

X heißt normalverteilt mit Parametern $\mu \in \mathbb{R}$ und $\sigma^2 \in (0, \infty)$, falls X die Dichte

$$\varphi_{(\mu, \sigma^2)}(x) = \frac{1}{\sqrt{2\pi}} \exp\left(-\frac{(x - \mu)^2}{2\sigma^2}\right), \quad x \in \mathbb{R}.$$

hat \rightarrow **Gauß'sche Glockenkurve.**

Carl Friedrich Gauß (1777-1855): Berühmter Göttinger Mathematiker



Gauss



Lupe...



Verteilungsfunktion:

$$\Phi_{(\mu, \sigma^2)}(x) = \int_{-\infty}^x \varphi_{(\mu, \sigma^2)}(t) dt = p$$

Quantilfunktion (Umkehrfunktion):

$$x = \Phi_{(\mu, \sigma^2)}^{-1}(p)$$

Es gibt keine expliziten Formeln! → Computer / Tabellen

R: $p = \text{pnorm}(x)$, $x = \text{qnorm}(p)$.

Eigenschaften der Normalverteilung

- 1 $E(X) = \int_{-\infty}^{\infty} x\varphi_{(\mu,\sigma^2)}(x)dx = \mu.$
- 2 $\text{Var}(X) = \int_{-\infty}^{\infty} (x - \mu)^2\varphi_{(\mu,\sigma^2)}(x)dx = \sigma^2.$
- 3 Dichte hat Symmetriezentrum: μ
- 4 Dichte hat Wendepunkte bei $\mu \pm \sigma$

Rechenregeln

- 1 $X \sim N(\mu_1, \sigma_1^2)$ und $Y \sim N(\mu_2, \sigma_2^2)$ unabhängig, dann gilt:
 $X + Y \sim N(\mu_1 + \mu_2, \sigma_1^2 + \sigma_2^2)$.
- 2 Ist $X \sim N(\mu, \sigma^2)$ und sind $a, b \in \mathbb{R}$, dann gilt:
 $aX + b \sim N(a\mu + b, a^2\sigma^2)$.
- 3 Ist $X \sim N(\mu, \sigma^2)$, dann gilt:

$$X^* = \frac{X - \mu}{\sigma} \sim N(0, 1).$$

X^* : Standardisierte Version.

- 4 Ist $X^* \sim N(0, 1)$, dann gilt

$$\mu + \sigma \cdot X^* \sim N(\mu, \sigma^2).$$

Regel

Sind $X_1, \dots, X_n \sim N(\mu, \sigma^2)$ unabhängig, dann ist das arithmetische Mittel normalverteilt mit Erwartungswert μ und Varianz σ^2/n :

$$\bar{X} \sim N(\mu, \sigma^2/n)$$

und

$$\bar{X}^* = \frac{\bar{X} - \mu}{\sigma/\sqrt{n}} = \sqrt{n} \frac{\bar{X} - \mu}{\sigma} \sim N(0, 1).$$

Zufallsvektoren

Ω abzählbar, dann heißt **jede** Abbildung

$$\mathbf{X} : \Omega \rightarrow \mathbb{R}^n, \quad \omega \mapsto \mathbf{X}(\omega) = (X_1(\omega), \dots, X_n(\omega))$$

in den n -dimensionalen Raum \mathbb{R}^n **Zufallsvektor**.

Zusatz: Ist Ω überabzählbar, dann müssen alle X_i , $i = 1, \dots, n$, messbar sein.

Realisationen von $\mathbf{X} = (X_1, \dots, X_n)$ sind **Vektoren** \mathbf{x} im \mathbb{R}^n :

$$\mathbf{x} = (x_1, \dots, x_n) \in \mathbb{R}^n.$$

Verteilung eines Zufallsvektors (X, Y)

Verteilungsfunktion:

$$F(x, y) = P(X \leq x, Y \leq y), \quad x, y \in \mathbb{R}$$

Es gilt: $F(-\infty, y) = P(\{X \leq -\infty\} \cap \{Y \leq y\}) = P(\emptyset \cap \{Y \leq y\}) = 0$.

