

## Bedingter Erwartungswert

Berechne EW mit bedingter Verteilung.

- ① Sei  $(X, Y)$  nach der Zähldichte  $p(x, y)$  verteilt.

**Bedingte Erwartungswert** von  $X$  gegeben  $Y = y$  gegeben durch

$$E(X|Y = y) = \sum_{x \in \mathcal{X}} x \cdot p_{X|Y}(x|y)$$

- ② Sei  $(X, Y) \sim f_{(X, Y)}(x, y)$  stetig. Bedingter Erwartungswert:

$$E(X|Y = y) = \int x \cdot f_{X|Y}(x|y) dx$$

- ③  $g(y) = E(X|Y = y)$  ist eine **Funktion von  $y$** .

- ④ Einsetzen der Zufallsvariable  $Y$  liefert **bedingte Erwartung von  $X$  gegeben  $Y$** . Notation:  $E(X|Y) := g(Y)$ .

**Beispiel:** Bedingte Dichte für  $y > 0$ :

$$f(x|y) = y \cdot e^{-y \cdot x} \mathbf{1}_{(0, \infty)}(x), \quad x \in \mathbb{R}.$$

Bedingter Erwartungswert

$$E(X|Y = y) = \int_{-\infty}^{\infty} x \cdot f(x|y) dx = \int_0^{\infty} xy \cdot e^{-y \cdot x} dx = \frac{1}{y}$$

(Wie beim partiellen Differenzieren behandle  $y$  als Konstante und integriere nach  $x$ ).

Also zum Beispiel: Für  $Y = 2$  erwarten wir

$$E(X|Y = 2) = \frac{1}{2}$$

## Quantil-Transformation:

Ist  $U \sim U[0, 1]$ , dann ist die Zufallsvariable  $F^{-1}(U)$  nach der Verteilungsfunktion  $F$  verteilt.

Beispiel:  $-\ln(U)/\lambda$  ist  $\text{Exp}(\lambda)$ -verteilt.

## Normalverteilung: Box-Muller-Methode

Sind  $U_1, U_2$  unabhängig und identisch  $U[0, 1]$ -verteilt, dann sind

$$Z_1 = \sqrt{-2 \ln U_1} \cos(2\pi U_2),$$

$$Z_2 = \sqrt{-2 \ln U_1} \sin(2\pi U_2),$$

unabhängig und identisch  $N(0, 1)$ -verteilt und

$$X_i = \mu + \sigma Z_i, \quad i = 1, 2,$$

unabhängig und identisch  $N(\mu, \sigma^2)$ -verteilt.

## Erwartungswertvektor

$\mathbf{X} = (X_1, \dots, X_n)'$  Zufallsvektor.

Gelte:  $\mu_i = E(X_i)$ ,  $i = 1, \dots, n$ , existieren.

Der (Spalten-) Vektor  $\boldsymbol{\mu} = (E(X_1), \dots, E(X_n))'$  heißt

**Erwartungswertvektor von  $\mathbf{X}$ .**

Rechenregeln übertragen sich. Insbesondere gilt für zwei Zufallsvektoren  $\mathbf{X}$  und  $\mathbf{Y}$  sowie Skalare  $a, b \in \mathbb{R}$ :

$$E(a \cdot \mathbf{X} + b \cdot \mathbf{Y}) = a \cdot E(\mathbf{X}) + b \cdot E(\mathbf{Y}).$$

**Beispiel:** Der Zufallsvektor  $\mathbf{X} = (X_1, X_2)^\top$  sei gegeben durch

$X_1$  : Anzahl der Sechsen bei 12 Würfeln mit einem fairen Würfel,  
 $X_2 = 10 + 2 \cdot Z$

wobei  $Z \sim N(0, 1)$ . Es gilt  $X_1 \sim \text{bin}(12, 1/6)$  und somit

$$E(X_1) = 12 \cdot \frac{1}{6} = 2.$$

Nach den Rechenregeln für normalverteilte Zufallsvariablen ist  $X_2 \sim N(10, 2^2)$  und somit  $E(X_2) = 10$ . Daher ist

$$E(\mathbf{X}) = \begin{pmatrix} E(X_1) \\ E(X_2) \end{pmatrix} = \begin{pmatrix} 2 \\ 10 \end{pmatrix}.$$

