

Wahrscheinlichkeitsrechnung und Statistik  
im Biologie-Bachelorstudiengang der LMU  
**Wiederholung zum Rechnen mit Zufallsvariablen,  
Erwartungswerten und (Co-)Varianzen**

Dirk Metzler

29. Juli 2020

## Inhaltsverzeichnis

<b>1</b>	<b>Zufallsvariablen</b>	<b>1</b>
1.1	Was sind Zufallsvariablen und Verteilungen? . . . . .	1
1.2	Rechnen mit Zufallsvariablen . . . . .	3
1.3	Stochastische (Un-)Abhängigkeit, bedingte Wahrscheinlichkeiten . . . . .	5
<b>2</b>	<b>Erwartungswerte</b>	<b>7</b>
<b>3</b>	<b>Varianz, Standardabweichung, Kovarianz und Korrelation</b>	<b>8</b>

## 1 Zufallsvariablen

### 1.1 Was sind Zufallsvariablen und Verteilungen?

Nehmen wir an, in einer kleinen Population von  $n = 100$  Individuen hat ein neutrales Allel A in der aktuellen Generation eine Häufigkeit von 0.32.

Wie wird die Häufigkeit  $X$  von A in der nächsten Generation sein?

Das können wir nicht genau vorhersagen, denn es hängt vom Zufall ab.

$X$  ist eine [Zufallsvariable](#).

Berechnen können wir aber z.B.:

$EX$  : den Erwartungswert von  $X$ ,

$\Pr(X = 0.32)$  : die Wahrscheinlichkeit, dass  $X$  einen bestimmten Wert annimmt.

Allerdings müssen wir dazu die Population zunächst stochastisch modellieren, und das Ergebnis wird davon abhängen, wie wir das machen.

### Beispiele für Zufallsvariablen

- Ergebnis eines Würfelwurfs
- Karte, die aus einem gemischten Kartenspiel gezogen wird
- Koordinatenpaar des Pfeils in einer Dart-Scheibe

- Größe eines zufällig gezogenen Individuums aus einer Population
- Mittelwert der Größe von 10 aus einer Population gezogenen Individuen
- Jede Statistik, d.h. aus Daten berechnete Werte

Als **Zufallsgröße oder Zufallsvariable** bezeichnet man das (Mess-)Ergebnis eines zufälligen Vorgangs.

Der **Wertebereich  $\mathcal{S}$**  (engl. state space) einer Zufallsgröße ist die Menge aller möglichen Werte.

Die **Verteilung einer Zufallsgröße  $X$**  weist jeder Menge  $A \subseteq \mathcal{S}$  die **Wahrscheinlichkeit  $\Pr(X \in A)$**  zu, dass  $X$  einen Wert in  $A$  annimmt.

Für Zufallsgrößen werden üblicherweise Großbuchstaben verwendet (z.B.  $X, Y, Z$ ), für konkrete Werte Kleinbuchstaben.

### Binomialverteilung

Sei  $X$  die Anzahl der Erfolge bei  $n$  unabhängigen Versuchen mit Erfolgswahrscheinlichkeit von jeweils  $p$ . Dann gilt für  $k \in \{0, 1, \dots, n\}$

$$\Pr(X = k) = \binom{n}{k} p^k \cdot (1 - p)^{n-k}$$

und  $X$  heißt **binomialverteilt**, kurz:

$$X \sim \text{bin}(n, p).$$

Die Wahrscheinlichkeitsverteilung der Binomialverteilung weist jeder Teilmenge  $U \subseteq \{0, 1, \dots, n\}$  die folgende Wahrscheinlichkeit zu:


$$\Pr(X \in U) = \sum_{k \in U} \binom{n}{k} p^k \cdot (1 - p)^{n-k}$$

Sei  $X$  normalverteilt mit Mittelwert  $\mu$  und Varianz  $\sigma^2$ , kurz:

$$X \sim \mathcal{N}(\mu, \sigma^2)$$

$X$  hat dann die Dichte

$$f(x) = \frac{1}{\sqrt{2\pi}\sigma} \cdot e^{-\frac{(x-\mu)^2}{2\sigma^2}}.$$



“Gauß-Glocke” mit  $\mu = 0$   
und  $\sigma = 1$


Die Verteilung von  $X$  ordnet jeder messbaren<sup>1</sup> Teilmenge  $U$  von  $\mathbb{R}$  die Wahrscheinlichkeit

$$\Pr(X \in U) = \int_U \frac{1}{\sqrt{2\pi}\sigma} \cdot e^{-\frac{(x-\mu)^2}{2\sigma^2}} dx$$

zu.


$$f(x) = \frac{1}{\sqrt{2\pi}\sigma} \cdot e^{-\frac{(x-\mu)^2}{2\sigma^2}}$$

<sup>1</sup>erforderliche Einschränkung, damit das Integral überhaupt existiert (mathematisch etwas komplizierter)



### Dichten brauchen Integrale

Sei  $Z$  eine Zufallsvariable mit Dichte  $f(x)$ .