Rand-Verteilungsfunktionen:

$$F_X(x) = P(X \leq x) = F(x, \infty) = \lim_{y \rightarrow \infty} F(x, y)$$

$$F_Y(y) = P(Y \leq y) = F(\infty, y) = \lim_{x \rightarrow \infty} F(x, y)$$

Für (X_1, \dots, X_n) entsprechend, z. B.

$$F_{(X, Y, Z)}(\infty, y, \infty) = P(Y \leq y), \quad y \in \mathbb{R}.$$

Verteilung eines Zufallsvektors (X, Y)

Diskrete Zufallsvektoren: Verteilung durch Zähldichten gegeben

$$p(x, y) = P(X = x, Y = y), \quad (x, y) \in \mathbb{R}^2$$

- Stäbe über der (x, y) -Ebene an denjenigen Stellen (x, y) mit $P(X = x, Y = x) > 0$, sonst 0.
- Entspricht der Kontingenztabelle der gemeinsamen Wahrscheinlichkeiten.
- $P(X \in A, Y \in B) = \sum_{(x,y) \in A \times B} p(x, y)$
(Summe der Stäbe, die in $A \times B$ stehen.)

Stetige Zufallsvektoren: Verteilung gegeben durch Dichte $f(x, y)$

$$f(x, y) \geq 0, (x, y) \in \mathbb{R}^2, \quad \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} f(x, y) dx dy = 1$$

- 'Gebirge' über der (x, y) -Ebene.
- $P(a < X \leq b, c < Y \leq d) = \int_a^b \int_c^d f(x, y) dy dx$

Produktmodell / Produktverteilung

Produkt-Verteilungsfunktion

$$F(x, y) = F_X(x) \cdot F_Y(y), \quad (x, y) \in \mathbb{R}^2$$

Produkt-Zähldichte

$$p(x, y) = p_X(x) \cdot p_Y(y), \quad (x, y) \in \mathbb{R}^2$$

Produkt-Dichtefunktion

$$f(x, y) = f_X(x) \cdot f_Y(y), \quad (x, y) \in \mathbb{R}^2$$

Dies entspricht der stochastischen Unabhängigkeit von X und Y .

Verteilung eines Zufallsvektors (X, Y)

Beispiel: $X \sim \text{Bin}(10, 0.4)$ und $Y \sim \text{Poi}(2)$ seien unabhängig. Dann gilt:

$$P(X = k, Y = l) = \binom{10}{k} 0.4^k 0.6^{10-k} \cdot \frac{2^l e^{-l}}{l!}, k = 0, \dots, 10, l = 0, 1, 2, \dots$$

Beispiel: Sind $X, Y \sim N(0, 1)$ unabhängig, dann hat (X, Y) die Dichte

$$\begin{aligned} f(x, y) &= \frac{1}{\sqrt{2\pi}} \exp(-x^2/2) \cdot \frac{1}{\sqrt{2\pi}} \exp(-y^2/2) \\ &= \frac{1}{2\pi} \exp(-(x^2 + y^2)/2) \end{aligned}$$

für $(x, y) \in \mathbb{R}^2$.

Beispiel: Gelte $(X, Y) \sim f(x, y)$ wobei

$$f(x, y) = \begin{cases} \lambda^2 e^{-\lambda(x+y)}, & x, y > 0 \\ 0, & \text{sonst} \end{cases}$$

Für alle $x, y > 0$ gilt:

$$f(x, y) = \lambda^2 e^{-\lambda(x+y)} = \lambda^2 e^{-\lambda x} e^{-\lambda y} = (\lambda e^{-\lambda x})(\lambda e^{-\lambda y})$$

$f(x, y)$ ist das Produkt von zwei $\text{Exp}(\lambda)$ -Dichten (die 0 sind auf der nichtpositiven Halbachse). Also sind X und Y unabhängig und identisch $\text{Exp}(\lambda)$ -verteilt.

Bedingte Verteilung, Unabhängigkeit

X, Y diskret mit Werten in $\mathcal{X} = \{x_1, x_2, \dots\}$ bzw. $\mathcal{Y} = \{y_1, y_2, \dots\}$.

- ① Bedingte Wahrscheinlichkeit von $X = x_i$ gegeben $Y = y_j$:

$$P(X = x_i | Y = y_j) = \frac{P(X = x_i, Y = y_j)}{P(Y = y_j)} = \frac{p(x_i, y_j)}{p_Y(y_j)}$$

$p(x_i, y_j)$: gem. Zähldichte, $p_Y(y_j)$: Zähldichte von Y .

- ② Definiert die **bedingte Zähldichte**

$$p(x|y) = p_{X|Y}(x|y) = P(X = x | Y = y) = \begin{cases} \frac{p(x, y)}{p_Y(y)}, & y \in \{y_1, y_2, \dots\} \\ p_X(x), & y \notin \{y_1, y_2, \dots\} \end{cases}$$

- ③ Endlicher Fall: $p(x_i, y_j)$: Tabelle (Kontingenztafel), $p_Y(y_j)$: Rand
④ Entsprechend definiert man die bedingte Wahrscheinlichkeit von $Y = y_j$ gegeben $X = x_i$.

