{n-1}{n-p-1} (1 - R^2) = 1 - \frac{MSE}{MST}$$

2. Minimaler Mean Square Error:

$$MSE = \frac{SSE}{n-p-1}$$

3. Maximaler Wert der Teststatistik des globalen F -Tests:

$$F^* = \frac{MSR}{MSE}$$

4. Minimale **PRESS-Statistik** : Dieses Kriterium misst die Güte des Modells an seinem Vorhersagewert. Man rechnet das Regressionsmodell jeweils ohne die i -te Beobachtung und vergleicht dann den geschätzten Wert für die i -te Beobachtung mit dem tatsächlichen y -Wert.

Das i -te PRESS-Residuum ist definiert als

$$r_{i,-i} = y_i - \hat{y}_{i,-i}$$

mit dem geschätzten y -Wert für \mathbf{x}_i^t :

$$\hat{y}_{i,-i} = \mathbf{x}_i^t \boldsymbol{\beta}_{-i}.$$

$\boldsymbol{\beta}_{-i}$ bezeichnet die LS-Lösung ohne die i -te Beobachtung.

Führt man diese Berechnungen für jede Beobachtung aus (also n mal) und summiert die quadrierten PRESS-Residuen auf, so erhält man die PRESS-Statistik

$$\text{PRESS} = \sum_{i=1}^n (y_i - \hat{y}_{i,-i})^2 = \sum_{i=1}^n r_{i,-i}^2$$

Glücklicherweise ist es nicht nötig, alle n Regressionen durchzuführen, denn es gilt:

$$r_{i,-i} = \frac{r_i}{1 - h_{ii}}$$

Somit erhält man

$$\text{PRESS} = \sum_{i=1}^n \left(\frac{r_i}{1 - h_{ii}} \right)^2$$

Die PRESS-Statistik lässt sich also aus den gewöhnlichen Residuen r_i und den Leverages h_{ii} (Diagonalelementen der Hat-Matrix) berechnen.

5. Mallows C_q :

Die Statistik von Mallows ist gegeben durch

$$C_q = \frac{SSE_q}{\hat{\sigma}_f^2} - n + 2q$$

Dabei ist SSE_q das Fehlersummenquadrat des betrachteten Modells, q ist die Anzahl der Parameter des entsprechenden Modells ($q = p+1$), und $\hat{\sigma}_f^2$ ist die geschätzte Varianz unter dem vollen Modell mit allen erklärenden Variablen. Modelle mit C_q nahe bei q sind gute Kandidaten für die Modellwahl.

Für eine feste Anzahl von Variablen im Modell führen all diese Kriterien zum gleichen Ergebnis. Wenn hingegen Modelle miteinander verglichen werden mit einer unterschiedlichen Anzahl Variablen, dann können verschiedene „beste“ Modelle herauskommen. Es gibt eben auch nicht ein „bestes“ oder gar „richtiges“ Modell und alles andere ist schlechter oder falsch. Neben der automatisierten Suche aufgrund eines objektiven Kriteriums braucht es immer auch viel Fachwissen und subjektive Entscheidungen, um zu einem oder mehreren „geeigneten“ Modellen zu gelangen.

8. Versuchsplanung

Stufen einer Studie

1. Problem formulieren, in überprüfbare Hypothesen übersetzen
2. Information sammeln: Literatur, existierende Daten
3. Versuchsplanung
4. Daten sammeln und kontrollieren
5. Statistische Analyse
6. Interpretation

Versuchsplanung

- Wahl des Studientyps: beobachtend/experimentell
- Protokoll
 - Variablen (erklärende und Zielvariable)
 - Messinstrumente
 - Zielpopulation, Stichprobe
 - genauer Ablauf, Verantwortlichkeiten
 - Vorgehen bei Protokollabweichungen
- Pilotstudie
 - Reliabilität
 - Management
- Design
 - Block Design, Faktorieller Versuchsplan, Split-plot Design
 - Studiengrösse