Dann gilt

$$\Pr(Z \in [a, b]) = \int_a^b f(x) dx.$$

Frage: Wie berechnet man  $\Pr(Z = 5)$ ?

Antwort: Für jedes  $x \in \mathbb{R}$  gilt  $\Pr(Z = x) = 0$  (da Fläche der Breite 0)

Was wird dann aus  $\mathbb{E}Z = \sum_{x \in \mathcal{S}} x \cdot \Pr(Z = x)$  ?

Bei einer kontinuierlichen Zufallsvariable mit Dichtefunktion  $f$  definiert man:

$$\mathbb{E}Z := \int_{-\infty}^{\infty} x \cdot f(x) dx$$

### Die Normalverteilung in $R$

Die Normalverteilung hat in  $R$  das Kürzel 'norm'.

Es gibt 4  $R$ -Befehle:

- dnorm()**: Dichte der Normalverteilung (**d**ensity)
- rnorm()**: Ziehen einer Stichprobe (**r**andom **s**ample)
- pnorm()**: Verteilungsfunktion der Normalverteilung (**p**robability)
- qnorm()**: Quantilfunktion der Normalverteilung (**q**uantile)

## 1.2 Rechnen mit Zufallsvariablen

Zufallsvariablen, deren Werte Zahlen oder Vektoren sind, heißen auch Zufallszahlen bzw. -vektoren.

Mit ihnen kann man rechnen.

### Rechnen mit Zufallsvariablen

Am Beispiel der Summe  $W_1 + W_2$  zweier Würfelresultate  $W_1, W_2$  haben wir gesehen, dass man mit Zufallsvariablen auch wie mit normalen Variablen rechnen kann. Auch  $W_1 + W_2$  ist wieder eine Zufallsvariable und es gilt:

$$\begin{aligned}\Pr(W_1 + W_2 = k) &= \sum_{\{(x,y) : x+y=k\}} \Pr(W_1 = x, W_2 = y) \\ &= \sum_x \Pr(W_1 = x, W_2 = k - x)\end{aligned}$$

In Worten:  $\Pr(W_1 + W_2 = k)$  ist die Summe der Wahrscheinlichkeiten aller Wertepaare für  $W_1$  und  $W_2$ , die in Summe  $k$  ergeben.

### Rechnen mit Zufallsvariablen

Sie können Zufallsvariablen auch mit Zahlen multiplizieren. Stellen Sie sich z.B. vor, dass Sie bei einem Brettspiel die "Speed-Karte" gezogen haben, die Ihnen erlaubt, immer das Doppelte  $D = 2 \cdot W$  der gewürfelten Augenzahl  $W$  voranzuschreiten.

Dann ist  $D = 2 \cdot W$  ebenfalls eine Zufallsvariable. Ihre möglichen Werte sind 2,4,6,8,10 und 12, und  $D$  nimmt jeden dieser Werte mit Wahrscheinlichkeit  $\frac{1}{6}$  an.

### Anwendung einer Funktion auf eine Zufallsvariable

Wenn man eine Funktion  $f$  auf eine Zufallsvariable  $X$  anwendet, erhält man eine Zufallsvariable  $Y = f(X)$ .


Als Beispiel stellen wir uns ein Spiel vor, bei dem man, wenn man das Würfelresultat  $X$  hat,  $f(X) = (X - 3)^2$  Felder vorrücken darf.

Dann ist die Wahrscheinlichkeit, dass man 4 Felder vorrücken darf, also dass die Zufallsvariable  $f(X)$  den Wert 4 hat (also  $X$  den Wert 1 oder 5):

$$\Pr(f(X) = 4) = \Pr(X \in \{1, 5\}) = 1/3.$$

Um das mathematisch klar zu fassen, benötigen wir den Begriff **Urbild**: Für eine Menge  $M$  ist  $f^{-1}(M) = \{x : f(x) \in M\}$  das **Urbild** von  $M$  unter  $f$ , also in Worten: die Menge aller  $x$ , die von  $f$  auf ein Element von  $M$  abgebildet werden.

