

## 1 Wahrscheinlichkeitsräume

→ mathematische Beschreibung als Tripel  $(\Omega, \mathbb{F}, P)$

- $\Omega$ : Ergebnisraum, Menge aller möglichen Ergebnisse eines Zufallsexperiments
- $\mathbb{F}$ : Ereignisalgebra, die die Anforderungen einer Algebra erfüllt:

$$\begin{aligned}\Omega &\in \mathbb{F} \\ A \in \mathbb{F} &\Rightarrow A^c \in \mathbb{F} \\ A_1, A_2, \dots, A_k \in \mathbb{F} &\Rightarrow \bigcup_{i=1}^k A_i \in \mathbb{F}\end{aligned}$$

Ist also ein Erzeugendensystem  $\mathbb{G}$  gegeben und soll überprüft werden, ob dieses Erzeugendensystem bereits eine Ereignisalgebra darstellt, so müssen obige drei Bedingungen erfüllt sein:  $\Omega$  und  $\emptyset$  müssen entsprechend stets in  $\mathbb{F}$  enthalten sein, die anderen Elemente finden sich durch Komplement- und Vereinigungsbildung.

- $P$ : Wahrscheinlichkeitsmaß

$$\begin{aligned}P(A) &\geq 0 \\ P(\Omega) &= 1 \\ P\left(\bigcup_{i=1}^{\infty} A_i\right) &= \sum_{i=1}^{\infty} P(A_i), \text{ wenn } A_i \cap A_j = \emptyset, \forall i \neq j\end{aligned}$$

Hieraus ergeben sich die folgenden, mitunter äußerst nützlichen Zusammenhänge:

$$\begin{aligned}P(A^c) &= 1 - P(A) & P(\emptyset) &= 0 \\ P(A \setminus B) &= P(A \cap B^c) = P(A) - P(A \cap B) & P(A \cup B) &= P(A) + P(B) - P(A \cap B) \\ A \subset B &\Rightarrow P(A) \leq P(B) & P\left(\bigcup_{i=1}^k A_k\right) &\leq \sum_{i=1}^k P(A_i)\end{aligned}$$

## 2 Bedingte Wahrscheinlichkeit und Unabhängigkeit

→ Definition:  $P(A|B) = \frac{P(A \cap B)}{P(B)}$ ,  $P(B) \neq 0$

→ Gesetz der totalen Wahrscheinlichkeit ( $\bigcup_{i \in I} B_i = \Omega, B_i \cap B_j = \emptyset, \forall i \neq j$ ):

$$P(A) = \sum_{i \in I} P(A|B_i) \cdot P(B_i)$$

→ Satz von Bayes

$$P(B_j|A) = \frac{P(A|B_j)P(B_j)}{\sum_{i \in I} P(A|B_i)P(B_i)}$$

→ Mit Hilfe des Gesetzes der totalen Wahrscheinlichkeit und dem Satz von Bayes ist es möglich, die Wahrscheinlichkeit zu berechnen, falls untersuchtes Ereignis und Bedingung ihre Rolle tauschen.

→ Stochastische Unabhängigkeit: Ereignisse  $A, B$  unabhängig, falls  $P(A \cap B) = P(A) \cdot P(B)$  bzw.  $P(A|B) = P(A)$

### 3 Zufallsvariablen

- Definition:  $(\Omega, \mathbb{F}, P)$  Wahrscheinlichkeitsraum,  $(\Omega', \mathbb{F}')$  Messraum, eine Funktion  $X$ , die Ereignisse  $\omega_i$  von  $\Omega$  nach  $\Omega'$  abbildet, heißt Zufallsvariable;
- Kumulative Wahrscheinlichkeitsverteilung (KVF, CDF):

$$F_X(x) = P(X \leq x) = P(\omega \in \Omega | X(\omega) \leq x)$$

- $F_X(x)$  monoton wachsend, d.h.  $\frac{dF_X(x)}{dx} \geq 0$
- $F_X(x)$  ist rechtsseitig stetig, d.h.  $\forall h > 0 : \lim_{h \rightarrow 0} F_X(x+h) = F_X(x), \forall x \in \mathbb{R}$
- $\lim_{x \rightarrow -\infty} F_X(x) = 0, \lim_{x \rightarrow \infty} F_X(x) = 1$

Umkehrung dieses Satzes ist möglich, d.h. zu jeder Funktion  $F$ , die obige Eigenschaften erfüllt, existiert eine Zufallsvariable  $X$ .