Studientypen

- experimentell: Versuchseinheiten, -personen werden verschiedenen Behandlungen (treatments) zugeteilt. "Behandlung" umfasst alles, was kontrolliert werden kann, die gesamten Versuchsbedingungen. Bsp: Interventionsstudie, klinische Studie.
- beobachtend: Kein Einfluss auf die Gruppenzuteilung, keine Kontrolle der erklärenden Variablen. Bsp: epidemiologische Studie.
 - Umfrage (survey)
 - Fall-Kontroll-Studie (case-control study): Vergleich der Häufigkeiten des Auftretens eines Risikofaktors bei kranken und bei gesunden Personen.
 - Kohortenstudie (cohort study): Vergleich der Häufigkeiten des Auftretens von Krankheiten bei Personen mit/ohne Risikofaktor.

Randomisierte, kontrollierte Studien

Goldstandard für experimentelle Studien sind randomisierte, kontrollierte Studien (RCT): die Versuchseinheiten werden zufällig der Behandlungs- oder der Kontrollgruppe zugeteilt und die Studie ist, wo möglich, doppelblind, d. h. weder Versuchspersonen noch ExperimentatorInnen wissen, wer in welcher Gruppe ist.

9. Varianzanalyse

Beispiel: Postoperative Zahnschmerzen

Eine Anaesthesistin untersuchte in einer Doppel-Blind-Studie die Wirksamkeit von vier verschiedenen Behandlungen gegen Zahnschmerzen nach einem chirurgischen Eingriff. Die vier Behandlungen waren:

- I: Codein und Akupunktur
- II: nur Akupunktur (und Zuckerkapsel)
- III: nur Codein (und „Scheinakupunktur“)
- IV: Placebo (Zuckerkapsel und „Scheinakupunktur“)

40 Patienten, alles Männer im Alter zwischen 18 und 30 Jahren, wurden mittels Randomisierung den vier Gruppen zugeteilt. Für jede Person wurde ein Schmerz-Intensitäts-Index erhoben, sowohl vor der Zahnbehandlung als auch 2 Stunden danach. Zielvariable war die Differenz zwischen „vorher“ und „nachher“. Die Daten sind:

Behandlung	Einzelwerte									
I	3.1	2.7	1.6	1.3	1.0	0.8	2.5	1.7	1.1	0.9
II	0.6	1.3	0.3	1.5	0.0	0.4	2.0	1.3	0.2	0.8
III	2.1	1.6	0.8	0.5	0.3	0.0	1.0	1.4	-0.2	0.6
IV	1.8	0.0	-1.8	-1.6	1.7	-1.6	1.2	0.3	0.0	-0.7

Idee der Varianzanalyse

$$\boxed{\text{Gesamtvariabilität der Beobachtungen}} = \boxed{\text{Variationsursache 1}} + \boxed{\text{Variationsursache 2}} + \boxed{\text{Variationsursache 3}} + \dots$$

Begriffe

Faktor: diskrete, erklärende Variable

Levels: Werte, die der Faktor annimmt

Ein-Weg-Varianzanalyse: Einfluss eines Faktors wird untersucht

Zwei-Weg-Varianzanalyse: Einfluss von zwei Faktoren wird untersucht

Treatment: Faktorkombination

Plot, experimentelle Einheit: kleinste Einheit, die einem Treatment zugeteilt werden kann.

9.1. Ein-Weg-Varianzanalyse

Modell:

$$y_{ij} = \mu + A_i + \epsilon_{ij}, \quad \text{wobei } \sum A_i = 0$$

y_{ij} ist die Messung für Person j mit Treatment i , $j = 1, \dots, J$; $i = 1, \dots, I$,

μ ist das Gesamtmittel,

A_i ist der Effekt des i -ten Levels von Faktor A, bzw. die Abweichung der Gruppe i vom Gesamtmittel und

ϵ_{ij} ist ein zufälliger „Fehler“ oder Rest, über den folgendes vorausgesetzt wird:

- 1) $E(\epsilon_{ij}) = 0$ für alle i und j
- 2) die ϵ_{ij} sind unabhängig und haben alle die gleiche Varianz σ^2
- 3) die ϵ_{ij} sind normalverteilt

