

3.3 Varianz und Kovarianz

Definition 3.12. X reelle ZV, $p > 0$. X besitzt p -tes Moment (auch geschrieben $X \in \mathcal{L}^p$), wenn $\mathbb{E}[|X|^p] < \infty$. $\mathbb{E}[X^p]$ heißt das p -te Moment von X .

(bzw. $Z^p(P)$, wenn das zugehörige W'Maß P nicht aus dem Kontext klar)

Bemerkung 3.13. Für $p \geq p' \geq 1$ ist $\mathcal{L}^p \subset \mathcal{L}^{p'}$ (denn $|x|^{p'} \leq 1 + |x|^p$).

Definition 3.14. Für $X, Y \in \mathcal{L}^2$ heißt

1. $\text{Var}[X] := \mathbb{E}[(X - \mathbb{E}[X])^2] = \mathbb{E}[X^2] - (\mathbb{E}[X])^2$ die *Varianz* von X (manchmal schreibt man auch $\sigma_X^2 := \text{Var}[X]$),

$\sqrt{\text{Var}[X]}$ die *Standardabweichung (oder Streuung)* von X (manchmal auch $\sigma_X = \sqrt{\sigma_X^2}$ geschrieben),

2. $\text{Cov}[X, Y] := \mathbb{E}[(X - \mathbb{E}[X])(Y - \mathbb{E}[Y])] = \mathbb{E}[XY] - \mathbb{E}[X]\mathbb{E}[Y]$ die *Kovarianz* von X und Y .

(ein "populäres Maß" für die Variabilität von X)

X und Y heißen *unkorreliert*, wenn $\text{Cov}[X, Y] = 0$.

$$\text{Var}[X] = \mathbb{E}[(X - \mathbb{E}[X])^2], \quad \text{Cov}[X, Y] := \mathbb{E}[(X - \mathbb{E}[X])(Y - \mathbb{E}[Y])]$$

Beobachtung 3.15. 1. Wegen $|XY| \leq X^2 + Y^2$ ist die Kovarianz wohldefiniert. Es gilt (offensichtlich)

$$\text{Cov}[X, Y] = \text{Cov}[Y, X].$$

2. Es ist

$$\begin{aligned} \mathbb{E}[(X - \mathbb{E}[X])(Y - \mathbb{E}[Y])] &= \mathbb{E}[XY - X\mathbb{E}[Y] - Y\mathbb{E}[X] + \mathbb{E}[X]\mathbb{E}[Y]] \\ &= \mathbb{E}[YX] - \mathbb{E}[X]\mathbb{E}[Y] - \mathbb{E}[Y]\mathbb{E}[X] + \mathbb{E}[X]\mathbb{E}[Y] \\ &= \mathbb{E}[XY] - \mathbb{E}[X]\mathbb{E}[Y] \end{aligned}$$

(und analog für $\text{Var}[X] = \text{Cov}[X, X]$). $\leftarrow \text{Var}[X] = \mathbb{E}[X^2] - (\mathbb{E}[X])^2$

3. $\text{Var}[X] = 0 \iff P(X = \mathbb{E}[X]) = 1$

(„ \Leftarrow “ ist klar, für „ \Rightarrow “ wende Satz 3.4, 3. an auf die ZV $(X - \mathbb{E}[X])^2$) (d.h. $P((X - \mathbb{E}[X])^2 = 0) = 1$)

4. $\text{Var}[X]$ ist eine Eigenschaft der Verteilung von X , $\text{Cov}[X, Y]$ ist eine Eigenschaft der gemeinsamen Verteilung von X und Y .

