

Stochastik für die Informatik, Vorlesung 17

Inhalt

- ▶ Maximum Likelihood Schätzung
- ▶ Lineare Regression
- ▶ Simulation von Zufallsvariablen

Lernziele

- ▶ Maximum Likelihood Schätzer berechnen können
- ▶ Die Grundprinzipien der linearen Regression kennen
- ▶ Simulationsmethoden kennen

Vorkenntnisse Differentialrechnung, Logarithmengesetze, lineare Gleichungssysteme, Zufallsvariablen, Verteilungsfunktion

Maximum Likelihood Schätzung (MLE)

Grundidee: Gegeben Daten x_1, \dots, x_n einer Verteilung mit einem unbekanntem Parameter. Unter allen (theoretisch möglichen) Werten des Parameters ist der Maximum Likelihood-Schätzer derjenige, für welchen die Wahrscheinlichkeit, die gemessenen Werte x_1, \dots, x_n zu finden maximal wird.

Wir betrachten zwei verschiedene Situationen:

- ▶ Die zugrundeliegenden Zufallsvariablen X_1, \dots, X_n sind diskret, und haben Verteilung p_θ in Abhängigkeit von einem unbekanntem Parameter θ
- ▶ Die zugrundeliegenden Zufallsvariablen X_1, \dots, X_n haben Dichte f_θ in Abhängigkeit von einem unbekanntem Parameter θ .

Maximum Likelihood Schätzung (MLE)

Beispiel: Diskrete Verteilung

- ▶ Gegeben: (x_1, \dots, x_n)
- ▶ Annahme: Dies sind Realisierungen von n unabhängigen identisch verteilten Zufallsvariablen X_1, \dots, X_n mit unbekanntem Parameter θ .
- ▶ Sei $p_\theta(x)$ die **Verteilung** der X_1, \dots, X_n , mit unbekanntem θ .
- ▶ Betrachte

$$\mathbb{P}_\theta(X_1 = x_1, \dots, X_n = x_n) = p_\theta(x_1) \cdot \dots \cdot p_\theta(x_n).$$

Grundidee:

- ▶ Bestimme θ so, dass diese Wahrscheinlichkeit für das vorgegebene $x = (x_1, \dots, x_n)$ **maximal** ist (z.B. durch Ableiten).
- ▶ (Beispiel 8.8)

Maximum Likelihood Schätzung (MLE)

Beispiel: Diskrete Verteilung

- ▶ Gegeben: (x_1, \dots, x_n)
- ▶ Annahme: Dies sind Realisierungen von n unabhängigen identisch verteilten Zufallsvariablen X_1, \dots, X_n mit unbekanntem Parameter θ .
- ▶ Sei $p_\theta(x)$ die **Verteilung** der X_1, \dots, X_n , mit unbekanntem θ .
- ▶ Betrachte

$$\mathbb{P}_\theta(X_1 = x_1, \dots, X_n = x_n) = p_\theta(x_1) \cdot \dots \cdot p_\theta(x_n).$$

Grundidee:

- ▶ Bestimme θ so, dass diese Wahrscheinlichkeit für das vorgegebene $x = (x_1, \dots, x_n)$ **maximal** ist (z.B. durch Ableiten).
- ▶ (Beispiel 8.8)

Likelihood-Funktion

(Def. 8.9) Seien $x_1, \dots, x_n \in \mathbb{R}$ Messwerte, welche als Realisierungen von unabhängigen, identisch verteilten Zufallsvariablen X_1, \dots, X_n aufgefasst werden können. Die **Likelihood-Funktion** ist die Funktion $L((x_1, \dots, x_n); \theta)$ von $\mathbb{R}^n \times \mathbb{R}$ nach $[0, 1]$, für welche gilt:

- ▶ Falls die X_i eine diskrete Verteilung p_θ mit Parameter θ besitzt, so ist

$$L((x_1, \dots, x_n); \theta) = p_\theta(x_1) \cdot \dots \cdot p_\theta(x_n) = \prod_{i=1}^n p_\theta(x_i).$$