Varianzanalyse-Grundgleichung

$$\underbrace{\sum_i \sum_j (y_{ij} - y_{..})^2}_{\text{Gesamtvariabilität}} = \underbrace{\sum_i \sum_j (y_{i.} - y_{..})^2}_{\text{Variabilität zwischen den Gruppen}} + \underbrace{\sum_i \sum_j (y_{ij} - y_{i.})^2}_{\text{Variabilität innerhalb der Gruppen}}$$

$$\begin{array}{lclcl} \text{total sum of squares} & = & \text{treatment sum of squares} & + & \text{residual sum of squares} \\ SS_{tot} & = & SS_{treat} & + & SS_{res} \end{array}$$

$$\begin{array}{lclcl} N-1 & = & I-1 & + & N-I \\ df_{tot} & = & df_{treat} & + & df_{res} \end{array}$$

Total mean square: $MS_{tot} = SS_{tot}/(N - 1)$

Residual mean square: $MS_{res} = SS_{res}/I(J - 1) = \hat{\sigma}^2$, $E(MS_{res}) = \sigma^2$

Treatment mean square: $MS_{treat} = SS_{treat}/(I - 1)$, $E(MS_{treat}) = \sigma^2 + \sum JA_i^2/(I - 1)$

Anova-Tabelle

Source	SS	df	MS	F	P-Value
Treatment	$\sum_i \sum_j (y_{i.} - y_{..})^2$	I-1	MS_{treat}	MS_{treat}/MS_{res}	$P_{H_0}(F > F^*)$
Residuals	$\sum_i \sum_j (y_{ij} - y_{i.})^2$	N-I	MS_{res}		
Total	$\sum_i \sum_j (y_{ij} - y_{..})^2$	N-1			

Tests und Parameterschätzungen

F-Test

H_0 : alle $A_i = 0$, H_A : mindestens ein $A_i \neq 0$

Wenn die ϵ_{ij} normalverteilt sind, dann ist $F = MS_{treat}/MS_{res}$ unter H_0 F -verteilt mit $I - 1$ und $N - I$ Freiheitsgraden. Verwerfe H_0 , falls $F > F_{95\%, I-1, N-I}$.

Effekt Modell: $y_{ij} = \mu + A_i + \epsilon_{ij}$, $\sum A_i = 0$

Schätzungen: $\hat{\mu} = y_{..}$, $\hat{\mu} + \hat{A}_i = y_{i.}$, $\hat{A}_i = y_{i.} - y_{..}$

Voraussage: $\hat{y}_{ij} = \hat{\mu} + \hat{A}_i = y_{i.}$, Residuum: $\hat{\epsilon}_{ij} = y_{ij} - y_{i.}$

Mean Modell: $y_{ij} = \mu_i + \epsilon_{ij}$, $\hat{\mu}_i = y_{i.}$

Effekt Modell mit anderer Nebenbedingung: $y_{ij} = \mu + A_i + \epsilon_{ij}$, $A_1 = 0$

$\hat{\mu} = y_{1.}$, $\hat{A}_i = y_{i.} - y_{1.}$

Treatmentvergleiche

Treatmentunterschied $A_i - A_{i'}$ wird geschätzt durch $y_{i.} - y_{i'.$, mit Standardfehler $\sqrt{\sigma^2(1/J + 1/J)} = \sqrt{2\sigma^2/J}$, geschätzt durch $\sqrt{2MS_{res}/J}$.

Multiple Vergleiche

Ein Kontrast C ist eine Linearkombination von Effekten: $C = \sum_{i=1}^I \lambda_i A_i$ mit $\sum \lambda_i = 0$ und wird durch $\hat{C} = \sum \lambda_i y_i$ geschätzt.