$E(Y) = ?$  für  $Y = g(\mathbf{X})$ :

Ist  $\mathbf{X}$  nach der diskreten Zähldichte  $p_{\mathbf{X}}(\mathbf{x})$ ,  $\mathbf{x} \in \mathbb{R}^n$ , verteilt, dann gilt

$$E(Y) = E(g(\mathbf{X})) = \sum_{\mathbf{x}} g(\mathbf{x}) p_{\mathbf{X}}(\mathbf{x}).$$

Ist  $\mathbf{X}$  nach der stetigen Dichte  $f_{\mathbf{X}}(\mathbf{x})$  verteilt, dann gilt

$$E(Y) = E(g(\mathbf{X})) = \int_{\mathbb{R}^n} g(\mathbf{x}) f_{\mathbf{X}}(\mathbf{x}) d\mathbf{x}.$$

## Beispiel:

Es gelte  $\mathbf{X} = (X_1, X_2)' \sim f_{\mathbf{X}}$  mit

$$f_{(X_1, X_2)}(x_1, x_2) = \begin{cases} x_2^3 & \text{falls } x_1 \in [0, 4] \text{ und } x_2 \in [0, 1], \\ 0, & \text{sonst.} \end{cases}$$

Zu bestimmen sei  $Eg(X_1, X_1)$  für die Funktion  $g(x_1, x_2) = x_1 \cdot x_2$ ,  $x_1, x_2 \in \mathbb{R}$ . Wir erhalten

$$\begin{aligned} E(X_1 \cdot X_2) &= \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} x_1 x_2 f_{(X_1, X_2)}(x_1, x_2) dx_1 dx_2 \\ &= \int_0^1 \int_0^4 x_1 x_2 x_2^3 dx_1 dx_2 \\ &= \int_0^1 x_2^4 \left( \frac{x_1^2}{2} \Big|_{x_1=0}^{x_1=4} \right) dx_2 = \dots = \frac{8}{5}. \end{aligned}$$

Bekannt:  $X, Y$  unabhängig, dann gilt:  $\text{Var}(X + Y) = \text{Var}(X) + \text{Var}(Y)$ .

**Frage:** Formel für den allgemeinen Fall?

Sei  $\mu_X = E(X)$  und  $\mu_Y = E(Y)$ .

Ausquadrieren und Linearität des Erwartungswertes ausnutzen:

$$\begin{aligned}\text{Var}(X + Y) &= E\left(\left(X + Y - (\mu_X + \mu_Y)\right)^2\right) \\ &= E\left(\left((X - \mu_X) + (Y - \mu_Y)\right)^2\right) \\ &= E\left(\left(X - \mu_X\right)^2 + 2(X - \mu_X)(Y - \mu_Y) + (Y - \mu_Y)^2\right) \\ &= E\left(\left(X - \mu_X\right)^2\right) + 2E\left(\left(X - \mu_X\right)(Y - \mu_Y)\right) + E\left(\left(Y - \mu_Y\right)^2\right) \\ &= \text{Var}(X) + 2E(X - \mu_X)(Y - \mu_Y) + \text{Var}(Y).\end{aligned}$$

Sind  $X$  und  $Y$  stochastisch unabhängig, dann gilt für den mittleren Term

$$E\left(\left(X - \mu_X\right)(Y - \mu_Y)\right) = E(X - \mu_X) \cdot E(Y - \mu_Y) = 0.$$

## Kovarianz, Kovarianzmatrix

- ① Sind  $X$  und  $Y$  Zufallsvariablen mit existierenden Varianzen, dann heißt

$$\text{Cov}(X, Y) = E((X - \mu_X)(Y - \mu_Y))$$

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

- ②  $X, Y$  heißen **unkorreliert**, falls  $\text{Cov}(X, Y) = 0$ .
- ③ Ist  $\mathbf{X} = (X_1, \dots, X_n)$  ein Zufallsvektor, dann heißt die symmetrische  $(n \times n)$ -Matrix  $\text{Var}(\mathbf{X}) = (\text{Cov}(X_i, X_j))_{i,j}$  der  $n^2$  Kovarianzen **Kovarianzmatrix von  $\mathbf{X}$** .

