



## **Stochastik**

**Barth, Friedrich**

**München, [20]03**

18. 6. Die Stichprobenvarianz

---

[urn:nbn:de:hbz:466:1-83580](https://nbn-resolving.de/urn:nbn:de:hbz:466:1-83580)

Auf Grund der bei den Beweisen verwendeten Sätze 212.1 und 212.2 gilt die Erwartungstreue von  $\bar{X}_n$  auch für Stichproben, bei denen die  $X_i$  nicht unabhängig sind, und die Konsistenz von  $\bar{X}_n$  für Stichproben, bei denen die  $X_i$  nur paarweise unabhängig sind.

## 18.6. Die Stichprobenvarianz

Wir wollen nun eine Schätzgröße für die Varianz  $\sigma^2$  einer Zufallsgröße  $X$  ausfindig machen. Wenn möglich, soll sie erwartungstreue sein. Dazu ziehen wir aus  $X$  eine Stichprobe  $(X_1 | X_2 | \dots | X_n)$ . Die  $X_i$  sind Kopien von  $X$ ; also ist  $\mathbb{E} X_i = \mathbb{E} X = \mu$  und  $\sigma^2 = \text{Var } X = \text{Var } X_i = \mathbb{E}[(X_i - \mu)^2]$ .

Da wir in 18.5. unbekannte Erwartungswerte durch das Stichprobenmittel geschätzt haben, ist es naheliegend, als Schätzfunktion für  $\sigma^2$  das Stichprobenmittel  $V := \frac{1}{n} \sum_{i=1}^n (X_i - \mu)^2$  der Zufallsgrößen  $(X_i - \mu)^2$  zu verwenden. Wie in

Aufgabe 384/4 gezeigt werden soll, ist  $V$  eine erwartungstreue Schätzgröße für  $\sigma^2$ . Darüber hinaus ist sie konsistent und effizient.

In den meisten Fällen ist aber auch  $\mu$  nicht bekannt. Wir schätzen dann  $\mu$  gemäß 18.5. durch das Stichprobenmittel  $\bar{X}_n$ , das wir an Stelle von  $\mu$  in den Ausdruck für  $V$  einführen. Wir erhalten somit als Schätzfunktion für  $\sigma^2$  die Stichprobenfunktion

$$\tilde{S}^2 := \frac{1}{n} [(X_1 - \bar{X}_n)^2 + \dots + (X_n - \bar{X}_n)^2] = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X}_n)^2.$$

Zur Vereinfachung der Schreibweise lässt man üblicherweise beim Stichprobenmittel  $\bar{X}_n$  den Index  $n$  weg und schreibt

$$\tilde{S}^2 = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2.$$

Um zu prüfen, ob  $\tilde{S}^2$  eine erwartungstreue Schätzgröße ist, formen wir die Summe um. Wir gehen dabei genauso vor wie bei der Herleitung des Verschiebungssatzes 207.1:

$$\begin{aligned} \tilde{S}^2 &= \frac{1}{n} \sum_{i=1}^n [(X_i - \mu) - (\bar{X} - \mu)]^2 = \\ &= \frac{1}{n} \sum_{i=1}^n [(X_i - \mu)^2 + (\bar{X} - \mu)^2 - 2(\bar{X} - \mu)(X_i - \mu)] = \\ &= \frac{1}{n} \left[ \sum_{i=1}^n (X_i - \mu)^2 + \sum_{i=1}^n (\bar{X} - \mu)^2 - 2(\bar{X} - \mu) \sum_{i=1}^n (X_i - \mu) \right] = \\ &= \frac{1}{n} \sum_{i=1}^n (X_i - \mu)^2 + \frac{1}{n} \cdot n(\bar{X} - \mu)^2 - \frac{2}{n} \cdot (\bar{X} - \mu)(n\bar{X} - n\mu) = \\ &= \frac{1}{n} \sum_{i=1}^n (X_i - \mu)^2 + (\bar{X} - \mu)^2 - 2(\bar{X} - \mu)^2 = \\ &= \frac{1}{n} \sum_{i=1}^n (X_i - \mu)^2 - (\bar{X} - \mu)^2. \end{aligned}$$