Zwei Kontraste $C_1 = \sum \lambda_i A_i$ und $C_2 = \sum \lambda'_i A_i$ heißen **orthogonal**, wenn $\sum \lambda_i \lambda'_i = 0$. Die entsprechenden Schätzungen sind dann unkorreliert. Es gibt $I-1$ orthogonale Kontraste.

n geplante, orthog. Kontraste Bonferroni (-Holm) Signifikanzniveau α/n
 ($n \leq I-1$)

alle Paarvergleiche Tukey: krit. Werte für die Verteilung von $\max |y_i - y_{i'}|$

komplexe nichtorthogonale oder Scheffé: krit. Wert $\sqrt{(I-1)F_{I-1, N-I, 95\%}}$
 komplexe ungeplante Vergleiche

9.2. Vollständiges Blockdesign

Jedes Treatment kommt in jedem Block gleich oft vor.

Modell: $y_{ij} = \mu + A_i + b_j + \epsilon_{ij}$, b_j : Effekt des Blocks j .

Fixed-Effects Model / Modell I $\sum A_i = 0, \sum b_j = 0, \epsilon_{ij} \sim \mathcal{N}(0, \sigma^2)$
 Mixed Model / Modell III $\sum A_i = 0, b_j \sim \mathcal{N}(0, \sigma_b^2), \epsilon_{ij} \sim \mathcal{N}(0, \sigma_e^2)$,
 alle b_j und ϵ_{ij} unabhängig
 Random-Effects Model / Modell II alle Faktoren haben zufällige Effekte

Anova-Tabelle:

Source	SS	df	MS	F
Blocks	...	$J-1$...	
Treatments	...	$I-1$
Residual	...	$(I-1)(J-1)$...	
Total	...	$N-1$		

9.3. Multi-Faktor-Experimente

2-Weg-Varianzanalyse

Modell:

$$y_{ijk} = \mu + A_i + B_j + (AB)_{ij} + \epsilon_{ijk}, \quad i = 1, \dots, I; j = 1, \dots, J; k = 1, \dots, K.$$

mit den Nebenbedingungen: $\sum A_i = 0, \sum B_j = 0, \sum_i (AB)_{ij} = 0, \sum_j (AB)_{ij} = 0$.

y_{ijk} ist die k -te Beobachtung mit Faktor A auf Level i und Faktor B auf Level j , μ ist das Gesamtmittel, A_i ist der Haupteffekt des i -ten Levels des Faktors A , B_j ist der Haupteffekt des j -ten Levels des Faktors B , $(AB)_{ij}$ ist die Interaktion des i -ten Levels von A mit dem j -ten Level von B und ϵ_{ijk} ist der zufällige Rest mit $\epsilon \sim \mathcal{N}(\mathbf{0}, \sigma^2 \mathbf{I})$.

Zerlegung der Gesamtvariabilität: $SS_{tot} = SS_A + SS_B + SS_{AB} + SS_{res}$

$$SS_{tot} = \sum \sum \sum (y_{ijk} - y_{...})^2 \quad SS_A = \sum \sum \sum (y_{i..} - y_{...})^2 \quad SS_B = \sum \sum \sum (y_{.j.} - y_{...})^2$$

$$SS_{AB} = \sum \sum \sum (y_{ij.} - y_{i..} - y_{.j.} + y_{...})^2 \quad SS_{res} = \text{«Differenz»}$$

Ein Faktor mit I Levels hat $I-1$, eine Interaktion zwischen zwei Faktoren mit I und J Levels hat $(I-1)(J-1)$ Freiheitsgrade.

Anova-Tabelle

Source	SS	df	MS	F	P-Wert
A		$I - 1$		MS_A/MS_{res}	
B		$J - 1$		MS_B/MS_{res}	
AB		$(I - 1)(J - 1)$		MS_{AB}/MS_{res}	
Residual		«Differenz»			
Total		$IJK - 1$			

Modell mit zufälligen Effekten (Modell II)

$$y_{ijk} = \mu + a_i + b_j + \epsilon_{ijk}, \quad i = 1, \dots, I; j = 1, \dots, J; k = 1, \dots, K.$$

μ ist das Gesamtmittel,

a_i ist der zufällige Effekt von Faktor a, $a_i \sim \mathcal{N}(0, \sigma_a^2)$,

b_j ist der zufällige Effekt von Faktor b, $b_j \sim \mathcal{N}(0, \sigma_b^2)$,

ϵ_{ijk} ist der zufällige Rest, $\epsilon_i \sim \mathcal{N}(0, \sigma_e^2)$, die a_i , b_j und ϵ_{ijk} sind alle unabhängig.