- ④ Alle  $X_i$  paarweise unkorreliert:  $\text{Var}(\mathbf{X})$  Diagonalmatrix.
- ⑤ Korrelation:

$$\text{Cor}(X, Y) = \frac{\text{Cov}(X, Y)}{\sqrt{\text{Var}(X)}\sqrt{\text{Var}(Y)}}$$

## Rechenregeln

$X$ ,  $Y$  und  $Z$  Zufallsvariablen mit endlichen Varianzen. Dann gelten für alle  $a, b \in \mathbb{R}$  die folgenden Rechenregeln:

- 1  $\text{Cov}(aX, bY) = ab \text{Cov}(X, Y)$ .
- 2  $\text{Cov}(X, Y) = \text{Cov}(Y, X)$ .
- 3  $\text{Cov}(X, Y) = 0$ , wenn  $X$  und  $Y$  unabhängig sind.
- 4  $\text{Cov}(X + Y, Z) = \text{Cov}(X, Z) + \text{Cov}(Y, Z)$
- 5 Cauchy-Schwarz-Ungleichung:  $\sigma_X^2 = \text{Var}(X), \sigma_Y^2 = \text{Var}(Y)$ .

$$|\text{Cov}(X, Y)| \leq \sqrt{\text{Var}(X)}\sqrt{\text{Var}(Y)} = \sigma_X\sigma_Y.$$

(liefert:  $\text{Cor}(X, Y) \in [-1, 1]$ .)

# Kovarianz: Rechenbeispiel

Sei  $Z \sim N(0, 1)$  und  $\mathbf{X} = (X_1, X_2)'$  gegeben durch

$$X_1 = 1 + 2Z,$$

$$X_2 = 3Z.$$

Dann gilt

$$\text{Var}(X_1) = 4, \quad \text{Var}(X_2) = 9$$

und die Kovarianz zwischen  $X_1$  und  $X_2$  berechnet sich zu

$$\begin{aligned} \text{Cov}(X_1, X_2) &= \text{Cov}(1 + 2Z, 3Z) \\ &= \text{Cov}(2Z, 3Z) \\ &= 2 \cdot 3 \cdot \text{Cov}(Z, Z) \\ &= 6\text{Var}(Z) = 6. \end{aligned}$$

Somit erhalten wir für die Kovarianzmatrix

$$\text{Cov}(\mathbf{X}) = \begin{pmatrix} \text{Var}(X_1) & \text{Cov}(X_1, X_2) \\ \text{Cov}(X_1, X_2) & \text{Var}(X_2) \end{pmatrix} = \begin{pmatrix} 4 & 6 \\ 6 & 9 \end{pmatrix}.$$

## Anwendung: Multivariate Normalverteilung

**Definition:** Sind  $X_1, \dots, X_n$  unabhängig und identisch  $N(0, 1)$ -verteilte Zufallsvariablen, dann ist die gemeinsame Dichtefunktion des Zufallsvektors  $\mathbf{X} = (X_1, \dots, X_n)'$  gegeben durch

$$\varphi(x_1, \dots, x_n) = \left( \frac{1}{\sqrt{2\pi}} \right)^n \exp \left( -\frac{1}{2} \sum_{i=1}^n x_i^2 \right), \quad x_1, \dots, x_n \in \mathbb{R}.$$

$\mathbf{X}$  heißt **multivariat** oder  $n$ -dimensional **standardnormalverteilt**.

Notation:  $\mathbf{X} \sim N_n(\mathbf{0}, \mathbf{I})$

Erwartungswertvektor und Kovarianzmatrix von  $\mathbf{X}$  sind gegeben durch

$$\boldsymbol{\mu} = E(\mathbf{X}) = \mathbf{0} = (0, \dots, 0)' \in \mathbb{R}^n, \quad \boldsymbol{\Sigma} = \begin{pmatrix} 1 & 0 & \cdots & 0 \\ 0 & \ddots & & 0 \\ \vdots & & \ddots & \vdots \\ 0 & \cdots & 0 & 1 \end{pmatrix}.$$