Beispiel 3.16. 1. $X \sim \text{Ber}_p$, $\text{Var}[X] = \underbrace{\mathbb{E}[X^2]} - (\mathbb{E}[X])^2 = p - p^2 = p(1-p)$
 $= p \cdot 1^2 + (1-p) \cdot 0^2 = p$

2. $X \sim \text{Poi}_\alpha$, so ist $\text{Var}[X] = \alpha$

$$\mathbb{E}[X(X-1)] = \sum_{k=2}^{\infty} k(k-1) e^{-\alpha} \frac{\alpha^k}{k!} = \cancel{e^{-\alpha}} \alpha^2 \sum_{k=2}^{\infty} \frac{\alpha^{k-2}}{(k-2)!}$$

$$= \sum_{j=0}^{\infty} \frac{\alpha^j}{j!} = \cancel{e^{\alpha}}$$

$$= \alpha^2$$

$$\text{Var}[X] = \mathbb{E}[X^2] - (\mathbb{E}[X])^2$$

$$= \underbrace{\mathbb{E}[X(X-1)]}_{=\alpha^2} + \underbrace{\mathbb{E}[X]}_{=\alpha} - \alpha^2 = \alpha$$

3. $X \sim \text{Bin}_{n,p}$

$$\mathbb{E}[X(X-1)] = \sum_{k=0}^n k(k-1) \binom{n}{k} p^k (1-p)^{n-k}$$

$$= n(n-1)p^2 \sum_{k=2}^n \binom{n-2}{k-2} p^{k-2} (1-p)^{(n-2)-(k-2)} = n(n-1)p^2$$

also

$$\text{Var}[X] = \mathbb{E}[X(X-1)] + \mathbb{E}[X] - (\mathbb{E}[X])^2 = n(n-1)p^2 + np - (np)^2 = -np^2 + np = np(1-p)$$

4. $X \sim \text{Geom}_p$, $p \in [0, 1]$ (d.h. $P(X = k) = p(1-p)^k$, $k \in \mathbb{N}_0$, vgl. Bsp. 1.21), so ist $\text{Var}[X] = \frac{1-p}{p^2}$

$$\mathbb{E}[X(X-1)] = \sum_{n=2}^{\infty} n(n-1)p(1-p)^n = (1-p)^2 p \sum_{n=2}^{\infty} n(n-1)(1-p)^{n-2}$$

$$f(t) = \sum_{n=0}^{\infty} t^n, \quad |t| < 1 \quad = \frac{2(1-p)^2}{p^2}$$

$$= \frac{1}{1-t}$$

$$f'(t) = \frac{1}{(1-t)^2}, \quad f''(t) = \frac{2}{(1-t)^3} = \sum_{n=2}^{\infty} n(n-1)t^{n-2}$$

$$\text{Var}[X] = \mathbb{E}[X(X-1)] + \underbrace{\mathbb{E}[X]}_{= \frac{1-p}{p}} - (\mathbb{E}[X])^2$$

$$= \dots = \frac{1-p}{p^2}$$

$$5. X \sim \mathcal{N}_{\mu, \sigma^2}, \text{Var}[X] = \sigma^2$$

(es gilt $\mu = \mathbb{E}[X]$)

$$\text{Var}[X] = \mathbb{E}[(X - \mu)^2]$$

$$= \int_{\mathbb{R}} \underbrace{(x - \mu)^2}_{=(\sigma z)^2} \frac{1}{\sqrt{2\pi\sigma^2}} \underbrace{e^{-\frac{(x-\mu)^2}{2\sigma^2}}}_{e^{-z^2/2}} dx$$

Setze $\begin{matrix} \uparrow \\ \Downarrow \end{matrix}$
 $z = \frac{x - \mu}{\sigma}$,
 $dz = \frac{1}{\sigma} dx$

$$= \sigma^2 \int_{\mathbb{R}} z^2 \frac{1}{\sqrt{2\pi}} e^{-z^2/2} dz$$

$$= \sigma^2 \frac{1}{\sqrt{2\pi}} \int_{\mathbb{R}} z \cdot \underbrace{\left(z e^{-z^2/2} \right)}_{= -\frac{d}{dz} e^{-z^2/2}} dz = \sigma^2$$

$$= -z \cdot e^{-z^2/2} \Big|_{-\infty}^{\infty} - \int_{\mathbb{R}} 1 \cdot \underbrace{(-e^{-z^2/2})}_{= \sqrt{2\pi}} dz$$

Satz 3.17 (Rechenregeln für Varianz und Kovarianz). Seien $X, Y, X_1, X_2, \dots, X_n \in \mathcal{L}^2$, $a, b, c, d \in \mathbb{R}$.