Schätzungen:

$$\hat{\sigma}_e^2 = MS_{res}$$

$$\hat{\sigma}_a^2 = (MS_a - MS_{res})/JK$$

$$\hat{\sigma}_b^2 = (MS_b - MS_{res})/IK$$

A. Matrizen und Vektoren

A.1. Definition

Eine Matrix ist eine rechteckige Anordnung von Zahlen in Zeilen und Spalten.

$$\mathbf{A} = \begin{pmatrix} a_{11} & a_{12} & \dots & a_{1m} \\ a_{21} & a_{22} & \dots & a_{2m} \\ \vdots & \vdots & \ddots & \vdots \\ a_{n1} & a_{n2} & \dots & a_{nm} \end{pmatrix}$$

Die Dimension von \mathbf{A} ist $\dim \mathbf{A} = n \times m$ (Anzahl Zeilen \times Anzahl Spalten)

a_{ij} : Element in der i -ten Zeile und j -ten Spalte von \mathbf{A}

Transponierte Matrix von \mathbf{A} :

$$\mathbf{A}^t = \begin{pmatrix} a_{11} & a_{21} & \dots & a_{n1} \\ a_{12} & a_{22} & \dots & a_{n2} \\ \vdots & \vdots & \ddots & \vdots \\ a_{1m} & a_{2m} & \dots & a_{nm} \end{pmatrix}$$

Spezialfälle:

Eine Matrix der Dimension 1×1 ist eine Zahl (Skalar). Eine quadratische Matrix hat gleichviele Spalten wie Zeilen.

Eine Matrix, die nur aus einer Spalte besteht, ist ein Vektor.

Wenn $\mathbf{A} = \mathbf{A}^t$, so heisst \mathbf{A} symmetrisch.

Eine Diagonalmatrix ist symmetrisch und alle Elemente ausserhalb der Diagonalen sind 0.

Die Einheitsmatrix \mathbf{I} ist diagonal mit lauter Einsen in der Diagonale.

A.2. Rechnen mit Matrizen

Addition und Subtraktion von zwei Matrizen und die Multiplikation einer Matrix mit einem Skalar geschieht elementweise.

Multiplikation zweier Matrizen:

$$\mathbf{A} = \begin{pmatrix} 2 & 3 \\ 4 & 1 \end{pmatrix} \quad \mathbf{B} = \begin{pmatrix} 1 & 4 & 6 \\ 1 & 5 & 8 \end{pmatrix}$$

$$\left(\begin{array}{|c|c|} \hline 2 & 3 \\ \hline 4 & 1 \\ \hline \end{array} \right) \cdot \left(\begin{array}{|c|c|c|} \hline 1 & 4 & 6 \\ \hline 1 & 5 & 8 \\ \hline \end{array} \right) = \left(\begin{array}{ccc} 5 & \cdot & \cdot \\ \cdot & \cdot & \cdot \end{array} \right)$$

$2 \cdot 1 + 3 \cdot 1 = 5$

Einfaches lineares Regressionsmodell $y = \mathbf{X}\beta + \epsilon$

mit

$$\mathbf{y} = \begin{pmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{pmatrix} \quad \mathbf{X} = \begin{pmatrix} 1 & x_1 \\ 1 & x_2 \\ \vdots & \vdots \\ 1 & x_n \end{pmatrix} \quad \beta = \begin{pmatrix} \beta_0 \\ \beta_1 \end{pmatrix} \quad \text{und} \quad \epsilon = \begin{pmatrix} \epsilon_1 \\ \epsilon_2 \\ \vdots \\ \epsilon_n \end{pmatrix}$$

A.3. Lineare Unabhängigkeit und inverse Matrizen

Eine Menge von Vektoren heisst **linear unabhängig**, wenn keine der Spalten als Linearkombination der übrigen geschrieben werden kann.