- Unterscheidung zwischen **stetigen** (Bildraum  $\mathbb{R}$ ) und **diskreten** (Bildraum endlich) Zufallsvariablen
- im Falle einer reellen diskreten Zufallsvariable lässt sich  $F_X(x)$  mittels der **Zähldichte** (probability mass function, PMF)

$$p_X(x) = P(\{X = x\})$$

wie folgt darstellen

$$F_X(x) = \sum_{\xi \in \Omega'; \xi \leq x} p_X(\xi)$$

- im Falle einer reellen stetigen Zufallsvariable lässt sich  $F_X(x)$  mittels der **Wahrscheinlichkeitsdichtefunktion** (probability density function, PDF) wie folgt darstellen

$$F_X(x) = \int_{-\infty}^x f_X(\xi) d\xi \quad \Leftrightarrow \quad f_X(x) = \frac{dF_X(x)}{dx}$$

- **Mehrdimensionale Verteilungen:** Geg. sei  $\mathbf{X} = (X_1, X_2, \dots, X_n)^T$  n-dimensionale Zustandsvariable, für die kumulative Verteilungsfunktion von  $\mathbf{X}$  folgt:

$$F_{X_1, \dots, X_n}(x_1, \dots, x_n) = P(\{\mathbf{X} \leq \mathbf{x}\}) = P(\{X_1 \leq x_1\} \cap \dots \cap \{X_n \leq x_n\})$$

analog zum eindimensionalen Fall folgt:

$$p_{X_1, \dots, X_n} = p(\{\mathbf{X} = \mathbf{x}\})$$

$$F_{X_1, \dots, X_n} = \int_{-\infty}^{x_1} \dots \int_{-\infty}^{x_n} f_{X_1, \dots, X_n}(\xi_1, \dots, \xi_n) d\xi_1 \dots d\xi_n$$

- **Marginalisierung:** Durch Integration/Summation über die nicht mehr berücksichtigten Zufallsvariablen erhält man aus der Verbundwahrscheinlichkeitsdichte/Verbund-Zähldichte die Randdichte/Rand-Zähldichte einer oder mehrerer Zufallsvariablen

$$p_{X_1}(x_1) = \sum_{x_2, \dots, x_n} p_{X_1, \dots, X_n}(x_1, \dots, x_n)$$

$$f_{X_1}(x_1) = \int_{-\infty}^{\infty} \dots \int_{-\infty}^{\infty} f_{X_1, \dots, X_n}(x_1, \dots, x_n) dx_2 \dots dx_n$$

→ **Unabhängigkeit von Zufallsvariablen:** Zufallsvariablen  $X_1, \dots, X_n$  unabhängig, falls

$$f_{X_1, \dots, X_n}(x_1, \dots, x_n) = \prod_{i=1}^n f_{X_i}(x_i)$$

$$F_{X_1, \dots, X_n}(x_1, \dots, x_n) = \prod_{i=1}^n F_{X_i}(x_i)$$

$$p_{X_1, \dots, X_n}(x_1, \dots, x_n) = \prod_{i=1}^n p_{X_i}(x_i)$$

→ **Bedingte Zufallsvariablen:** Definition entsprechend dem Vorgehen bei Ereignissen

$$F_{X|A}(x|A) = P_A(\{X \leq x\}) = P(\{X \leq x\}|A)$$

$$F_{X|Y}(x|y) = P_Y(\{X \leq x\}) = \frac{P(\{X \leq x\} \cap \{Y = y\})}{P(\{Y = y\})}$$

nur definiert, falls  $P(\{Y = y\}) \neq 0$

$$p_{X|Y}(x|y) = \frac{p_{X,Y}(x, y)}{p_Y(y)}$$

$$f_{X|Y}(x|y) = \frac{dF_{X|Y}(x|y)}{dx} = \frac{f_{X,Y}(x, y)}{f_Y(y)}$$

→ **Funktionen von Zufallsvariablen**

– lineare Funktion  $Y = g(X) = aX + b$

$$F_Y(y) = P(\{Y \leq y\}) = P(\{aX + b \leq Y\}) = \begin{cases} F_X\left(\frac{y-b}{a}\right), & a > 0 \\ 1 - F_X\left(\frac{y-b}{a}\right), & a < 0 \end{cases}$$

$$f_Y(y) = \frac{1}{|a|} f_X\left(\frac{y-b}{a}\right)$$

⇒ affine Abbildungen verändern den generellen Typ der Verteilung nicht

– allgemeiner Fall  $Y = g(X)$

$$f_Y(y) = \sum_{i=1}^K f_X(x_i) \left( \left| \frac{dg(x_i)}{dx} \right| \right)^{-1}, \quad y - g(x_i) = 0, \quad i \in 1, \dots, K$$