Wir prüfen  $\tilde{S}^2$  auf Erwartungstreue:

$$\begin{aligned}
 \mathcal{E}(\tilde{S}^2) &= \mathcal{E}\left[\frac{1}{n} \sum_{i=1}^n (X_i - \mu)^2 - (\bar{X} - \mu)^2\right] = \\
 &= \frac{1}{n} \cdot \mathcal{E}\left[\sum_{i=1}^n (X_i - \mu)^2\right] - \mathcal{E}[(\bar{X} - \mu)^2] = \\
 &= \frac{1}{n} \cdot \sum_{i=1}^n \mathcal{E}[(X_i - \mu)^2] - \mathcal{E}[(\bar{X} - \mu)^2] = \\
 &= \frac{1}{n} \sum_{i=1}^n \text{Var} X_i - \mathcal{E}[(\bar{X} - \mu)^2] = \\
 &= \frac{1}{n} \sum_{i=1}^n \sigma^2 - \mathcal{E}[(\bar{X} - \mu)^2] = \\
 &= \sigma^2 - \mathcal{E}[(\bar{X} - \mu)^2].
 \end{aligned}$$

Da  $\mu = \mathcal{E}\bar{X}$ , ist der Subtrahend nichts anderes als  $\text{Var}\bar{X}$ , wofür nach Satz 212.2 gilt  $\text{Var}\bar{X} = \frac{1}{n} \text{Var} X = \frac{1}{n} \sigma^2$ . Damit wird

$$\begin{aligned}
 \mathcal{E}(\tilde{S}^2) &= \sigma^2 - \frac{1}{n} \sigma^2 = \\
 &= \frac{n-1}{n} \sigma^2.
 \end{aligned}$$

Wegen des Faktors  $\frac{n-1}{n}$  ist  $\tilde{S}^2$  keine erwartungstreue Schätzgröße für  $\sigma^2$ . Man würde  $\sigma^2$  stets zu klein schätzen, und dies um so mehr, je kleiner die Länge  $n$  der Stichprobe ist. Der Mangel lässt sich aber für  $n > 1$  leicht beheben: Wir multiplizieren  $\tilde{S}^2$  mit  $\frac{n}{n-1}$  und erhalten eine erwartungstreue Schätzgröße für  $\sigma^2$ , die sogenannte Stichprobenvarianz  $S^2$ .

Wir halten fest

**Satz 382.1** Ist  $(X_1 | X_2 | \dots | X_n)$  eine Stichprobe aus der Zufallsgröße  $X$  mit

$$\bar{X} := \frac{1}{n} \cdot \sum_{i=1}^n X_i, \text{ dann ist für } n \geq 2 \text{ die Stichprobenvarianz}$$

$$S^2 := \frac{1}{n-1} \cdot \sum_{i=1}^n (X_i - \bar{X})^2$$

eine erwartungstreue Schätzgröße für die Varianz  $\sigma^2$  der Verteilung von  $X$ .

Für große  $n$  ist der Unterschied zwischen  $S^2$  und  $\tilde{S}^2$  natürlich unerheblich. So-wohl die Stichprobenvarianz  $S^2$  wie auch  $\tilde{S}^2$  sind konsistent (vgl. Aufgabe 385/14), aber nicht effizient, was wir ohne Beweis mitteilen.