1. $aX + b, cY + d \in \mathcal{L}^2$ und

$$\text{Cov}[aX + b, cY + d] = ac\text{Cov}[X, Y],$$

insbesondere

$$\text{Var}[aX + b] = a^2\text{Var}[X]$$

(die Kovarianz ist eine Bilinearform, die Varianz ein quadratisches Funktional).

$$2. \text{Var}\left[\sum_{i=1}^n X_i\right] = \sum_{i=1}^n \text{Var}[X_i] + \sum_{\substack{1 \leq i, j \leq n \\ i \neq j}} \text{Cov}[X_i, X_j],$$

insbesondere gilt für paarweise unkorrelierte X_1, \dots, X_n also $\text{Var}\left[\sum_{i=1}^n X_i\right] = \sum_{i=1}^n \text{Var}[X_i]$.

3. Sind X und Y unabhängig, so gilt $\text{Cov}[X, Y] = 0$.

4. Es gilt

$$|\text{Cov}[X, Y]| \leq \sqrt{\text{Var}[X]} \sqrt{\text{Var}[Y]} \quad (\text{Cauchy-Schwarz-Ungleichung}^2)$$

²nach Augustin-Louis Cauchy (1789–1857) und Hermann Amandus Schwarz (1843–1921)

Beweis. 1. Z.z: $\text{Cov}[aX + b, cY + d] = ac\text{Cov}[X, Y]$

$$\begin{aligned} & \underbrace{\text{Cov}[aX + b, cY + d]} \\ &= \text{Cov}(aX, cY) \quad (aX + \cancel{b} - \underbrace{\mathbb{E}[aX + b]}_{\mathbb{E}[aX] + \cancel{b}}) \\ &= \mathbb{E}[(aX)(cY)] - \mathbb{E}[aX] \cdot \mathbb{E}[cY] \\ &= ac (\mathbb{E}[XY] - \mathbb{E}[X] \cdot \mathbb{E}[Y]) \quad \checkmark \end{aligned}$$

$$2. \text{ Z.z.: } \text{Var}\left[\sum_{i=1}^n X_i\right] = \sum_{i=1}^n \text{Var}[X_i] + \sum_{i \neq j}^n \text{Cov}[X_i, X_j]$$

(Induktiv mit 1. oder:)

Sei o. F. $\mathbb{E}[X_1] = \dots = \mathbb{E}[X_n] = 0$ (sonst betr.

dann ist

$$\tilde{X}_i = X_i - \mathbb{E}[X_i]$$

$$\text{Var}\left[\sum_{i=1}^n X_i\right] = \mathbb{E}\left[\left(\sum_{i=1}^n X_i\right)^2\right] \quad (-0^2)$$

$$= \sum_{i=1}^n \underbrace{\mathbb{E}[X_i^2]}_{\text{Var}[X_i]} + \sum_{\substack{i, j=1 \\ i \neq j}}^n \underbrace{\mathbb{E}[X_i X_j]}_{=\text{Cov}[X_i, X_j]} = \sum_{i, j=1}^n X_i \cdot X_j = \sum_{i=1}^n X_i^2 + \sum_{i \neq j}^n X_i X_j$$

$$3. X \text{ und } Y \text{ unabhängig} \implies \text{Cov}[X, Y] = 0$$

denn dann gilt $\mathbb{E}[XY] = \mathbb{E}[X] \cdot \mathbb{E}[Y]$



4. Z.z. $|\text{Cov}[X, Y]| \leq \sqrt{\text{Var}[X]} \sqrt{\text{Var}[Y]}$ (Cauchy-Schwarz-Ungleichung)

• Falls $\text{Var}[Y] = 0$, so ist $P(Y - \mathbb{E}[Y] = 0) = 1$,
also auch $\text{Cov}[X, Y] = \mathbb{E}[(X - \mathbb{E}[X]) \underbrace{(Y - \mathbb{E}[Y])}_{= 0}] = 0$
(Formel gilt als $0 = 0$)

