

Überblick

- Beschreibende Statistik:
Auswertung von Experimenten und Stichproben
- Wahrscheinlichkeitsrechnung:
Schlüsse aus gegebenen Wahrscheinlichkeiten,
Hilfsmittel: Kombinatorik
- Beurteilende Statistik:
Schlüsse aus Experimenten, Beurteilung von exp.
Ergebnissen (machen wir nicht)

Linguistische Anwendungen:

- Spracherkennung
- Textretrival
- probabilistische Grammatiken: z.B. Disambiguierung

Problem: woher Daten?

Beschreibende Statistik

Statistische Erhebung: Bestimmung der *Ausprägung* eines *Merkmals* bei allen Individuen einer Grundgesamtheit.

qualitative vs. quantitative Merkmale,
diskrete vs. stetige qualitative Merkmale...

Beispiele:

- Geschlecht/ Gewicht aller Neugeborenen an einem Tag in einem Krankenhaus
- Anzahl der Wörter in jedem Artikel einer Ausgabe einer Tageszeitung
- Anzahl des Vorkommens von bestimmten Wörtern in einem Text-Korpus

Begriffe

- *absolute Häufigkeit:*

Anzahl des Vorkommens einer Ausprägung.

- *relative Häufigkeit:*

absolute H. / Anzahl der Individuen

- *Häufigkeitsverteilung:*

Funktion von allen Ausprägungen eines Merkmals auf Häufigkeiten.

- *Zentralwert:*

Bedingung: Ausprägungen geordnet. Der Zentralwert ist diejenige Ausprägung, für die gilt: es liegen nicht mehr als die Hälfte der Erhebungswerte darunter oder darüber.

- *arithmetisches Mittel \bar{x} von Erhebungswerten x_1, \dots, x_n :*

Bedingung: quantitatives Merkmal.

$$\bar{x} = \frac{1}{n}(x_1 + \dots + x_n) = \frac{1}{n} \sum_{i=1}^n x_i$$

- *Varianz, Streuung \bar{s}^2 (mittlere quadratische Abweichung):*

$$\bar{s}^2 = \frac{1}{n}((x_1 - \bar{x})^2 + \dots + (x_n - \bar{x})^2) = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2$$

- *Standardabweichung:* Quadratwurzel aus Varianz

Zufallsexperimente

Zufallsvariable X : unsicherer Ausgang eines Zufallsexperiments mit endlicher Zahl möglicher Ausgänge E_1, \dots, E_k , Ausgangsmenge oder Ereignisraum $V(X)$.

Bsp: Werfen einer Münze, Ziehung der Lottozahlen, Alter des nächsten Passanten.

Jede Teilmenge von $V(X)$ heisst *Ereignis*, die einzelnen Elemente auch *Elementarereignisse*.

Das Komplement eines Ereignisses A heisst Gegenereignis \bar{A} .

relative Häufigkeit eines Ausgangs, $h(E)$:

Eintreten von E / # Versuche.

Bemerkung zum Übergang zur Wahrscheinlichkeitsrechnung: es gelten gleiche Gesetzmässigkeiten, aber W'keitsrechnung lässt sich nicht statistisch begründen. Daher axiomatische Einführung mit gegebenen *Wahrscheinlichkeiten* der Elementarereignisse.

Axiome der Wahrscheinlichkeit (Kolmogoroff)

Wahrscheinlichkeit:

Sei $\{E_1, \dots, E_k\}$ ein Ereignisraum mit den Elementarereignissen E_i .

Wahrscheinlichkeitsverteilung:

Funktion $P : \{E_1, \dots, E_k\} \rightarrow [0, 1]$ (1)

$$\text{mit } P(E_1) + P(E_2) + \dots + P(E_k) = 1, \quad (2)$$

$P(E_i)$ heisst *Wahrscheinlichkeit* von E_i .

Sei A ein Ereignis mit Ereignisraum wie oben.

Wahrscheinlichkeit von A :

$P(A) = P(E_1) + \dots + P(E_i)$, falls $A = E_1 \cup \dots \cup E_i$;

$P(A) = 0$, falls $A = \emptyset$ (3)

Folgerungen daraus: für alle Ereignisse A, B gilt:

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

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

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

$$A \cap B = \emptyset \Rightarrow P(A \cup B) = P(A) + P(B)$$

(A und B heissen *unvereinbar*)

Gleichverteilung

Gleichverteilung: W'keitsverteilung, bei der alle Elementarereignisse die gleiche W'keit haben.

Zufallsexperimente mit Gleichverteilung heissen *Laplace-Experimente*.

Für Laplace-Experimente gilt für Ereignis A :

$$P(A) = \frac{\text{Anzahl der günstigen Ausgänge}}{\text{Anzahl der möglichen Ausgänge}}$$

Beispiele:

- X_1 : Augenzahl bei Wurf eines fairen (idealen) Würfels.

$$V(X_1) = \{1, 2, 3, 4, 5, 6\}, P(E_i) = 1/6$$

- X_2 : Augenzahl bei Wurf von zwei fairen Würfeln gleichzeitig.

$$V(X_2) = \{2, 3, 4, 5, 6, 7, 8, 9, 10, 11, 12\}$$

$$P(2) = 2/36, P(3) = 4/36, \dots$$

Kombinatorik

Produktregel zur Bestimmung möglicher Kombinationen:

Sei folgendes Lexikon gegeben:

{ die, keine, schönen, grünen, schnellen, Hunde, Katzen, Mäuse }.