Bedingte Zähldichten

Beispiel: X, Y seien Zufallsvariable und es gelte:

$$P(X = 1) = 0.1, \quad P(X = 2) = 0.5, \quad P(X = 3) = 0.4$$

$$P(Y = 0) = 0.2, \quad P(Y = 1) = 0.8$$

Stochastische Abhängigkeit bei Verletzung der Produktregel:

$Y \setminus X$	1	2	3	
0	0.02	0.08	0.1	0.2
1	0.08	0.42	0.3	0.8
	0.1	0.5	0.4	1

Bedingte Wahrscheinlichkeit für $X = 2$ gegeben $Y = 1$:

$$P(X = 2|Y = 1) = \frac{p_{XY}(2, 1)}{p_Y(1)} = \frac{0.42}{0.8} = 0.525$$

Beispiel: Klassifikation im Machine Learning

Problem: Klassifiziere Objekte in 2 Klassen, 0: ok, 1: defekt
Klassifizierer (Algorithmus) berechnet $Y = g(X) \in \{0, 1\}$.

X : Zufallsvariable(n) (Input-Feature(s))

Z : wahres Label mit Werten in $\{0, 1\}$ (unbeobachtet).

Beispiele: Virus (defekt=infiziert), Produktion (Objekt=Produkt), ...

Entscheidung für Klasse 0: „0“ = $\{Y = 0\}$,

Entscheidung für Klasse 1: „1“ = $\{Y = 1\}$

Wahre Wahrscheinlichkeiten in der Population:

Klassifizierer Y	wahres Label Z		
	0	1	
„0“	p_{00}	p_{01}	$p_{00} + p_{01}$
„1“	p_{10}	p_{11}	$p_{10} + p_{11}$

Fehlklassifikationswahrscheinlichkeit: $p_{err} = p_{01} + p_{10}$.

Falsch-Positiv-Rate: $P(Z = 0 | Y = 1) = \frac{p_{10}}{p_{10} + p_{11}}$

Falsch-Positiv-Rate: $P(Z = 0|Y = 1) = \frac{p_{10}}{p_{10} + p_{11}}$

Analyse des Zählers:

$$\begin{aligned} p_{10} &= P(Y = 1|Z = 0)P(Z = 0) \\ &= (1 - P(Y = 0|Z = 0)) \cdot (1 - P(Z = 1)) \end{aligned}$$

Hier ist $P(Y = 0|Z = 0)$ die **Spezifität** des Klassifiziers (richtige Entscheidung bei Nicht-Defekten) und $P(Z = 1)$ der Defektanteil. Falsch-Positiv-Rate kann sehr groß sein, wenn Spezifität nicht nahe 1 und/oder Defektanteil klein!

Sensitivität: $P(Y = 1|Z = 1)$ (Erfolgsrate unter Defekten)

- Algorithmen optimieren in der Regel $p_{err} = p_{01} + p_{11}$
- Sensitivität und Spezifität schätzbar aus Testfällen mit Z bekannt.
- Anwendung problematisch, wenn Falsch-Positiv-Rate hoch!

Simpson's Paradoxon

Situation: Verteilung von Y gegeben $X = x$ interessiert. Zusätzliche Variable Z

Beispiel: Fahrprüfungen: Y : best. / n. best., X : M/W, Z : Tag 1, 2
Tabellen nach Tagen (Werten von Z):

Tag $Z = 1$:	$Y \setminus X$	M	F	Durchfallquoten: 0 %, 10 %
	best.	1	9	
	n. best.	0	1	
		1	10	

Tag $Z = 2$:	$Y \setminus X$	M	F	Durchfallquoten: 25%, 50 %
	best.	3	1	
	n. best.	1	1	
		4	2	

Aggregiert über Z :	$Y \setminus X$	M	F	Durchfallquoten: 20%, 16.67 %
	best.	4	10	
	n. best.	1	2	
		5	12	

Simpson's Paradoxon

Paradoxon: Das Ergebnis kehrt sich um, d.h. aggregiert anderes Ergebnis als aufgeschlüsselt!