• Falls $\text{Var}[Y] > 0$, setze $\alpha := -\frac{\text{Cov}[X, Y]}{\text{Var}[Y]}$

$$0 \leq \underbrace{\text{Var}[X + \alpha Y]}_{\text{Cov}[X + \alpha Y, X + \alpha Y]} \cdot \text{Var}[Y]$$

$$\stackrel{(1.)}{=} \left(\text{Var}[X] + 2\alpha \text{Cov}[X, Y] + \alpha^2 \text{Var}[Y] \right) \cdot \text{Var}[Y]$$

$$= \text{Var}[X] \cdot \text{Var}[Y] - (\text{Cov}[X, Y])^2 \quad \square$$

Bemerkung 3.18. Es gilt Gleichheit in der Cauchy-Schwarz-Ungleichung g.d.w.

es gibt $a, b, c \in \mathbb{R}$ (mit $a \neq 0$ oder $b \neq 0$), so dass $P(aX + bY + c = 0) = 1$.

In diesem Fall heißen X und Y perfekt korreliert.

Beispiel 3.19. 1. $X \sim \text{Bin}_{n,p}$, schreibe $X = Y_1 + \dots + Y_n$ mit Y_i u.i.v. $\sim \text{Ber}_p$, so ist (mit Satz 3.17, 2.)

$$\text{Var}[X] = \sum_{i=1}^n \text{Var}[Y_i] = n \text{Var}[Y_1] = np(1-p)$$

(vgl. auch Bsp. 3.16, 3.).

2. $X \sim \text{Hyp}_{s,w,n}$, so ist $\text{Var}[X] = np(1-p) \left(1 - \frac{n-1}{s+w-1}\right)$

$A_i = \{i\text{-te gez. Kugel schwarz}\}$

$Y_i = \mathbb{1}_{A_i}$, $X = Y_1 + Y_2 + \dots + Y_n$,

$$\text{Var}[X] = \sum_{i=1}^n \text{Var}[Y_i] + \sum_{i \neq j} \text{Cov}[Y_i, Y_j]$$

$$\begin{aligned} & \text{Var}[Y_1] \\ &= \frac{s}{s+w} \cdot \frac{w}{s+w} \\ &=: p \end{aligned}$$

$$\text{Cov}[Y_1, Y_2]$$

$$= \mathbb{E}[Y_1 \cdot Y_2] -$$

$$\mathbb{E}[Y_1] \cdot \mathbb{E}[Y_2]$$

$$= \left(\frac{s}{s+w}\right)^2$$

$$= np(1-p)$$

$$+ n(n-1) \underbrace{\frac{s}{s+w}}_{=p}$$

$$\left(\frac{s-1}{s+w-1} - \frac{s}{s+w} \right) = -\frac{w}{s+w} \frac{1}{s+w-1}$$

$$\frac{s}{s+w} \cdot \frac{s-1}{s+w-1}$$

$$= np(1-p) \left(1 - \frac{n-1}{s+w-1}\right)$$

(s schwarze,
w weiße Kugeln,
ziehe n mal
ohne Zurücklegen)

(vgl.
Diskussion
und im
Pölye-Ume)

3. Z reelle ZV mit $\mathbb{E}[|X|^3] < \infty$ und *symmetrischer* Verteilung, d.h. es gilt $P(Z > z) = P(Z < -z)$ für alle $z \geq 0$ (z.B. $Z \sim \mathcal{N}_{0,1}$), setze

$$Y := Z^2, \\ \mathbb{E}[|Z|^3] < \infty$$

$$\text{Cov}[Y, Z] = \underbrace{\mathbb{E}[Z^2 \cdot Z]}_{= \mathbb{E}[Z^3] = 0} - \mathbb{E}[Z^2] \cdot \underbrace{\mathbb{E}[Z]}_{= 0} = 0$$

d.h. Y und Z sind unkorreliert

(aber i. A. nicht unabh.)