- ▶ Falls die X_i eine Dichte f_θ mit Parameter θ besitzt, so ist

$$L((x_1, \dots, x_n); \theta) = f_\theta(x_1) \cdot \dots \cdot f_\theta(x_n) = \prod_{i=1}^n f_\theta(x_i).$$

Maximum Likelihood Schätzung (MLE)

(Def. 8.10) Seien x_1, \dots, x_n Messwerte, welche Realisierungen von unabhängigen, identisch verteilten Zufallsvariablen sind, welche entweder der diskreten Verteilung p_θ folgen, oder die Dichte f_θ haben. Der **Maximum Likelihood-Schätzer** für θ ist $\theta_* = \theta_*(x_1, \dots, x_n)$, welches die Likelihood-Funktion $L((x_1, \dots, x_n); \theta)$ unter allen $\theta \in \mathbb{R}$ maximiert. Formal gesprochen ist

$$\theta_*(x_1, \dots, x_n) = \operatorname{argmax}_{\theta \in \mathbb{R}} L((x_1, \dots, x_n); \theta).$$

- ▶ Der Maximum Likelihood-Schätzer wird dabei manchmal auch kurz als MLE bezeichnet, für das englische “maximum likelihood estimator”.

Log-likelihood

(Def. 8.11) Die **Log-Likelihood-Funktion** ist definiert als

$$l((x_1, \dots, x_n); \theta) = \ln L((x_1, \dots, x_n); \theta).$$

(Satz 8.24) Die Funktion $l((x_1, \dots, x_n); \theta)$ ist genau dann maximal (in θ), wenn $L((x_1, \dots, x_n); \theta)$ maximal ist.

- ▶ $l(x_1, \dots, x_n; \theta)$ ist oft einfacher zu maximieren als $L(x_1, \dots, x_n; \theta)$.


Maximum Likelihood Schätzung: Vorgehen

Das allgemeine Vorgehen zur Bestimmung des MLE wird somit:

1. Likelihood-Funktion $L(x_1, \dots, x_n; \theta)$ aufstellen (nach Definition 10.8), abhängig davon ob die Verteilung diskret ist oder eine Dichte besitzt
2. Die log-Likelihood-Funktion $l(x_1, \dots, x_n; \theta)$ durch logarithmieren von $L(x_1, \dots, x_n; \theta)$ berechnen und so weit wie möglich vereinfachen (Logarithmengesetze!)
3. Den Parameter θ so bestimmen, dass $l((x_1, \dots, x_n); \theta)$ für das vorgegebene $x = (x_1, \dots, x_n)$ maximal ist. Meistens geschieht das durch Ableiten nach θ .
4. Überprüfen, dass es sich beim Ergebnis tatsächlich um ein Maximum handelt (z.B. durch Test mit der 2. Ableitung).

(Beispiel 8.9)

Beispiel 8.10: Korrelationen zwischen Daten




- ▶ Daten von zwei gleichzeitig gemessenen Größen: **Paare von Messwerten** $(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)$.
- ▶ Grundannahme: Realisierungen zweier Zufallsvariablen X und Y .

Maß für den Grad der Abhängigkeit?

Linearer Zusammenhang

Beispiel Geysir: Daten $(x_i, y_i)_{i=1, \dots, n}$ ergeben eine **Punktwolke** im \mathbb{R}^2 .

Rotes Quadrat: **Schwerpunkt** $(\bar{\mu}_x, \bar{\mu}_y)$.



Korrelationen zwischen Daten

(Def. 8.12) Seien $x = (x_1, \dots, x_n)$ und $y = (y_1, \dots, y_n)$ gegeben. Die **empirische Kovarianz** ist definiert als

$$c_{xy} := \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{\mu}_x)(y_i - \bar{\mu}_y),$$

wobei $\bar{\mu}_x$ das empirische Mittel der x_i und $\bar{\mu}_y$ das empirische Mittel der y_i ist.

Der empirische **Korrelationskoeffizient** ist definiert als

$$r_{xy} = \frac{c_{xy}}{\bar{\sigma}_x \bar{\sigma}_y},$$






wobei $\bar{\sigma}_x = \sqrt{\bar{\sigma}_x^2}$ die empirische Standardabweichung von x ist (und analog $\bar{\sigma}_y$ für y).