Es liegt nun die Vermutung nahe, man könne die **Stichprobenstreuung**  $S := \sqrt{S^2}$

als erwartungstreue Schätzgröße für die Standardabweichung  $\sigma$  benützen. Dies ist leider falsch, wie wir an einem Beispiel zeigen:

Es sei  $X := \text{»Zahl der Adler beim Wurf einer evtl. unsymmetrischen Münze«}$ .  $X$  ist nach  $B(1; p)$  verteilt.  $(X_1 | X_2)$  sei eine Stichprobe der Länge 2 aus  $X$ . Mit  $\bar{X} = \frac{1}{2}(X_1 + X_2)$  erhält man

$$S^2 = (X_1 - \bar{X})^2 + (X_2 - \bar{X})^2 = \frac{1}{2}(X_1 - X_2)^2,$$

$$S = \frac{1}{2}\sqrt{2}|X_1 - X_2|.$$

$S$  nimmt offensichtlich nur die Werte 0 und 1 an. Damit errechnet man

$$\begin{aligned}\mathcal{E}S &= \frac{1}{2}\sqrt{2}[P(X_1 = 1 \wedge X_2 = 0) + P(X_1 = 0 \wedge X_2 = 1)] = \\ &= p(1-p)\sqrt{2}.\end{aligned}$$

Dagegen ist  $\sigma(X) = \sqrt{p(1-p)}$ .

Die Verschiedenheit von  $\mathcal{E}S$  und  $\sigma$  lässt sich nicht so wie die von  $\mathcal{E}\tilde{S}^2$  und  $\sigma^2$  durch einen für alle  $p$  gültigen Faktor beseitigen.

**Die Berechnung des Wertes von  $S^2$ .** Bei mehrfacher Messung einer (z. B. physikalischen) Größe unter gleichen Bedingungen ist es üblich, aus der Meßreihe die Werte  $\bar{x}$  und  $s$  von  $\bar{X}$  bzw.  $S$  zu bestimmen und das Meßresultat in der Form

$\bar{x} \pm s$  zu schreiben.

So findet man z. B. für das Wirkungsquantum  $h$  die Angabe

$$\frac{h}{2\pi} = (1,05443 \pm 0,00004) \cdot 10^{-34} \text{ Js}.$$

$s$  ist meist sehr mühsam zu berechnen, wenn man die in Satz 382.1 enthaltene Definition von  $S^2$  direkt benützt, da  $\bar{x}$  im allgemeinen keine glatte Zahl ist. Man hat viele unbequeme Subtraktionen auszuführen. Die folgende Umformung erleichtert die Arbeit. Sie entspricht genau der oben vorgeführten Umformung von  $\tilde{S}^2$ .

$$\begin{aligned}(n-1) \cdot s^2 &= \sum_{i=1}^n (x_i - \bar{x})^2 = \\ &= \sum_{i=1}^n (x_i - a)^2 + 2 \sum_{i=1}^n (x_i - a)(a - \bar{x}) + n(a - \bar{x})^2.\end{aligned}$$

Der zweite Term ist gleich

$$2(a - \bar{x}) \sum_{i=1}^n (x_i - a) = 2(a - \bar{x})(n\bar{x} - na) = -2n(a - \bar{x})^2.$$

Also erhält man schließlich mit  $\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i$

$$s^2 = \frac{1}{n-1} \cdot \sum_{i=1}^n (x_i - \bar{x})^2 = \frac{1}{n-1} \left( \sum_{i=1}^n (x_i - a)^2 - n(\bar{x} - a)^2 \right)$$

Diese Formel gilt für eine beliebige Zahl  $a$ . Man wählt  $a$  als glatte Zahl in der Nähe von  $\bar{x}$  und kann damit die rechte Seite verhältnismäßig einfach ausrechnen. Ein Beispiel zeigt Tabelle 384.1.

Tab. 384.1 Punktbewertungen  $x_i$  von 10 Personen bei einem Gedächtnistest. Die Hilfszahl  $a = 35$  wird bereits zur Berechnung von  $\bar{x}$  mit Vorteil verwendet. (Vgl. Aufgabe 215/20)

$$\bar{x} = 35 - \frac{5}{10} = 34,5; \\ s^2 = \frac{1}{9}(1473 - 10 \cdot 0,5^2); \\ s = 12,8.$$