Definition 3.20. Seien $X, Y \in \mathcal{L}^2$.

$$\kappa_{X,Y} := \frac{\text{Cov}[X, Y]}{\sqrt{\text{Var}[X] \text{Var}[Y]}} \in [-1, 1]$$

wg. Cauchy-Schwarz-Ungl.

heißt Korrelationskoeffizient von X und Y (manche Autoren schreiben auch $\rho_{X,Y}$).

Beobachtung 3.21 (Interpretation des Korrelationskoeffizienten via „beste lineare Vorhersage“). Es ist

$$\min_{\beta_0, \beta_1 \in \mathbb{R}} \mathbb{E}[(Y - \beta_1 X - \beta_0)^2] = (1 - \kappa_{X,Y}^2) \min_{\beta_0 \in \mathbb{R}} \mathbb{E}[(Y - \beta_0)^2] \quad (= (1 - \kappa_{X,Y}^2) \text{Var}[Y]),$$

$(Y - (\beta_0 + \beta_1 X))^2$

(siehe Skript)

$$\min_{\beta_0, \beta_1 \in \mathbb{R}} \mathbb{E}[(Y - \beta_1 X - \beta_0)^2] = (1 - \kappa_{X,Y}^2) \min_{\beta_0 \in \mathbb{R}} \mathbb{E}[(Y - \beta_0)^2] \quad \left(= (1 - \kappa_{X,Y}^2) \text{Var}[Y] \right),$$

Im Sinne einer möglichst kleinen quadratischen Abweichung ist $\mathbb{E}[Y]$ die beste konstante „Vorhersage“ von Y . Man kann demnach um einen Faktor $(1 - \kappa_{X,Y}^2)$ besser vorhersagen, wenn man stattdessen eine affin-lineare Funktion von X verwenden darf.


Demnach (vgl. auch Bem. 3.18)

$|\kappa_{X,Y}| = 1 \iff$ perfekter linearer Zusammenhang zwischen X und Y


$\kappa_{X,Y} = 1 \iff$ perfekter linearer Zusammenhang zwischen X und Y
mit positivem Koeffizienten
(X größer als $\mathbb{E}[X] \iff Y$ größer als $\mathbb{E}[Y]$)

$\kappa_{X,Y} = -1 \iff$ perfekter linearer Zusammenhang zwischen X und Y
mit negativem Koeffizienten
(X größer als $\mathbb{E}[X] \iff Y$ kleiner als $\mathbb{E}[Y]$)


Nicht-lineare Zusammenhänge erfasst der Korrelationskoeffizient möglicherweise nicht korrekt (oder gar nicht), vgl. Bsp. 3.19, 3.



Die Scatterplots zeigen jeweils 100 simulierte Paare (X, Y) , wobei $\sigma_X = \sigma_Y = 1$ und $\kappa_{X,Y}$ den angegebenen Wert hat. (Blau eingezeichnet ist die „Vorhersagegerade“ $x \mapsto \beta_1^* x + \beta_0^*$.)



Die Scatterplots zeigen jeweils 100 simulierte Paare (X, Y) , wobei $\sigma_X = \sigma_Y = 1$ und $\kappa_{X,Y}$ den angegebenen Wert hat. (Blau eingezeichnet ist die „Vorhersagegerade“ $x \mapsto \beta_1^* x + \beta_0^*$.)



Die Scatterplots zeigen jeweils 100 simulierte Paare (X, Y) , wobei $\sigma_X = \sigma_Y = 1$ und $\kappa_{X,Y}$ den angegebenen Wert hat. (Blau eingezeichnet ist die „Vorhersagegerade“ $x \mapsto \beta_1^* x + \beta_0^*$.)