### Das Urbild einer Menge unter einer Funktion $f$




Die Funktion  $f : x \mapsto (x - 3)^2$  für  $x \in \{1, 2, 3, 4, 5, 6\}$  ist nicht umkehrbar. So ist  $f^{-1}(4)$  nicht definierbar, denn es wäre ja auch  $f(1) = 4 = f(5)$ . Etwas anderes ist jedoch  $f^{-1}(\{4\})$ . Hier ist mit  $f^{-1}$  keine Umkehrfunktion gemeint, sondern die

**Urbildfunktion**, die auf Mengen operiert:

$$f^{-1}(\{4\}) = \{x : f(x) \in \{4\}\} = \{1, 5\}$$

Oder z.B.:

$$f^{-1}([0.5, 5]) = \{x : f(x) \in [0.5, 5]\} = \{1, 2, 4, 5\}$$



### 1.3 Stochastische (Un-)Abhängigkeit, bedingte Wahrscheinlichkeiten

#### Stochastische Unabhängigkeit

**Definition 1 (stochastische Unabhängigkeit)** Ereignisse  $U$  und  $V$  sind *(stochastisch) unabhängig*, wenn gilt

$$\Pr(U, V) = \Pr(U) \cdot \Pr(V).$$

Zwei Zufallsgrößen  $X$  und  $Y$  sind *(stochastisch) unabhängig*, wenn jedes Ereignis der Art  $\{X \in A\}$  von jedem Ereignis der Art  $\{Y \in B\}$  stochastisch unabhängig ist.

Beispiel:

- Werfen zweier Würfel:  $X =$  Augenzahl Würfel 1,  $Y =$  Augenzahl Würfel 2.

$$\Pr(X = 2, Y = 5) = \frac{1}{36} = \frac{1}{6} \cdot \frac{1}{6} = \Pr(X = 2) \cdot \Pr(Y = 5)$$

“Stochastisch unabhängig” bedeutet nicht immer, dass zwei Zufallsexperimente ganz unabhängig voneinander durchgeführt wurden. Z.B. beim Ziehen einer Karte aus einem Spiel mit 32 Karten sei

**Ereignis  $A$ :** Die gezogene Karte ist ein Ass

**Ereignis  $\heartsuit$ :** Die gezogene Karte ist von der Farbe Herz

Dann gilt

$$\Pr(\heartsuit, A) = \frac{1}{32} = \frac{1}{4} \cdot \frac{1}{8} = \Pr(\heartsuit) \cdot \Pr(A).$$

Also sind die Ereignisse  $A$  und  $\heartsuit$  stochastisch unabhängig.

- **Bedingte Wahrscheinlichkeit:** Wahrscheinlichkeit des Ereignisses  $U$  unter der Bedingung  $V$

$$\Pr(U|V) := \frac{\Pr(U, V)}{\Pr(V)}$$

„bedingte Wahrscheinlichkeit von  $U$ , gegeben  $V$ “

Daraus ergibt sich also auch:

$$\Pr(U, V) = \Pr(V) \cdot \Pr(U|V) = \Pr(U) \cdot \Pr(V|U)$$

$A, B$  Ereignisse

Bedingte Wahrscheinlichkeit von  $A$ , gegeben  $B$  (sofern  $\Pr(B) > 0$ ):

$$\Pr(A|B) = \frac{\Pr(A \cap B)}{\Pr(B)}$$

( $A \cap B := A$  und  $B$  treten beide ein) “gegeben  $B$ ” bedeutet: wenn man schon weiß, dass  $B$  eintritt oder eingetreten ist [0.3cm] Satz von der totalen Wahrscheinlichkeit (mit  $B^c := \{B \text{ tritt nicht ein}\}$ ):

$$\Pr(A) = \Pr(B) \Pr(A|B) + \Pr(B^c) \Pr(A|B^c)$$

Bayes-Formel:

$$\Pr(B|A) = \frac{\Pr(B) \Pr(A|B)}{\Pr(A)}$$

Beispiel medizinischer Test, etwa Mammographie:

$A$ : Das Mammogramm zeigt Krebs an.

$B$ : Die Patientin hat Krebs.

