

Statistische Grundlagen – Ein kurzer Überblick (diskret)

Die wichtigsten Begriffe und Definitionen:

- 1) Erwartungswert
- 2) Varianz / Standardabweichung
- 3) Stichprobenvarianz
- 4) Kovarianz
- 5) Korrelationskoeffizient
- 6) Unabhängigkeit vs. Unkorreliertheit
- 7) Normalverteilung und Standardnormalverteilung

Erklärungen und Rechnungen im Anhang.

Zu 1)

Ganz allgemein: Wenn $g(X)$ eine eindeutige Funktion der Zufallsvariablen X ist, dann ist auch $g(X)$ eine Zufallsvariable. Der Erwartungswert der Zufallsvariablen $g(X)$ wird im diskreten Fall definiert durch:

$$\mathbf{E}[g(\mathbf{X})] = \sum_{k=1}^n \mathbf{p}_k \cdot \mathbf{g}(\mathbf{x}_k).$$

Den Erwartungswert der Zufallsgröße X selbst erhält man mit $g(X)=X$:

$$\mu_X = \mathbf{E}[\mathbf{X}] = \sum_{k=1}^n \mathbf{p}_k \cdot \mathbf{x}_k.$$

Beispiel siehe Anhang: i

In der Vorlesung betrachten wir die den Erwartungswert eines Portfolios mit Anteilen x_i investiert in Aktie i . Weiter bezeichnet r_i die Rendite der Aktie i

Der erwartete Portfolioreturn ist gegeben durch:

$$\mathbf{E}[\mathbf{X}] = \mu = \sum_{i=1}^n x_i \cdot r_i.$$

Bem.: Die Rendite unseres Portfolio ist somit schon ein Erwartungswert.

Der Erwartungswert für n Variablen (Aktien) , d.h. $\mathbf{E}[\mathbf{X}] = \mu = \mathbf{x}_1 \cdot \mathbf{r}_1 + \mathbf{x}_2 \cdot \mathbf{r}_2 + \dots + \mathbf{x}_n \cdot \mathbf{r}_n$.

Betrachte im folgenden den Fall für

n=1: $\mathbf{E}[\mathbf{aX} + \mathbf{b}] = \mathbf{a} \cdot \mathbf{E}[\mathbf{X}] + \mathbf{b}$, Beispiel dazu siehe Anhang: ii

und n=2: $\mathbf{E}[\mathbf{aX} + \mathbf{bY}] = \mathbf{a} \cdot \mathbf{E}[\mathbf{X}] + \mathbf{bE}[\mathbf{Y}]$, Beispiel dazu siehe Anhang: iii

Zu 2)

Die Varianz ist die mittlere quadratische Abweichung

$$\mathbf{V}[\mathbf{X}] = \sigma^2 = \mathbf{E}[\mathbf{X} - \mathbf{E}(\mathbf{X})]^2 ,$$

Nach dem „Satz von Steiner“ kann die Varianz auch geschrieben werden als:

$$\mathbf{V}[\mathbf{X}] = \sigma^2 = \mathbf{E}[\mathbf{X}^2] - [\mathbf{E}(\mathbf{X})]^2 .$$

Die Standardabweichung ist definiert als die positive Quadratwurzel der Varianz

$$\sigma = \sqrt{\sigma^2} .$$

Zu 3)

Mit dem arithmetischen Mittel der Verteilung $\bar{\mathbf{x}} = \frac{1}{\mathbf{n}} \sum_{i=1}^{\mathbf{n}} \mathbf{x}_i$ lautet die Stichprobenvarianz mit n-1

Freiheitsgraden:

$$\mathbf{S}^2 = \hat{\sigma}^2 = \frac{1}{\mathbf{n}-1} \sum_{i=1}^{\mathbf{n}} (\mathbf{x}_i - \bar{\mathbf{x}})^2$$

Es gilt: $\mathbf{E}[\mathbf{S}^2] = \sigma^2$, damit ist \mathbf{S}^2 ein unverzerrter Schätzer für die Varianz σ^2 .