- ▶ $-1 \leq r_{x,y} \leq 1$,
- ▶ Beispiel 8.11: Im Beispieldatensatz:

$$c_{x,y} = \text{cov}(x,y) = 13.97781, \quad r_{x,y} = \text{cor}(x,y) = 0.9008112.$$

Linearer Zusammenhang ($\rho = r$)


(Quelle: Wikipedia)



Lineare Regression

Grundidee: Finde die Gerade $y = ax + b$, welche durch den Punkt $(\bar{\mu}_x, \bar{\mu}_y)$ verläuft, und welche die **Abstände** der Punkte von der Geraden **minimiert**.

- ▶ Meistens: Summe der quadratischen Abstände in y -Richtung minimieren



Lineare Regression

Gegeben: $x = (x_1, \dots, x_n), y = (y_1, \dots, y_n)$

Gesucht: Die Zahlen $a, b \in \mathbb{R}$, so dass die Gerade mit der Gleichung

$$y = ax + b$$

zwei Bedingungen erfüllt:

- ▶ $(\bar{\mu}_x, \bar{\mu}_y)$ liegt auf der Geraden, also $\bar{\mu}_y = a \cdot \bar{\mu}_x + b$,
- ▶ Der Ausdruck

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

ist minimal, wobei $\hat{y}_i := ax_i + b$ die y -Koordinaten des Punktes auf der Geraden ist, welcher x -Koordinate x_i hat.

Lineare Regression

(Satz 8.2) Die beiden Bedingungen auf der vorigen Folie legen a und b eindeutig fest, und zwar als

$$a = \frac{c_{xy}}{\bar{\sigma}_x^2}, \quad b = \bar{\mu}_y - a \cdot \bar{\mu}_x.$$

- ▶ Rollen von x und y sind nicht symmetrisch!
- ▶ (Beweis)

Beispiel 8.12: Lineare Regression

R-Befehl: `lm(y ~ x)`

`> reg<-lm(y x)`

`> summary(reg)`

Ausgabe:

```
Call:
lm(formula = y ~ x)

Residuals:
    Min       1Q   Median       3Q      Max
-12.0796  -4.4831   0.2122   3.9246  15.9719

Coefficients:
            Estimate Std. Error t value Pr(>|t|)
(Intercept)  33.4744     1.1549   28.98  <2e-16 ***
x            10.7296     0.3148   34.09  <2e-16 ***
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1


Residual standard error: 5.914 on 270 degrees of freedom
Multiple R-squared:  0.8115, Adjusted R-squared:  0.8108
F-statistic: 1162 on 1 and 270 DF,  p-value: < 2.2e-16
```

Parameter: $a = 10.7296$, $b = 33.4744$


Andere Angaben: Informationen über Fehler/Güte des Fit

Beispiel 8.20

Plot:



Linearer Zusammenhang oder nicht?



Einteilung in zwei Cluster z.B. mittels [EM-Algorithmus](#), basierend auf der Maximum-Likelihood-Schätzung. Statische Methode der [Clusteranalyse](#).

Kapitel 15: Simulation von Zufallsvariablen

(Satz 15.1) Sei X uniform auf $[0, 1]$ verteilt. Sei F eine invertierbare Verteilungsfunktion. Dann ist

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

eine Zufallsvariable mit Verteilungsfunktion F .

Anwendung dieses Satzes: Simulation von Zufallsvariablen: Sobald man eine auf $[0, 1]$ –gleichverteilte Zufallsvariable simulieren kann, kann man im Prinzip jede Zufallsvariable mit bekannter (invertierbarer) Verteilungsfunktion simulieren (also z.B. Exponentialverteilung).

- ▶ Diskrete Verteilungen, Normalverteilung?
- ▶ und wie simuliert man eine $[0, 1]$ –gleichverteilte Zufallsvariable?