Die nicht bedingte Wahrscheinlichkeit  $\Pr(B)$  heißt auch *a-priori*-Wahrscheinlichkeit für  $B$ , d.h. die Wahrscheinlichkeit, die man  $B$  zuordnet, *bevor* man die Daten  $A$  gesehen hat. In unserem Beispiel war 0.008 die Wahrscheinlichkeit, dass eine Vorsorgepatientin Brustkrebs hat. [0.5cm] Die bedingte Wahrscheinlichkeit  $\Pr(B|A)$  heißt auch *a-posteriori*-Wahrscheinlichkeit für  $B$ . Das ist die Wahrscheinlichkeit, die man  $B$  zuweist, *nachdem* man die Daten  $A$  gesehen hat.

Die bedingte Wahrscheinlichkeit, dass die Patientin Krebs hat, gegeben, dass das Mammogramm dies anzeigt, ist:

$$\begin{aligned} \Pr(B|A) &= \frac{\Pr(B) \cdot \Pr(A|B)}{\Pr(A)} \\ &= \frac{\Pr(B) \cdot \Pr(A|B)}{\Pr(B) \cdot \Pr(A|B) + \Pr(B^c) \cdot \Pr(A|B^c)} \end{aligned}$$

Mit den Werten aus dem Beispiel aus der Vorlesung:

$$= \frac{0.008 \cdot 0.9}{0.008 \cdot 0.9 + 0.992 \cdot 0.07} \approx 0.0939$$

Bedingt darauf, dass das Mammogramm Krebs anzeigt, beträgt die Wahrscheinlichkeit, dass die Patientin Krebs hat, also lediglich 9.4%.

## 2 Erwartungswerte

**Definition 2 (Erwartungswert)** Sei  $X$  eine Zufallsvariable mit endlichem oder abzählbarem Wertebereich  $\mathcal{S} = \{x_1, x_2, x_3, \dots\} \subseteq \mathbb{R}$ . Dann ist der *Erwartungswert* von  $X$  definiert durch

$$\mathbb{E}X = \sum_{x \in \mathcal{S}} x \cdot \Pr(X = x)$$

Bei einer kontinuierlichen Zufallsvariable  $Z$  mit Dichtefunktion  $f$  lautet die Definition:

$$\mathbb{E}Z := \int_{-\infty}^{\infty} x \cdot f(x) dx$$

### Beispiele

- Sei  $X$  eine 0-1-Zufallsvariable mit Erfolgswahrscheinlichkeit  $p \in [0, 1]$ . Dann gilt

$$\mathbb{E}X = 1 \cdot \Pr(X = 1) + 0 \cdot \Pr(X = 0) = \Pr(X = 1) = p$$

- Sei  $W$  die Augenzahl bei einem Würfelwurf. Dann gilt

$$\begin{aligned} \mathbb{E}W &= 1 \cdot \Pr(W = 1) + 2 \cdot \Pr(W = 2) + \dots + 6 \cdot \Pr(W = 6) \\ &= 1 \cdot \frac{1}{6} + 2 \cdot \frac{1}{6} + \dots + 6 \cdot \frac{1}{6} = 21 \frac{1}{6} = 3.5 \end{aligned}$$

- Ist  $k_x$  die Häufigkeit des Wertes  $x$  in einer Gesamtheit der Größe  $n$ , aus der rein zufällig gezogen wird, so folgt:

$$\mathbb{E}X = \sum_x x \cdot \frac{k_x}{n} = \frac{\sum_x x \cdot k_x}{n}$$

### Rechnen mit Erwartungswerten

**Satz 1 (Linearität des Erwartungswerts)** Sind  $X$  und  $Y$  Zufallsvariablen mit Werten in  $\mathbb{R}$  und ist  $a \in \mathbb{R}$ , so gilt:

- $\mathbb{E}(a \cdot X) = a \cdot \mathbb{E}X$
- $\mathbb{E}(X + Y) = \mathbb{E}X + \mathbb{E}Y$

**Satz 2 (Nur für Unabhängige!)** Sind  $X$  und  $Y$  *stochastisch unabhängige* Zufallsvariablen mit Werten in  $\mathbb{R}$ , so gilt

- $\mathbb{E}(X \cdot Y) = \mathbb{E}X \cdot \mathbb{E}Y$ .

