

Vorlesung 8a

Zweistufige Zufallsexperimente

Teil 6:

Bedingte Wahrscheinlichkeiten

(Buch S. 115-117)

Definition.

Seien E_1, E_2 Ereignisse. Dann ist die *bedingte Wahrscheinlichkeit von E_2 , gegeben E_1* , definiert als

$$\mathbf{P}(E_2 | E_1) := \frac{\mathbf{P}(E_2 \cap E_1)}{\mathbf{P}(E_1)}$$

... die Wahrscheinlichkeit von E_2 , wenn man schon weiß, dass E_1 eingetreten ist.

Dies passt in den Rahmen von Teil 4,
als Verteilungsgewicht $\mathbf{P}(I_{E_2} = 1 | I_{E_1} = 1)$
der bedingten Verteilung von I_{E_2} , gegeben $\{I_{E_1} = 1\}$.

Beispiel:

T sei $\text{Geom}(p)$ -verteilt. Für $k, \ell \in \mathbb{N}_0$ berechnen wir die bedingte Wahrscheinlichkeit von $\{T - k > \ell\}$, gegeben $\{T > k\}$.

Wegen $\{T - k > \ell\} \cap \{T > k\} = \{T > k + \ell\}$ ist

$$\mathbf{P}(T - k > \ell \mid T > k) = q^{k+\ell} / q^k = q^\ell .$$

Die bedingte Verteilung von $T - k$, gegeben $\{T > k\}$,
ist somit (wieder) gleich $\text{Geom}(p)$.

Die Kenntnis, dass T größer als k ausfällt,
ändert also die Verteilung der verbleibenden Wartezeit nicht.

Man nennt diese Eigenschaft die
Gedächtnislosigkeit der geometrischen Verteilung.

Bedingte Verteilung der verbleibenden Wartezeit: Gedächtnislosigkeit der Exponentialverteilung

Für exponentialverteiltes T zum Parameter λ gilt für $r, s > 0$

$$\mathbf{P}(T > r + s \mid T > r) = e^{-\lambda s} .$$

Die bedingte Verteilung von $T - r$, gegeben $\{T > r\}$,
ist somit gleich $\text{Exp}(\lambda)$.

Die Kenntnis, dass T einen Wert größer als r annimmt,
ändert also die Verteilung der verbleibenden Wartezeit nicht.

Für zwei Ereignisse E_1, E_2 lautet die

Formel von Bayes:

$$\mathbf{P}(E_1|E_2) = \frac{\mathbf{P}(E_1)P(E_2|E_1)}{\mathbf{P}(E_1)P(E_2|E_1) + \mathbf{P}(E_1^c)P(E_2|E_1^c)}$$

Beispiel:

In einer Population haben 0.1% eine bestimmte Krankheit.

Bei einer bestimmten Reihenuntersuchung wird eine kranke Person in 100% der Fälle positiv getestet, eine gesunde Person in 1%.

Wie groß ist die Wahrscheinlichkeit, dass eine positiv getestete Person wirklich krank ist?

Hier ist erst einmal ein Rezept für eine intuitive Überschlagsrechnung:

In einer Population von 1000
sind 999 gesund und einer krank. Von den 999 Gesunden
werden ca 10 (falsch) positiv diagnostiziert.


Von 11 positiv Diagnostizierten
ist also im Schnitt nur einer krank.

Hier ist eine **Formalisierung**:

X_1 sei der Gesundheitszustand (mit Werten in $S_1 = \{g, k\}$),

X_2 der Testbefund (mit Werten in $S_2 = \{p, n\}$).

(X_1, X_2) entsteht über ein zweistufiges Experiment:



$$\mathbf{P}(X_1 = k | X_2 = p) = \frac{\mathbf{P}(X_1 = k, X_2 = p)}{\mathbf{P}(X_2 = p)}$$

$$= \frac{0.001 \cdot 1}{0.999 \cdot 0.01 + 0.001 \cdot 1} \approx \frac{1}{11}$$