Bernoulli aus gleichverteilt

(Satz 15.1) Sei U eine auf $[0, 1]$ gleichverteilte Zufallsvariable. Sei $p \in (0, 1)$. Dann ist

$$X(U) := 1_{\{U \leq p\}}$$

eine Bernoulli-verteilte Zufallsvariable mit Parameter p .

- ▶ (Beweis)
- ▶ (15.1, 15.2)

Normal aus gleichverteilt

(Beispiel 15.3) Seien U und V unabhängige, auf $[0, 1]$ gleichverteilte Zufallsvariablen. Dann sind

$$(X, Y) := \sqrt{-2 \log U} (\cos(2\pi V), \sin(2\pi V))$$

zwei unabhängige, standardnormalverteilte Zufallsvariablen.

- ▶ Box-Muller-Methode
- ▶ (ohne Beweis)
- ▶ Bem. allgemeine Normalverteilung

Pseudozufallszahlen

(Def. 15.1) Ein **Pseudozufallszahlengenerator** ist ein Algorithmus welcher ausgehend von einem Startwert eine **deterministische** Folge von Zahlen erzeugt, welche sich “wie eine Realisierung einer Folge von (uniform auf $[0, 1]$ verteilten) Zufallsvariablen” verhält.

- ▶ Überprüfung des zufälligen Verhaltens mit Hilfe von statistischen Tests, z.B. χ^2 -Test auf uniforme Verteilung
- ▶ “Echte” Zufallszahlen: Mit Hilfe physikalischer Generatoren, z.B. durch Beobachtung radioaktiver Zerfälle, kosmisches Rauschen...

Pseudozufallszahlen

Beispiel 15.4: Der lineare Kongruenzgenerator

- ▶ Wähle Parameter $m \in \mathbb{N}$, $a \in \mathbb{Z} \setminus \{0\}$, $c \in \mathbb{Z}$.
- ▶ Wähle einen Startwert $x_0 \in \{0, \dots, m\}$
- ▶ Definiere **rekursiv**

$$x_n := (ax_{n-1} + c) \bmod m$$

- ▶ Definiere für $n \in \mathbb{N}$

$$u_n := \frac{x_n}{m}$$

- ▶ Dann ist die Folge $(u_n)_{n \in \mathbb{N}_0}$ eine Folge von Pseudozufallszahlen (uniform auf $[0, 1]$).

Pseudozufallszahlen

Beispiel 15.4: Der lineare Kongruenzgenerator

Eigenschaften:

- ▶ Damit können höchstens m verschiedene Zahlen erzeugt werden
- ▶ Die erzeugte Folge ist periodisch
- ▶ Entsprechend sollte m **möglichst groß** gewählt werden, auf jeden Fall deutlich größer als die Anzahl zu erzeugender Zufallszahlen
- ▶ Wahl von a nach zahlentheoretischen Überlegungen
- ▶ **Wahl des Startwerts** kann große Auswirkung auf die erzeugte Folge haben, deshalb ist die Methode geeignet um Zufallszahlen zu erzeugen.
- ▶ Reproduzierbarkeit durch Wahl des Startwerts gegeben


Pseudozufallszahlen

Das Software-Paket R bietet die Auswahl aus verschiedenen Pseudozufallszahlen-Generatoren, der Standard ist der sogenannte **Mersenne-Twister** (welcher ebenfalls ein rekursives Verfahren benutzt).

- ▶ Befehl: `runif`
- ▶ `runif(n)`: Vektor von n unabhängigen uniform $[0, 1]$ verteilten Zufallszahlen
- ▶ `runif(n, a, b)` : Vektor von n unabhängigen uniform $[a, b]$ verteilten Zufallszahlen
- ▶ Mit dem Befehl `set.seed(x)` kann der **Startwert** x_0 festgelegt werden.
- ▶ Wählt man zweimal denselben Startwert, so erhält man zweimal dieselbe Folge
- ▶ Simulation von anderen Verteilungen: `rnorm`, `rexp`...


Pseudozufallszahlen

Beispiel: `x<-runif(100)`



Pseudozufallszahlen

Beispiel: `z<-rnorm(100)`



Pseudozufallszahlen

Beispiel: `z<-rnorm(1000)`