Im allgemeinen gilt  $\mathbb{E}(X \cdot Y) \neq \mathbb{E}X \cdot \mathbb{E}Y$ . Beispiel:

$$\mathbb{E}(W \cdot W) = \frac{91}{6} = 15.167 > 12.25 = 3.5 \cdot 3.5 = \mathbb{E}W \cdot \mathbb{E}W$$

### Erwartungswert der Binomialverteilung

Seien  $Y_1, Y_2, \dots, Y_n$  die Indikatorvariablen der  $n$  unabhängigen Versuche d.h.

$$Y_i = \begin{cases} 1 & \text{falls der } i\text{-te Versuch gelingt} \\ 0 & \text{falls der } i\text{-te Versuch scheitert} \end{cases}$$

Dann ist  $X = Y_1 + \dots + Y_n$  binomialverteilt mit Parametern  $(n, p)$ , wobei  $p$  die Erfolgswahrscheinlichkeit der Versuche ist.

Wegen der Linearität des Erwartungswerts gilt

$$\begin{aligned} \mathbb{E}X &= \mathbb{E}(Y_1 + \dots + Y_n) \\ &= \mathbb{E}Y_1 + \dots + \mathbb{E}Y_n \\ &= p + \dots + p = np \end{aligned}$$

Wir halten fest:

$$X \sim \text{bin}(n, p) \Rightarrow \mathbb{E}X = n \cdot p$$

## 3 Varianz, Standardabweichung, Kovarianz und Korrelation

**Definition 3 (Varianz, Kovarianz und Korrelation)** Die *Varianz* einer  $\mathbb{R}$ -wertigen Zufallsgröße  $X$  ist

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

$\sigma_X = \sqrt{\text{Var}X}$  ist die *Standardabweichung*.

Ist  $Y$  eine weitere reellwertige Zufallsvariable, so ist

$$\text{Cov}(X, Y) = \mathbb{E}[(X - \mathbb{E}X) \cdot (Y - \mathbb{E}Y)]$$

die *Kovarianz* von  $X$  und  $Y$ .

Die *Korrelation* von  $X$  und  $Y$  ist

$$\text{Cor}(X, Y) = \frac{\text{Cov}(X, Y)}{\sigma_X \cdot \sigma_Y}.$$

Die Varianz

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

ist die durchschnittliche quadrierte Abweichung vom Mittelwert.

Die Korrelation

$$\text{Cor}(X, Y) = \frac{\text{Cov}(X, Y)}{\sigma_X \cdot \sigma_Y}$$

liegt immer im Intervall  $[-1, 1]$ . Die Variablen  $X$  und  $Y$  sind

- **positiv korreliert**, wenn  $X$  und  $Y$  tendenziell entweder beide überdurchschnittlich große Werte oder beide unterdurchschnittlich große Werte annehmen.
- **negativ korreliert**, wenn  $X$  und  $Y$  tendenziell auf verschiedenen Seiten ihrer Erwartungswerte liegen.

Sind  $X$  und  $Y$  unabhängig, so sind sie auch **unkorreliert**, d.h.  $\text{Cor}(X, Y) = 0$ .

### Bernoulli-Verteilung

Eine Bernoulli-verteilte Zufallsvariable  $Y$  mit Erfolgsws  $p \in [0, 1]$  hat Erwartungswert

$$\mathbb{E}Y = p$$

und Varianz

$$\text{Var}Y = p \cdot (1 - p)$$

**Beweis:** Aus  $\Pr(Y = 1) = p$  und  $\Pr(Y = 0) = (1 - p)$  folgt

$$\mathbb{E}Y = 1 \cdot p + 0 \cdot (1 - p) = p.$$

Varianz:

$$\begin{aligned} \text{Var } Y &= \mathbb{E}(Y^2) - (\mathbb{E}Y)^2 \\ &= 1^2 \cdot p + 0^2 \cdot (1 - p) - p^2 = p \cdot (1 - p) \end{aligned}$$

### Beispiel: Würfel

Varianz des Würfelergebnisses  $W$ :

$$\begin{aligned} \text{Var}(W) &= \mathbb{E}[(W - \mathbb{E}W)^2] \\ &= \mathbb{E}[(W - 3.5)^2] \\ &= (1 - 3.5)^2 \cdot \frac{1}{6} + (2 - 3.5)^2 \cdot \frac{1}{6} + \dots + (6 - 3.5)^2 \cdot \frac{1}{6} \\ &= \frac{17.5}{6} \\ &= 2.91667 \end{aligned}$$

### Beispiel: Die empirische Verteilung

Sind  $x_1, \dots, x_n \in \mathbb{R}$  Daten und entsteht  $X$  durch rein zufälliges Ziehen aus diesen Daten (d.h.  $\Pr(X = x) = \frac{n_x}{n}$ , wobei  $n_x = |\{i : x_i = x\}|$  die Anzahl der  $x_i$  ist mit  $x_i = x$ ), so gilt:

$$\mathbb{E}X = \sum_x x \cdot \frac{n_x}{n} = \sum_{i=1}^n x_i \cdot \frac{1}{n} = \frac{1}{n} \sum_{i=1}^n x_i = \bar{x}$$

und

$$\text{Var } X = \mathbb{E}[(X - \mathbb{E}X)^2] = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2$$