**Beispiel:** Produktverteilung (Erinn:  $\prod_{i=1}^n \varphi_i(x_i)$ ) aus Normalverteilungen

Sind  $X_i \sim N(\mu_i, \sigma_i^2)$  unabhängig,  $1 \leq i \leq n$ , dann hat  $\mathbf{X} = (X_1, \dots, X_n)'$  die gemeinsame Produktdichte

$$\varphi(x_1, \dots, x_n) = \left( \frac{1}{\sqrt{2\pi}} \right)^n \exp \left( -\frac{1}{2} \sum_{i=1}^n \frac{(x_i - \mu_i)^2}{\sigma_i^2} \right), \quad x_1, \dots, x_n \in \mathbb{R}.$$

Erwartungswert:  $E(\mathbf{X}) = \boldsymbol{\mu} = (\mu_1, \dots, \mu_n)'$

Kovarianzmatrix:  $\boldsymbol{\Sigma} = \text{Cov}(\mathbf{X}) = \text{diag}(\sigma_1^2, \dots, \sigma_n^2)$  (Diagonalmatrix).

Notation:  $\mathbf{X} \sim N_n(\mathbf{0}, \boldsymbol{\Sigma})$

**Satz:** Ist  $\mathbf{a} = (a_1, \dots, a_n)' \in \mathbb{R}^n$  ein Spaltenvektor und gilt  $\mathbf{X} = (X_1, \dots, X_n)' \sim N_n(\boldsymbol{\mu}, \mathbf{I})$ , dann ist die Linearkombination  $\mathbf{a}'\mathbf{X} = a_1X_1 + \dots + a_nX_n$  ebenfalls normalverteilt mit Erwartungswert

$$E(a_1X_1 + \dots + a_nX_n) = a_1\mu_1 + \dots + a_n\mu_n = \mathbf{a}'\boldsymbol{\mu}$$

und Varianz

$$\text{Var}(a_1X_1 + \dots + a_nX_n) = \text{Var}(a_1X_1) + \dots + \text{Var}(a_nX_n) = a_1^2 + \dots + a_n^2 = \mathbf{a}'\mathbf{a}.$$

Kurz: Wenn  $\mathbf{X} = (X_1, \dots, X_n)' \sim N_n(\boldsymbol{\mu}, \mathbf{I})$  und  $\mathbf{a} = (a_1, \dots, a_n)' \in \mathbb{R}^n$ , dann folgt

$$\mathbf{a}'\mathbf{X} \sim N_n(\mathbf{a}'\boldsymbol{\mu}, \mathbf{a}'\mathbf{a}).$$

# Multivariate Normalverteilung

**Anwendungsbeispiel:** Künstliche Neuronale Netze (z.B. CNNs) berechnen für einen (zufälligen)  $d$ -dim. Input  $\mathbf{X}$  lineare Transformationen

$$Z_j = b_j + \mathbf{a}'_j \mathbf{X}, \quad 1 \leq j \leq m,$$

mit Gewichtungsvektoren  $\mathbf{a}_1, \dots, \mathbf{a}_m \in \mathbb{R}^d$  und Intercept-Termen  $b_1, \dots, b_m$ , und dann Ausgaben

$$Y_j = \sigma(Z_j), \quad 1 \leq j \leq m,$$

mit einer Aktivierungsfunktion  $\sigma : \mathbb{R} \rightarrow \mathbb{R}$  (als Modell für ein Neuron mit  $m$  Dendriten).

Für normalverteilten Input  $\mathbf{X} \sim N(\boldsymbol{\mu}, \boldsymbol{\Sigma})$  sind die Zwischenergebnisse (Projektionen! - vgl. LA)  $Z_j$  multivariat normalverteilt:

$$\mathbf{Z} = (Z_1, \dots, Z_m)' = \mathbf{b} + \mathbf{A}\mathbf{X} \sim N(\mathbf{b} + \mathbf{a}'\boldsymbol{\mu}, \boldsymbol{\Sigma})$$

mit  $\boldsymbol{\Sigma} = (\text{Cov}(Z_i, Z_j))_{\substack{1 \leq i \leq m \\ 1 \leq j \leq m}} = (\mathbf{a}'_i \mathbf{a}_j)_{\substack{1 \leq i \leq m \\ 1 \leq j \leq m}}$ ,  $\mathbf{A} = (\mathbf{a}_1, \dots, \mathbf{a}_m)'$ ,

$\mathbf{b} = (b_1, \dots, b_m)'$ .