$x_i$	$x_i - a$	$(x_i - a)^2$
12	-23	529
21	-14	196
28	-7	49
30	-5	25
34	-1	1
37	+2	4
39	+4	16
39	+4	16
49	+14	196
56	+21	441
Summe:		-5
		1473

## Aufgaben

### Zu 18.3. - 18.6.

- Bestimme bei folgenden Stichproben aus einer Zufallsgröße Schätzwerte für den Erwartungswert und die Varianz:
  - 3; 5; 3; 6; 9.
  - 0,3; 0,7; -0,4; 0,8; -0,2.
  - 300; 700; -400; 800; -200
  - 1; 1; 1; 1; 1.
- Bestimme Schätzwerte für Erwartungswert und Varianz der Zufallsgröße »Bremsweg bei einer Geschwindigkeit von 50 km/h«, wenn sich folgende Meßwerte in m ergaben:  
15,5 14,0 14,1 14,9 13,4 15,0 14,4 14,4 15,8 15,9.
- Welchen Erwartungswert und welche Varianz erhält man bei  $n$  Messungen für das Stichprobenmittel  $\bar{X}$ , wenn für die Zufallsgröße  $X$  gilt:
  - $\mathbb{E}X = 2,71$ ;  $\text{Var}X = 1,5$ ;  $n = 10$ .
  - $\mathbb{E}X = 1$ ;  $\text{Var}X = 1$ ;  $n = 100$ .
  - $\mathbb{E}X = 1$ ;  $\text{Var}X = 1$ ;  $n = 1000$ .
  - $\mathbb{E}X = 0$ ;  $\text{Var}X = 1$ ;  $n = 1000$ .
- Zeige, daß  $V := \frac{1}{n} \sum_{i=1}^n (X_i - \mu)^2$  eine erwartungstreue Schätzfunktion für  $\sigma_X^2$  ist.
- a) Eine Zufallsgröße  $X$  ist binomial nach  $B(1; 0,25)$  verteilt. Bestimme Erwartungswert, Varianz und Standardabweichung von  $X$ . Berechne für eine Stichprobe der Länge 3 die Wahrscheinlichkeitsverteilungen und die Erwartungswerte des Stichprobenmittels  $\bar{X}_3$ , der Stichprobenvarianz  $S^2$  und der Stichprobenstreuung  $S$ .  
b) Löse a) für eine Stichprobe der Länge 2, wenn  $X$  nach  $B(2; 0,25)$  verteilt ist.
- Eine Zufallsgröße  $X$  besitze die Verteilung  $P(X = x_j) =: p_j$  für  $j = 1, \dots, s$ .  $(X_1 | X_2 | \dots | X_n)$  sei eine Stichprobe der Länge  $n$ , ferner sei  $N_j :=$  Anzahl der  $X_i$ , welche den Wert  $x_j$  annehmen.  $A_j$  bedeute das Ereignis  $\left| \frac{1}{n} N_j - p_j \right| \geq a$ .  
a) Formuliere für  $P(A_j)$  die Tschebyschow-Ungleichung.  
b) Formuliere mit den  $A_j$  das Ereignis  $A :=$  »Die Stichprobenverteilung weicht nirgends um  $a$  oder mehr von der Wahrscheinlichkeitsverteilung ab«.  
c) Finde für  $P(\bar{A})$  eine Abschätzung, die zeigt, daß das Ereignis  $A$  für genügend große  $n$  eine beliebig nahe an 1 gelegene Wahrscheinlichkeit hat. *Die Stichprobenverteilung konvergiert »in Wahrscheinlichkeit« gegen die Wahrscheinlichkeitsverteilung.*
- Eine Zufallsgröße sei nach  $B(100; 0,4)$  verteilt. Wie lang muß eine Stichprobe mindestens sein, damit die Varianz des Stichprobenmittels kleiner als 0,01 ist?
- Die Wahrscheinlichkeit für eine Knabengeburt ist 0,514. Die Zufallsgröße  $X$  nehme den Wert 1 an, wenn ein Knabe geboren wird, sonst habe sie den Wert 0.