

1. Eigenschaften einer Zufallsstichprobe

1.1 Grundkonzepte

Definition 1.1.1: Man nennt die Zufallsvariablen X_1, \dots, X_n **zufällige Stichprobe** oder **Zufallsstichprobe** vom Umfang n aus der Population (Grundgesamtheit) $f(x)$, wenn die X_1, \dots, X_n unabhängige Zufallsvariablen sind und die Randdichte oder Randwahrscheinlichkeitsfunktion jedes X_i dieselbe Funktion $f(x)$ ist. Alternativ nennt man X_1, \dots, X_n **unabhängig und identisch verteilte** (independent and identically distributed, **iid**) Zufallsvariablen mit Dichte oder Wahrscheinlichkeitsfunktion $f(x)$.

Bemerkungen:

Die Beobachtungen werden derart genommen, dass der Wert einer Beobachtung keinen Effekt auf die übrigen Beobachtungen hat (Unabhängigkeit).

Die gemeinsame Dichte oder Wahrscheinlichkeitsfunktion von X_1, \dots, X_n ist

$$f(x_1, \dots, x_n) = f(x_1)f(x_2) \cdots f(x_n) = \prod_{i=1}^n f(x_i).$$

Da die X_i alle identisch verteilt sind, sind die marginalen $f(x_i)$ alle dieselben. Falls $f(x)$ ein Mitglied einer parametrischen Familie ist (Normal- ...) mit Dichte oder Wahrscheinlichkeitsfunktion $f(x|\theta)$, dann ist die gemeinsame Dichte oder Wahrscheinlichkeitsfunktion

$$f(x_1, \dots, x_n|\theta) = \prod_{i=1}^n f(x_i|\theta).$$

Statistisches Denken: Wir nehmen an, dass die betrachtete Population ein Mitglied einer parametrischen Familie ist, aber der wahre Parameterwert unbekannt ist. Betrachtet man verschiedene Werte von θ , so kann man untersuchen, wie sich eine Zufallsstichprobe für verschiedene Populationen verhält.

Beispiel 1.1.1: Sei X_1, \dots, X_n eine Zufallsstichprobe aus einer Exponential(β)-Population, d.h. mit Dichtefunktion

$$f(x|\beta) = \frac{1}{\beta} \exp\left(-\frac{x}{\beta}\right), \quad 0 \leq x < \infty, \quad 0 < \beta,$$

mit $E(X) = \beta$ und $\text{var}(X) = \beta^2$. Dazu korrespondiert die Verteilungsfunktion

$$F(x|\beta) = 1 - \exp\left(-\frac{x}{\beta}\right).$$

Diese Zufallsstichprobe charakterisiere Ausfallszeiten von IC's in Jahren. Wir testen n IC's und verwenden diese bis sie ausfallen.

Die gemeinsame Dichte der Zufallsstichprobe ist

$$f(x_1, \dots, x_n | \beta) = \prod_{i=1}^n f(x_i | \beta) = \prod_{i=1}^n \frac{1}{\beta} \exp\left(-\frac{x_i}{\beta}\right) = \frac{1}{\beta^n} \exp\left(-\frac{1}{\beta} \sum_{i=1}^n x_i\right).$$

Damit ist z.B. die Wahrscheinlichkeit, dass alle IC's länger als 2 Jahre halten, gleich

$$\begin{aligned} P(X_1 > 2, \dots, X_n > 2 | \beta) &= P(X_1 > 2 | \beta) \cdots P(X_n > 2 | \beta) \quad \text{Unabhängigkeit} \\ &= (P(X_1 > 2 | \beta))^n \quad \text{identisch verteilt} \\ &= \left(e^{-2/\beta}\right)^n \quad \text{exponentialverteilt} \\ &= e^{-2n/\beta}. \end{aligned}$$

Für große Werte von β ist dies nahe 1.

Bemerkungen:

Diese Art Stichprobe nennt man *Stichprobe aus einer unendlichen Population*.