Ursache: Verteilung von Variable Z unterschiedlich für Werte von X :

Verteilung von Z unter Männern: $1/5, 4/5$

Verteilung von Z unter Frauen: $10/12, 2/12$

(Männer wählen meist Tag 2, Frauen Tag 1)

Rechnerisch gilt: ($Y = 1$ für n. best., rel. Hf. als Wkeiten)

$$\begin{aligned} P(Y = 1|X = M) &= \underbrace{P(Y = 1|X = M, Z = 1)}_{\text{Quote aus Teilpopulation } Z = 1} \cdot \underbrace{P(Z = 1|X = M)}_{\text{Anteil } Z = 1 \text{ unter } X = M} \\ &+ \underbrace{P(Y = 1|X = M, Z = 2)}_{\text{Quote aus Teilpopulation } Z = 2} \cdot \underbrace{P(Z = 2|X = M)}_{\text{Anteil } Z = 2 \text{ unter } X = M} \\ &= \frac{0}{1} \cdot \frac{1}{5} + \frac{1}{4} \cdot \frac{4}{5} = \frac{1}{5} \\ P(Y = 1|X = F) &= \frac{1}{10} \frac{10}{12} + \frac{1}{2} \frac{2}{12} = \frac{2}{12} = \frac{1}{6} = 0.1\bar{6} \end{aligned}$$

Simpson's Paradoxon: Klassisches Beispiel

Klassisches Beispiel: Y : Zulassung zum Studium, X : Geschlecht, Z : Studienfach.

Berkeley 1973: 35% der Frauen zugelassen, aber 44% der Männer.

Frage: Liegt eine Diskriminierung vor?

Analyse aufgeschlüsselt nach Studienfächern (Fakultäten) bestätigte den Verdacht nicht.

Ursache: Verteilung des Studienfachs Z bei Frauen anders als bei Männern. Frauen bewarben sich häufiger als Männer für Fächer mit niedrigen Zulassungsquoten für beide Geschlechter.

- In der Regel ist die Detailanalyse nach den Werten Z informativer und liefert eine genauere Interpretation.
- Generell Vorsicht bei aggregierten Daten/Tabellen! Besser aufschlüsseln nach weiteren (potentiellen) Einflussvariablen.

Allgegenwärtiges, reales Problem bei Big Data, ML, AI:

Diskriminierung, Bias, Fairness-Begriff

Datenbestände können ungewollten gesellschaftlichen Bias und Diskriminierung abbilden. Schlechterstellung/Nachteil (sagen wir $Y = 1$) bei Vorliegen von bestimmten Ausprägungen ($X = x^*$) häufiger als bei anderen Ausprägungen von X . KI-Verfahren lernen dies aus den Daten. Was soll Fairness bedeuten? Gleiche Quoten marginal oder in Teilpopulationen ($Z = z$)?

Bedingte Dichte

X und Y stetig verteilt: $(X, Y) \sim f(x, y)$.

Bedingte Dichte von X gegeben $Y = y$ (y fest):

$$f(x|y) = f_{X|Y}(x|y) = \begin{cases} \frac{f(x,y)}{f_Y(y)}, & f_Y(y) > 0, \\ f_X(x), & f_Y(y) = 0, \end{cases}$$

Dies ist als Funktion von x eine Dichte (für jedes $y \in \mathbb{R}$).

Notation: $X|Y = y \sim f_{X|Y}(x|y)$.

Beispiel: Bedingte Dichte für $y > 0$:

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

Ist $Y \sim U(1, 3)$, dann ist die gemeinsame Dichte

$$f(x, y) = f(x|y)f_Y(y) = \begin{cases} \frac{1}{2}y \cdot e^{-y \cdot x}, & y \in [1, 3], x > 0, \\ 0, & x \leq 0 \text{ oder } y < 1 \text{ oder } y > 3. \end{cases}$$

Kriterien für Unabhängigkeit

- ① Diskreter Fall: X und Y sind genau dann stochastisch unabhängig, wenn für alle x und y gilt:

$$p_{X|Y}(x|y) = p_X(x) \quad \text{bzw.} \quad p_{Y|X}(y|x) = p_Y(y).$$

bzw. $p(x, y) = p_X(x)p_Y(y)$
(gem. Zähldichte = Produkt-Zähldichte)

- ② Stetiger Fall: X und Y genau dann stochastisch unabhängig, wenn für alle x und y gilt:

$$f_{X|Y}(x) = f_X(x) \quad \text{bzw.} \quad f_{Y|X}(y) = f_Y(y).$$

bzw. $f(x, y) = f_X(x)f_Y(y)$ (gem. Dichte = Produktdichte).

- ③ X, Y ist genau dann stochastisch unabhängig, wenn für die gemeinsame Verteilungsfunktion $F_{(X,Y)}(x, y)$ für alle $x, y \in \mathbb{R}$ gilt:
 $F_{(X,Y)}(x, y) = F_X(x) \cdot F_Y(y)$.