Sind  $(x_1, y_1), \dots, (x_n, y_n) \in \mathbb{R} \times \mathbb{R}$  Daten und entsteht  $(X, Y)$  durch rein zufälliges Ziehen aus diesen Daten (d.h.  $\Pr((X, Y) = (x, y)) = \frac{|\{i : (x_i, y_i) = (x, y)\}|}{n}$ ), so gilt:

$$\text{Cov}(X, Y) = \mathbb{E}[(X - \mathbb{E}X)(Y - \mathbb{E}Y)] = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})$$

**Definition 4 (Korrigierte Stichprobenvarianz, -standardabweichung und -kovarianz)** Ist  $x_1, x_2, \dots, x_n$  eine Stichprobe der Zufallsgrößen  $X$ , schätzen wir die Varianzen  $\sigma_X^2$  und die Standardabweichung  $\sigma_X$  von  $X$  in der Regel durch

$$s_x^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2 \quad \text{und} \quad s_x = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2},$$

und bei gepaarten Stichproben  $(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)$  die Kovarianz  $\text{Cov}(X, Y)$  durch

$$\text{cov}(x, y) = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x}) \cdot (y_i - \bar{y})$$

sowie die Korrelation  $\text{Cor}(X, Y)$  durch

$$\text{cor}(x, y) = \frac{\text{cov}(x, y)}{s_x \cdot s_y}.$$

### Rechenregeln für Kovarianzen

$$\text{Cov}(X, Y) = \mathbb{E}[(X - \mathbb{E}X) \cdot (Y - \mathbb{E}Y)]$$

- Sind  $X$  und  $Y$  unabhängig, so folgt  $\text{Cov}(X, Y) = 0$  (die Umkehrung gilt nicht!)
- $\text{Cov}(X, Y) = \text{Cov}(Y, X)$
- $\text{Cov}(X, Y) = \mathbb{E}(X \cdot Y) - \mathbb{E}X \cdot \mathbb{E}Y$
- $\text{Cov}(a \cdot X, Y) = a \cdot \text{Cov}(X, Y) = \text{Cov}(X, a \cdot Y)$
- $\text{Cov}(X + Z, Y) = \text{Cov}(X, Y) + \text{Cov}(Z, Y)$
- $\text{Cov}(X, Z + Y) = \text{Cov}(X, Z) + \text{Cov}(X, Y)$

Die letzten drei Regeln beschreiben die Bilinearität der Kovarianz.

### Rechenregeln für die Korrelation

$$\text{Cor}(X, Y) = \frac{\text{Cov}(X, Y)}{\sigma_X \cdot \sigma_Y}$$

- $-1 \leq \text{Cor}(X, Y) \leq 1$
- $\text{Cor}(X, Y) = \text{Cor}(Y, X)$
- $\text{Cor}(X, Y) = \text{Cov}(X/\sigma_X, Y/\sigma_Y)$
- $\text{Cor}(X, Y) = 1$  genau dann wenn  $Y$  eine wachsende, affin-lineare Funktion von  $X$  ist, d.h. falls es  $a > 0$  und  $b \in \mathbb{R}$  gibt, so dass  $Y = a \cdot X + b$
- $\text{Cor}(X, Y) = -1$  genau dann wenn  $Y$  eine fallende, affin-lineare Funktion von  $X$  ist, d.h. falls es  $a < 0$  und  $b \in \mathbb{R}$  gibt, so dass  $Y = a \cdot X + b$

### Rechenregeln für Varianzen

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

- $\text{Var}X = \text{Cov}(X, X)$
- $\text{Var}X = \mathbb{E}(X^2) - (\mathbb{E}X)^2$
- $\text{Var}(a \cdot X) = a^2 \cdot \text{Var}X$
- $\text{Var}(X + Y) = \text{Var}X + \text{Var}Y + 2 \cdot \text{Cov}(X, Y)$
- $\text{Var}\left(\sum_{i=1}^n X_i\right) = \sum_{i=1}^n \text{Var}(X_i) + 2 \cdot \sum_{j=1}^n \sum_{i=1}^{j-1} \text{Cov}(X_i, X_j)$
- Sind  $(X, Y)$  stochastisch unabhängig, so folgt:

$$\text{Var}(X + Y) = \text{Var}X + \text{Var}Y$$

(Beweise an der Tafel; ergeben sich aus den Rechenregeln für Kovarianzen)

### Standardabweichung einer Summe

Angenommen, es sind bekannt:

$\sigma_X$  Standardabweichung von  $X$

$\sigma_Y$  Standardabweichung von  $Y$

Wie berechnet man die Standardabweichung  $\sigma_{X+Y}$  von  $X + Y$ ?