Beweis siehe Anhang: iv

Zu 4)

Die Kovarianz ist ein Maß für den linearen Zusammenhang von X und Y und lautet:

$$\mathbf{Cov}(\mathbf{X}, \mathbf{Y}) = \sigma_{\mathbf{X}, \mathbf{Y}} = \mathbf{E}[(\mathbf{X} - \mathbf{E}(\mathbf{X})) \cdot (\mathbf{Y} - \mathbf{E}(\mathbf{Y}))] = \mathbf{E}[\mathbf{XY}] - \mathbf{E}[\mathbf{X}] \cdot \mathbf{E}[\mathbf{Y}]$$

Zu 5)

Der Korrelationskoeffizient ist auf das Intervall $[-1,1]$ normiert und hat die folgende Form

$$\text{Corr}(\mathbf{X}, \mathbf{Y}) = \rho_{\mathbf{X}, \mathbf{Y}} = \frac{\text{Cov}(\mathbf{X}, \mathbf{Y})}{\sqrt{\mathbf{V}(\mathbf{X}) \cdot \mathbf{V}(\mathbf{Y})}} = \frac{\sigma_{\mathbf{X}, \mathbf{Y}}}{\sigma_{\mathbf{X}} \cdot \sigma_{\mathbf{Y}}}$$

Aus 5) ergibt sich die Umformung, die in den Übungen verwendet wird:

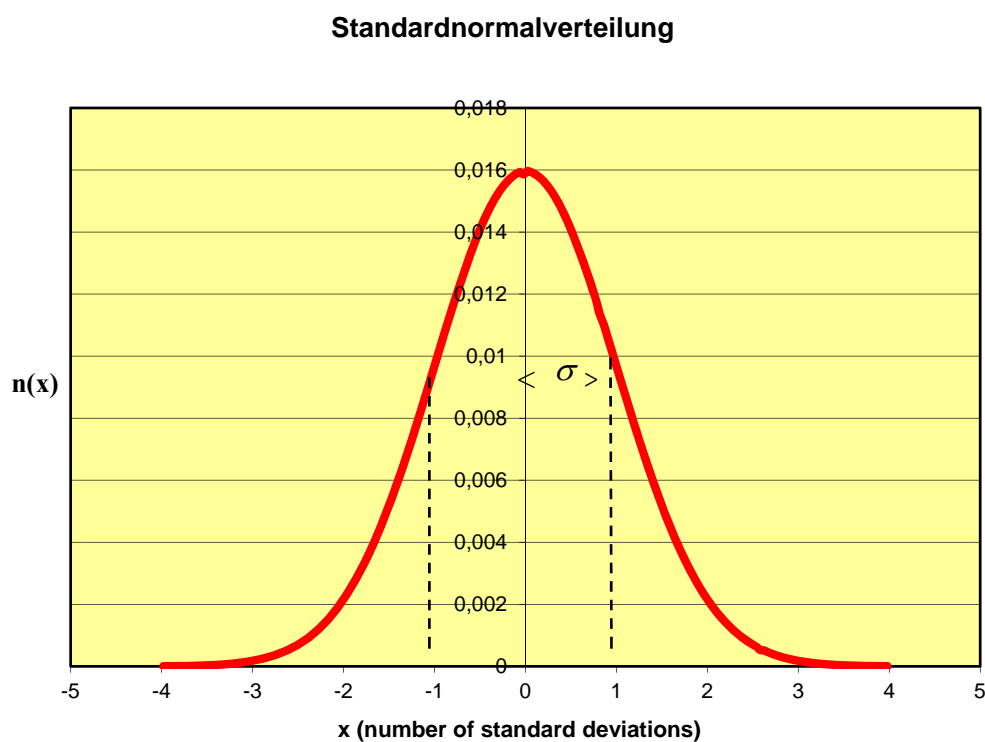
$$\text{Cov}(\mathbf{X}, \mathbf{Y}) = \sigma_{\mathbf{X}, \mathbf{Y}} = \rho_{\mathbf{X}, \mathbf{Y}} \cdot \sqrt{\mathbf{V}(\mathbf{X}) \cdot \mathbf{V}(\mathbf{Y})} \Leftrightarrow \text{Cov}(\mathbf{X}, \mathbf{Y}) = \rho_{\mathbf{X}, \mathbf{Y}} \cdot \sigma_{\mathbf{X}} \cdot \sigma_{\mathbf{Y}}$$