Wieviele NPs lassen sich unter Verwendung der Regel $NP \rightarrow \text{Det Adj N}$ daraus bilden?

NP = # Det · # Adj · # N.

- Geordnete Stichprobe mit Zurücklegen, k -mal eines von n Elementen ziehen:

n^k Möglichkeiten.

- Geordnete Stichprobe ohne Zurücklegen:

$$n \cdot (n - 1) \dots \cdot (n - k + 1) = \frac{n!}{(n-k)!}$$

- Geordnete Vollerhebung (Permutation): $n!$

- Ungeordnete Stichprobe ohne Zurücklegen (Bsp: Lottozahlen):

Binomialkoeffizient, "n über k":
$$\binom{n}{k} = \frac{n!}{k!(n-k)!}$$

Bedingte Wahrscheinlichkeiten

$P(A \cup B) = P(A) + P(B)$ gilt nur wenn $A \cap B = \emptyset$.

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

Wie kann man $P(A \cap B)$ bestimmen?

Bedingte relative Häufigkeit:

n Durchführungen, $n_1 > 0$ mal Ereignis A , davon k -mal auch B , dann ist k/n_1 die *relative Häufigkeit von B bezüglich A* , $h_A(B)$, auch $h(B | A)$.

$$h(A \cap B) = h(A) \cdot h_A(B)$$

Bedingte Wahrscheinlichkeit:

Gegeben: Ereignisse A und B , $P(A) \neq 0$, dann heisst

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

die *durch A bedingte Wahrscheinlichkeit von B* oder Wahrscheinlichkeit von B bezgl. A .

Allgemeiner Multiplikationssatz:

$P(A) \neq 0$, dann $P(A \cap B) = P(A) \cdot P_A(B)$

Beispiel

Wenn sich jemand noch genau erinnert, dass eines der beiden Kinder seiner Cousine ein Junge ist, wie gross ist dann die Wahrscheinlichkeit, dass beides Jungen sind? ($P(\text{Junge}) = P(\text{Mädchen}) = 0.5$).

Gesucht: $P_1 \text{ Junge}(2 \text{ Jungen})$

Lösung

Ohne Information:

$$P(2 \text{ Jungen}) = 1/4$$

$$P(2 \text{ Mädchen}) = 1/4$$

$$P(\text{Junge/Mädchen}) = 1/2$$

$$P(A) = P(1 \text{ Junge}) = 1/4 + 1/2 = 3/4$$

$$P(B) = P(2 \text{ Jungen}), P(A \cap B) = P(B)$$

Mit der Information, dass ein Kind ein Junge ist:

$$P_1 \text{ Junge}(2 \text{ Jungen}) = P(2 \text{ Jungen}) / P(1 \text{ Junge})$$

$$= 1/4 / 3/4 = 1/3$$

Weiter: bedingte W'keiten

Seien A und B Ereignisse mit $P(A) \neq 0, P(B) \neq 0$.

Dann gilt:

$$P_B(A) = P_A(B) \cdot P(A)/P(B).$$

verallgemeinert, Satz von Bayes:

Seien A_1, \dots, A_n Ereignisse, die den Ereignisraum zerlegen, d.h. $P(A_1) + \dots + P(A_n) = 1$, und $P(A_j) \geq 0$ für $1 \leq j \leq n$. Sei $P(B) > 0$.

Dann gilt für A_i mit $1 \leq i \leq n$:

$$P_B(A_i) = \frac{P(A_i) \cdot P_{A_i}(B)}{P(A_1) \cdot P_{A_1}(B) + \dots + P(A_n) \cdot P_{A_n}(B)}$$

Zwei Ereignisse heissen *unabhängig*, wenn gilt:
 $P_A(B) = P(B)$ (und $P_B(A) = P(A)$).

Spezieller Multiplikationssatz:

Sind A und B unabhängig, dann gilt:

$$P(A \cup B) = P(A) \cdot P(B)$$

bedingte W'keiten, linguistisch

Wortfolgen:

$$P(w_{1,n}) = P(w_1)P(w_2 | w_1)P(w_3 | w_1, w_2) \dots P(w_n | w_{1,n-1})$$

der $\left\{ \begin{array}{l} \text{kleine} \\ \text{Schweine} \end{array} \right\}$ Hund

Sei $P(\text{kleine} | \text{der}) = P(\text{Schweine} | \text{der})$.

$$P_1 = P(\text{der kleine Hund}) = P(\text{der}) P(\text{kleine} | \text{der}) P(\text{Hund} | \text{der kleine})$$

$$P_2 = P(\text{der Schweine Hund}) = P(\text{der}) P(\text{Schweine} | \text{der}) P(\text{Hund} | \text{der Schweine})$$

$P_1 > P_2$,
falls $P(\text{Hund} | \text{der kleine}) > P(\text{Hund} | \text{der Schweine})$