Gedanke: Erhalte die Werte von X_1, \dots, X_n sequentiell d.h.

1. Experiment: $X_1 = x_1$ wird beobachtet. Dann
2. Experiment: $X_2 = x_2$ wird beobachtet.

Unabhängigkeit bedeutet, dass die Verteilung von X_2 nicht von $X_1 = x_1$ abhängt.

Das Entfernen von x_1 aus der unendlich großen Population ändert diese nicht. Somit ist $X_2 = x_2$ noch immer zufällige Beobachtung aus derselben Population.

Bei einer *Stichprobe aus einer endlichen Population* muss zwischen mit/ohne Zurücklegen (replacement) unterschieden werden.

Population ist jetzt die endliche Menge von Zahlen $\{x_1, \dots, x_N\}$. Sei X_1, \dots, X_n eine Stichprobe daraus.

(1) *mit Zurücklegen*: Wir nehmen an, dass die Wahrscheinlichkeit einen Wert aus der Population zu wählen gleich ist für alle x_j , also gleich $1/N$ ist (Urnenmodell, ziehe aus einem Hut).

Sei $X_1 = x_1$. Dann wird x_1 zurückgelegt und das Ziehen wiederholt. Wieder sind alle N Werte gleichwahrscheinlich. Wir erhalten $X_2 = x_2$. Falls dieselbe Zahl gewählt wurde ist $x_2 = x_1$. Wir wiederholen das Experiment n mal und erhalten die Stichprobe X_1, \dots, X_n .

Die Bedingungen der Definition 1.1.1 sind bei dieser Art die Stichprobe zu ziehen erfüllt. Jedes X_i ist eine diskrete Zufallsvariable, welche die Werte x_1, \dots, x_N mit gleicher Wahrscheinlichkeit annimmt. Die Zufallsvariablen X_1, \dots, X_n sind *unabhängig*, da der Auswahlprozess eines X_i derselbe ist, unabhängig der Werte die zuvor gezogen wurden.

(2) *ohne Zurücklegen*: Annahmen wie zuvor jedoch wird jetzt nach $X_1 = x_1$ der Wert x_1 nicht mehr zurückgegeben. Der 2. Wert wird aus den verbliebenen $N - 1$ gewählt. Jeder dieser $N - 1$ Werte hat Wahrscheinlichkeit $1/(N - 1)$ gezogen zu werden.

Wir erhalten $X_2 = x_2 \neq x_1$ u.s.w. Dieser Prozess liefert eine Stichprobe X_1, \dots, X_n , jedoch ist ein gezogener Wert später nicht mehr verfügbar. Somit ist keine Unabhängigkeit in dieser Stichprobe und die Annahmen aus Definition 1.1.1 sind nicht erfüllt.

Betrachte die marginale Verteilung von X_2 :

$$P(X_2 = x) = \sum_{i=1}^N P(X_2 = x | X_1 = x_i) P(X_1 = x_i) \quad \text{totale Wahrscheinlichkeit.}$$

Für **einen** Index i ist $x = x_i$ und somit $P(X_2 = x | X_1 = x_i) = 0$. Für alle übrigen $N - 1$ Indizes $j \neq i$ gilt $P(X_2 = x | X_1 = x_j) = 1/(N - 1)$ und es folgt

$$P(X_2 = x) = (N - 1) \left(\frac{1}{N - 1} \cdot \frac{1}{N} \right) = \frac{1}{N}.$$

Also sind die marginalen Verteilungen dieselben unter Ziehen der Stichprobe *mit* und *ohne* Zurücklegen. Jedoch gibt es keine Unabhängigkeit bei Ziehen ohne Zurücklegen. Annähernde Unabhängigkeit erreicht man für N sehr groß.

Von nun an verwenden wir die Definition 1.1.1, um eine Zufallsstichprobe aus einer Population zu charakterisieren.