Antwort: Man benötigt zusätzlich  $\text{Cov}(X, Y)$  oder  $\text{Cor}(X, Y)$ . Sei z.B.  $\text{Cor}(X, Y)$  gegeben.

Dann verwenden wir die folgenden Gleichungen:

$$\begin{aligned}\text{Var}(X + Y) &= \text{Var}(X) + \text{Var}(Y) + 2 \cdot \text{Cov}(X, Y) \\ \text{Cov}(X, Y) &= \text{Cor}(X, Y) \cdot \sigma_X \cdot \sigma_Y\end{aligned}$$

Rechne also erst in Varianzen um und am Ende  $\sigma_{X+Y} = \sqrt{\text{Var}(X + Y)}$ . Der Rechenweg als Herleitung einer Formel zusammengefasst:

$$\begin{aligned}\sigma_{X+Y} &= \sqrt{\text{Var}(X + Y)} \\ &= \sqrt{\text{Var}(X) + \text{Var}(Y) + 2 \cdot \text{Cov}(X, Y)} \\ &= \sqrt{\sigma_X^2 + \sigma_Y^2 + 2 \cdot \text{Cor}(X, Y) \cdot \sigma_X \cdot \sigma_Y}\end{aligned}$$

### Binomialverteilung

Seien nun  $Y_1, \dots, Y_n$  unabhängig und Bernoulli-verteilt mit Erfolgsws  $p$ . Dann gilt

$$\sum_{i=1}^n Y_i =: X \sim \text{bin}(n, p)$$

und es folgt:

$$\text{Var } X = \text{Var} \left( \sum_{i=1}^n Y_i \right) = \sum_{i=1}^n \text{Var } Y_i = n \cdot p \cdot (1 - p)$$

### Binomialverteilung

**Satz 3 (Erwartungswert und Varianz der Binomialverteilung)** Ist  $X$  binomialverteilt mit Parametern  $(n, p)$ , so gilt:

$$\mathbb{E}X = n \cdot p$$

und

$$\text{Var } X = n \cdot p \cdot (1 - p)$$

### Beispiel: Genetische Drift

In einer haploiden Population von  $n$  Individuen habe Allel  $A$  die Häufigkeit  $p$ . Wir gehen wieder davon aus, dass jedes der  $n$  Individuen der nächsten Generation unabhängig von den anderen mit W'keit  $p$  Allel  $A$  bekommt. Die absolute Häufigkeit  $K$  von  $A$  in der nächsten Generation ist damit  $(n, p)$ -binomialverteilt.

Dann folgt für die relative Häufigkeit  $X = K/n$  in der nächsten Generation:

$$\begin{aligned}\text{Var}(X) &= \text{Var}(K/n) = \text{Var}(K)/n^2 = n \cdot p \cdot (1 - p)/n^2 \\ &= \frac{p \cdot (1 - p)}{n}\end{aligned}$$

Mit den Rechenregeln konnten wir auch beweisen:

**Satz 4** Sind  $X_1, X_2, \dots, X_n$  unabhängige  $\mathbb{R}$ -wertige Zufallsgrößen mit Mittelwert  $\mu$  und Varianz  $\sigma^2$ , so gilt für  $\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$ :

$$\mathbb{E}\bar{X} = \mu$$

und

$$\text{Var } \bar{X} = \frac{1}{n} \sigma^2,$$

d.h.

$$\sigma_{\bar{X}} = \frac{\sigma}{\sqrt{n}}$$

Insbesondere: Der Standardfehler  $\frac{s}{\sqrt{n}}$  ist ein Schätzer der Standardabweichung  $\sigma_{\bar{X}}$  des Stichprobenmittels  $\bar{X}$  der Stichprobe  $(X_1, X_2, \dots, X_n)$ .

Die Stichproben-Standardabweichung  $s$  ist ein Schätzer der Standardabweichung  $\sigma$  der Grundgesamtheit.