# Multivariate Normalverteilung

Seien allg.  $\mathbf{a} = (a_1, \dots, a_n)'$  und  $\mathbf{b} = (b_1, \dots, b_n)'$  Spaltenvektoren sowie

$$U = \mathbf{a}'\mathbf{X} = a_1X_1 + \dots + a_nX_n,$$

$$V = \mathbf{b}'\mathbf{X} = b_1X_1 + \dots + b_nX_n,$$

zwei Linearkombinationen der Zufallsvariablen  $X_1, \dots, X_n$ .

Ist der Zufallsvektor  $\mathbf{X} = (X_1, \dots, X_n)'$  nun  $N_n(\mathbf{0}, \mathbf{I})$ -verteilt, dann ist aufgrund der Unabhängigkeit der  $X_i$

$$\begin{aligned} \text{Cov}(U, V) &= \text{Cov}(a_1X_1 + \dots + a_nX_n, b_1X_1 + \dots + b_nX_n) \\ &= \text{Cov}(a_1X_1, b_1X_1) + \dots + \text{Cov}(a_nX_n, b_nX_n) \\ &= a_1b_1 + \dots + a_nb_n = \mathbf{a}'\mathbf{b}. \end{aligned}$$

Somit sind die Zufallsvariablen  $U$  und  $V$  genau dann unkorreliert (also unabhängig), wenn  $\mathbf{a}'\mathbf{b} = 0$ .

Ist  $\mathbf{X} \sim N_n(\mathbf{0}, \mathbf{I})$ ,  $\mathbf{b} \in \mathbb{R}^n$  und  $\mathbf{A}$  eine  $m \times n$ -Matrix, dann ist

$$\mathbf{Y} = \mathbf{b} + \mathbf{A}\mathbf{X} \sim N(\mathbf{b}, \mathbf{\Sigma})$$


mit  $\mathbf{\Sigma} = \mathbf{A}\mathbf{A}'$ .

Erzeugung von  $N(\boldsymbol{\mu}, \mathbf{\Sigma})$ -verteilten Vektoren:

- Bestimme Matrix  $\mathbf{A}$  mit  $\mathbf{\Sigma} = \mathbf{A}\mathbf{A}'$  (geht über Singulärwertzerlegung)
- Erzeuge  $\mathbf{X} \sim N(\mathbf{0}, \mathbf{I})$  (Box-Muller)
- Berechne  $\mathbf{Y} = \mathbf{b} + \mathbf{A}\mathbf{X}$

# Multivariate Normalverteilung

Dichte einer bivariaten Normalverteilung (Korrelation 0.6,  $\mu = \mathbf{0}$ ).



Höhenlinien sind Ellipsen (Achsen d. Ellipsen gegeben durch Eigenvektoren  $\mathbf{v}_i$  von  $\Sigma$ , Länge der Halbachsen = Wurzel der Eigenwerte).

(Plots von Stichproben sind aufsteigende Punktwolken, die ellipsenförmig aussehen.)

Gegeben: Eine Folge von Zufallsvariablen:

$$X_1, X_2, X_3, \dots$$

Formaler:

$$X_n, \quad n = 1, 2, \dots$$


Betrachte die Folge der arithmetischen Mittelwerte:

$$\bar{X}_n = \frac{1}{n} \sum_{i=1}^n X_i, \quad n = 1, 2, \dots$$

$$X_1, \quad \frac{X_1 + X_2}{2}, \quad \frac{X_1 + X_2 + X_3}{3}, \dots$$

# Computorexperiment I: Folge der arithmetischen Mittel

## Computorexperiment I:



Beobachtung:

- Die Folge der  $\bar{X}_n$  nähert sich einem festen Wert an.
- Welcher Wert ist das?
- Wie kann man diese 'Konvergenz' beschreiben?

Fundamentales Resultat 1: Gesetz der großen Zahl