Zu 6)

Aus der Unkorreliertheit folgt im Allgemeinen noch nicht, dass die Zufallsvariablen auch unabhängig sind. Dies ist nur bei symmetrischen Verteilungen wie z.B. der Normalverteilung der Fall.

Zu 7)

Eine Zufallsvariable X heißt normalverteilt, kurz $X \sim N(\mu, \sigma^2)$, falls ihre Dichte normalverteilt ist mit Parametern μ und σ^2 .



Eine Normalverteilung mit $\mu = 0$ und $\sigma^2 = 1$ heißt Standardnormalverteilung, kurz $N(0,1)$.

Sie besitzt die Dichtefunktion $n(\mathbf{x}) = \frac{1}{\sqrt{2\pi}} e^{-\frac{x^2}{2}}$, wie in dem Graph oben gezeichnet.

Einige Eigenschaften der Normalverteilung:

- unimodale Verteilung
- symmetrische Verteilung mit Maximum bei $x = \mu$
- Wendepunkte bei $x = \mu \pm \sigma$
- $E(X) = \mu$, $\text{Var}(X) = \sigma^2$

Jede Normalverteilung kann in eine Standardnormalverteilung transformiert werden.

Sei X eine Normalverteilte Zufallsvariable, $X \sim N(\mu, \sigma^2)$. Dann ist die Transformation $\mathbf{U} := \frac{\mathbf{X} - \mu}{\sigma}$,

eine standardnormalverteilte Zufallsvariable. Aus diesem Grund können alle Berechnungen (Wahrscheinlichkeiten, quantile, usw.) basierend auf einer Standardnormalverteilung durchgeführt werden und müssen nicht für jede $N(\mu, \sigma^2)$ -Verteilte Zufallsvariable einzeln berechnet werden.

Sei \mathbf{x}_p das Quantil einer Normalverteilung mit Parametern μ und σ^2 von der Ordnung p und sei λ_p das Quantil einer Standardnormalverteilung ($\mu=0$ und $\sigma^2=1$). Dann gilt:

$$\mathbf{x}_p = \mu + \lambda_p \cdot \sigma, \forall p \in (0,1).$$

Bei einer Normalverteilung liegt das Konfidenzintervall symmetrisch um den Erwartungswert der Verteilung. Das Konfidenzintervall, einer $N(\mu, \sigma^2)$ verteilten Zufallsvariable, zum Signifikanzniveau α kann aus den Quantilen der $N(0,1)$ -Verteilung bestimmt werden. Es gilt

$$\mathbf{P}\left(\mu - \lambda_{1-\frac{\alpha}{2}} \cdot \sigma \leq \mathbf{X} \leq \mu + \lambda_{1-\frac{\alpha}{2}} \cdot \sigma\right) = 1 - \alpha, \text{ mit } \lambda_p = -\lambda_{1-p}.$$

Andererseits lässt sich für gegebene Quantile die Wahrscheinlichkeit bestimmen, dass die Realisationen der Verteilung innerhalb des Intervalls $\mu \pm \lambda_{1-\frac{\alpha}{2}} \sigma$ liegen. Diese Wahrscheinlichkeit kann als relative Häufigkeit interpretiert werden.