**Beweis:** Linearität des Erwartungswertes impliziert

$$\begin{aligned} \mathbb{E}\bar{X} &= \mathbb{E}\left(\frac{1}{n} \sum_{i=1}^n X_i\right) = \frac{1}{n} \sum_{i=1}^n \mathbb{E}(X_i) \\ &= \frac{1}{n} \sum_{i=1}^n \mu = \mu. \end{aligned}$$

Die Unabhängigkeit der  $X_i$  vereinfacht die Varianz zu

$$\begin{aligned} \text{Var } \bar{X} &= \text{Var}\left(\frac{1}{n} \sum_{i=1}^n X_i\right) = \frac{1}{n^2} \text{Var}\left(\sum_{i=1}^n X_i\right) \\ &= \frac{1}{n^2} \sum_{i=1}^n \text{Var}(X_i) = \frac{1}{n^2} \sum_{i=1}^n \sigma^2 = \frac{1}{n} \sigma^2 \end{aligned}$$

**Beispiel: Erwartungstreue der korrigierten Stichprobenvarianz**

Mit etwas mehr Mühe folgte auch:

Für  $X_1, X_2, \dots, X_n$  unabhängig identisch verteilt mit Varianz  $\sigma^2$  ist die korrigierte Stichprobenvarianz

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

ein erwartungstreuer Schätzer für  $\sigma^2$ , das heißt:

$$\mathbb{E}(s^2) = \sigma^2$$

(Aber die Erwartungstreue gilt nicht für  $s$ , sondern i.A. gilt  $\mathbb{E}s < \sigma$ ).

**Beispiel: Standardfehler der Steigung einer Regressionsgeraden**

$$y_i = a + b \cdot x_i + \varepsilon_i \quad \text{mit } \varepsilon_i \sim \mathcal{N}(0, \sigma^2)$$

nicht zufällig:  $a, b, x_i, \sigma^2$       zufällig:  $\varepsilon_i, y_i$

$$\text{Var}(y_i) = \text{Var}(a + b \cdot x_i + \varepsilon_i) = \text{Var}(\varepsilon_i) = \sigma^2$$

und  $y_1, y_2, \dots, y_n$  sind stochastisch unabhängig.

$$\hat{b} = \frac{\sum_i y_i (x_i - \bar{x})}{\sum_i (x_i - \bar{x})^2}$$

$$\begin{aligned}\text{Var}(\hat{b}) &= \text{Var}\left(\frac{\sum_i y_i(x_i - \bar{x})}{\sum_i (x_i - \bar{x})^2}\right) = \frac{\text{Var}(\sum_i y_i(x_i - \bar{x}))}{(\sum_i (x_i - \bar{x})^2)^2} = \frac{\sum_i \text{Var}(y_i)(x_i - \bar{x})^2}{(\sum_i (x_i - \bar{x})^2)^2} \\ &= \sigma^2 \cdot \frac{\sum_i (x_i - \bar{x})^2}{(\sum_i (x_i - \bar{x})^2)^2} = \sigma^2 \Big/ \sum_i (x_i - \bar{x})^2\end{aligned}$$

### Standardfehler der Steigung einer Regressionsgeraden

Tatsächlich ist  $\hat{b}$  Normalverteilt mit Mittelwert  $b$  und

$$\text{Var}(\hat{b}) = \sigma^2 \Big/ \sum_i (x_i - \bar{x})^2$$

**Problem:** Wir kennen  $\sigma^2$  nicht. Wir schätzen  $\sigma^2$  mit Hilfe der beobachteten Residuenvarianz durch

$$s^2 := \frac{\sum_i (y_i - \hat{a} - \hat{b} \cdot x_i)^2}{n - 2}$$

Zu beachten ist, dass durch  $n - 2$  geteilt wird. Das hat damit zu tun, dass zwei Modellparameter  $a$  und  $b$  bereits geschätzt wurden, und somit 2 Freiheitsgrade verloren gegangen sind.

$$\text{Var}(\hat{b}) = \sigma^2 \Big/ \sum_i (x_i - \bar{x})^2$$

Schätze  $\sigma^2$  durch

$$s^2 = \frac{\sum_i (y_i - \hat{a} - \hat{b} \cdot x_i)^2}{n - 2}$$

Dann ist

$$\frac{\hat{b} - b}{s / \sqrt{\sum_i (x_i - \bar{x})^2}}$$

Student- $t$ -verteilt mit  $n - 2$  Freiheitsgraden und wir können den  $t$ -Test anwenden, um die Nullhypothese  $b = 0$  zu testen.