Das **Inverse** \mathbf{A}^{-1} einer Matrix \mathbf{A} ist :

$$\mathbf{A}^{-1} \cdot \mathbf{A} = \mathbf{A} \cdot \mathbf{A}^{-1} = \mathbf{I}$$

Nicht jede Matrix ist invertierbar.

Ein Inverses existiert genau dann, wenn alle Spalten, resp. Zeilen linear unabhängig sind.

A.4. Zufallsvektoren und Kovarianzmatrizen

Ein Zufallsvektor ist ein Vektor aus Zufallsvariablen Y_1, Y_2, \dots, Y_n :

$$\mathbf{Y} = \begin{pmatrix} Y_1 \\ Y_2 \\ \vdots \\ Y_n \end{pmatrix}$$

Erwartungswert

$$E(\mathbf{Y}) = \begin{pmatrix} E(Y_1) \\ E(Y_2) \\ \vdots \\ E(Y_n) \end{pmatrix}$$

Kovarianzmatrix

$$Cov(\mathbf{Y}) = \begin{pmatrix} VarY_1 & Cov(Y_1, Y_2) & Cov(Y_1, Y_3) & \cdots & Cov(Y_1, Y_n) \\ Cov(Y_1, Y_2) & VarY_2 & Cov(Y_2, Y_3) & \cdots & Cov(Y_2, Y_n) \\ Cov(Y_1, Y_3) & Cov(Y_2, Y_3) & Var(Y_3) & \cdots & Cov(Y_3, Y_n) \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ Cov(Y_1, Y_n) & Cov(Y_2, Y_n) & Cov(Y_3, Y_n) & \cdots & VarY_n \end{pmatrix}$$

Rechenregeln:

$$\begin{aligned} E(\mathbf{a} + \mathbf{B} \cdot \mathbf{Y}) &= \mathbf{a} + \mathbf{B} \cdot E(\mathbf{Y}) \\ Cov(\mathbf{a} + \mathbf{B} \cdot \mathbf{Y}) &= \mathbf{B} \cdot Cov(\mathbf{Y}) \cdot \mathbf{B}^t \end{aligned}$$

Mehrdimensionale Verteilungen

Die Wahrscheinlichkeitsverteilung eines Zufallsvektors ist die gemeinsame Verteilung der einzelnen Variablen. Am häufigsten benutzt wird die multivariate Normalverteilung. Was




Abbildung A.1.: Bivariate Normalverteilungen mit $\rho = 0$

man sich unter einer zweidimensionalen, sogenannte bivariaten Normalverteilung vorstellen soll, zeigen die Abbildungen A.1 und A.2.

X und Y , wie auch U und V haben univariate Normalverteilungen. Daneben bestimmt die Korrelation zwischen den Variablen die genaue Form der gemeinsamen Verteilung. Je grösser die Korrelation ρ , desto enger werden die elliptischen Kontourlinien (Punkte mit gleicher Dichte).

Eine bivariate Normalverteilung wird demnach durch fünf Parameter festgelegt: $\mu_x, \sigma_x^2, \mu_y, \sigma_y^2, \rho_{xy}$. Für eine 3-dimensionale Normalverteilung braucht es schon 9 Parameter und die Liste wird länger und länger mit wachsender Dimension. Benutzt man die Matrixnotation, so genügt die Angabe des Vektors der Erwartungswerte und der Kovarianzmatrix.

Also zum Beispiel:

$$\mathbf{Z} \sim N(\boldsymbol{\mu}, Cov(\mathbf{Z}))$$

mit

$$\mathbf{Z} = \begin{pmatrix} X \\ Y \end{pmatrix}, \quad \boldsymbol{\mu} = \begin{pmatrix} \mu_x \\ \mu_y \end{pmatrix} \quad \text{und} \quad Cov(\mathbf{Z}) = \begin{pmatrix} \sigma_x^2 & \rho\sigma_x\sigma_y \\ \rho\sigma_x\sigma_y & \sigma_y^2 \end{pmatrix}$$





Abbildung A.2.: Bivariate Normalverteilungen mit $\rho = 0.6$