Für $\lambda_{1-\frac{\alpha}{2}} = K$ erhalten wir die relative Häufigkeit bei einem Interquartilsabstand von $K \cdot \sigma$. Zum Beispiel:

$$K=1: \quad P(\mu - \sigma \leq X \leq \mu + \sigma) = 0.6827$$

d.h. ungefähr 68% aller Realisationen der Normalverteilung liegen innerhalb des Intervalls $\mu \pm \sigma$.

$$K=2: \quad \mathbf{P}(\mu - 2\sigma \leq \mathbf{X} \leq \mu + 2\sigma) = 0,9545$$

d.h. ungefähr 95% aller Realisationen der Normalverteilung liegen innerhalb des Intervalls $\mu \pm 2\sigma$.

$$K=3: \quad \mathbf{P}(\mu - 3\sigma \leq \mathbf{X} \leq \mu + 3\sigma) = 0,9973$$

d.h. ungefähr 99.7% aller Realisationen der Normalverteilung liegen innerhalb des Intervalls $\mu \pm 3\sigma$.

Anhang:

i Ein *Beispiel* dafür ist der Erwartungswert einer Verteilungsfunktion $P(X = x_i)$ im diskreten Fall:

$$E[X] = \sum_{i=1}^n x_i \cdot p(x_i) = \sum_{i=1}^n x_i \cdot P(X = x_i)$$

ii *Beispiel zu Folie 8* aus Risiko und Ertrag:

Vorraussetzung: Diskrete Zufallsvariable X mit Dichte $f(x)$, und die Konstanten a und b .

Behauptung: $E[aX + b] = a \cdot E[X] + b$

$$\begin{aligned} \text{Beweis: } E[aX + b] &= \sum_{i=1}^m (ax_i + b) \cdot f(x_i) \\ &= \sum_i ax_i f(x_i) + bf(x_i) \\ &= a \sum_i x_i f(x_i) + b \sum_i f(x_i) \\ &= aE[X] + b. \end{aligned}$$

q.e.d.

Analog lässt sich der Zusammenhang für die Varianz $V[aX + b] = a^2 \cdot V[X]$ zeigen.

iii Ebenso für die Varianz: $V[aX + bY] = a^2 \cdot V[X] + b^2 V[Y] + 2 \cdot a \cdot b \cdot \text{Cov}(X, Y)$
 $\Leftrightarrow V[aX + bY] = a^2 \cdot V[X] + b^2 V[Y] + 2 \cdot a \cdot b \cdot \sigma_X \cdot \sigma_Y \cdot \rho_{X,Y}$

iv *Rechnung dazu:*

$$\begin{aligned} E[S^2] &= E\left[\frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2\right] \\ &= \frac{n}{n-1} \cdot \frac{1}{n} E\left[\sum_{i=1}^n (x_i - \bar{x})^2\right] \\ &= \frac{n}{n-1} \cdot \frac{1}{n} \sum_i E[(x_i - \bar{x})^2] = \frac{n}{n-1} \cdot \frac{1}{n} \sum_i E[(\{x_i - \mu\} - \{\bar{x} - \mu\})^2] \end{aligned}$$

mit Binomischer Formel und $E[(\bar{x} - \mu)] = \frac{\sigma}{n}$ folgt

$$\begin{aligned} E[S^2] &= \frac{n}{n-1} \cdot \frac{1}{n} \left[n \cdot \sigma^2 + \frac{n\sigma^2}{n} - 2 \cdot E[(\bar{x} - \mu)] \sum (x_i - \mu) \right] \\ &= \frac{n}{n-1} \left[\sigma^2 + \frac{\sigma^2}{n} - \frac{2\sigma^2}{n} \right] = \frac{n}{n-1} \left[1 + \frac{1}{n} - \frac{2}{n} \right] \sigma^2 = \sigma^2. \end{aligned}$$

q.e.d.