#### 4 Stochastische Standardmodelle

→ **Verteilungen diskreter Zufallsvariablen**

– diskrete Gleichverteilung:

$$p_X(\omega) = \frac{1}{|\Omega|}$$

– Bernoulli-Verteilung: zwei Ereignisse (Erfolg  $X = 1$ , Misserfolg  $X = 0$ ) von Interesse

\* Parameter:  $p : 0 \leq p \leq 1$

$$* \text{ Zähl-dichte: } p_X(k) = \begin{cases} p, & k = 1 \\ (1 - p), & k = 0 \\ 0, & \text{sonst} \end{cases}$$

- \* Erwartungswert  $E[X] = p$
- \* Varianz:  $\text{Var}[X] = p(1 - p)$
- \* Wahrscheinlichkeitserzeugende Funktion:  $G_X(z) = pz + 1 - p$
- Binomialverteilung: stochastisch unabhängige Hintereinanderausführung mehrerer Bernoulli-Experimente
  - \* Parameter:  $p : 0 \leq p \leq 1, n : n \in \mathbb{N}$
  - \* Zähldichte:  $p_X(k) = \binom{n}{k} p^k (1 - p)^{(n-k)}$
  - \* Erwartungswert:  $E[X] = np$
  - \* Varianz:  $\text{Var}[X] = np(1 - p)$
  - \* Wahrscheinlichkeitsfunktion:  $G_X(z) = (pz + 1 - p)^n$
- Poissonverteilung: geht aus der Binomialverteilung durch Bildung des Grenzwertes  $\lim_{n \rightarrow \infty} B_n(p, k)$  hervor
  - \* Parameter:  $\lambda : \lambda = np = \text{const.}$
  - \* Zähldichte:  $p_X(k) = \frac{\lambda^k}{k!} e^{-\lambda}$
  - \* Erwartungswert:  $E[X] = \lambda$
  - \* Varianz:  $\text{Var}[X] = \lambda$
  - \* Wahrscheinlichkeitserzeugende Funktion:  $G_X(z) = e^{\lambda(z-1)}$
- Geometrische Verteilung: Modellierung von Warteschlangen-Problemen (typische Fragestellung: „Wann tritt Ereignis  $X$  zum ersten Mal auf?“); zusammen mit der Exponentialverteilung einzige *gedächtnislose* Verteilung ( $P(\{X > n + k\} | X > n) = P(\{X > k\})$ )
  - \* Parameter:  $p : 0 \leq p \leq 1$
  - \* Zähldichte:  $p_X(k) = p(1 - p)^{k-1}$
  - \* Erwartungswert:  $E[X] = \frac{1}{p}$
  - \* Varianz:  $\text{Var}[X] = \frac{1-p}{p^2}$
  - \* Wahrscheinlichkeitserzeugende Funktion:  $G_X(z) = \frac{pz}{1-z+pz}$

→ **stetige Verteilungsfunktionen**

- stetige Gleichverteilung:
  - \* Parameter:  $a, b : -\infty < a, b, < \infty$
  - \* Wahrscheinlichkeitsdichtefunktion:
 
$$f_X(x) = \begin{cases} \frac{1}{b-a}, & x \in [a, b] \\ 0, & \text{sonst} \end{cases}$$
  - \* Erwartungswert:  $E[X] = \frac{a+b}{2}$

- \* Varianz:  $\text{Var}[X] = \frac{(b-a)^2}{12}$
- \* Charakteristische Funktion:  $\varphi_X(\omega) = \frac{e^{j\omega b} - e^{j\omega a}}{j\omega(b-a)}$
- Exponentialverteilung:
  - \* Parameter:  $\lambda : \lambda > 0$
  - \* Wahrscheinlichkeitsdichtefunktion:  $f_X(x) = \lambda e^{-\lambda x}$
  - \* Erwartungswert:  $\text{E}[X] = \frac{1}{\lambda}$
  - \* Varianz:  $\text{Var}[X] = \frac{1}{\lambda^2}$
  - \* Charakteristische Funktion:  $\varphi_X(\omega) = \frac{\lambda}{\lambda - j\omega}$
- Normalverteilung
  - \* Parameter:  $\mu : \mu \in \mathbb{R}, \sigma : \sigma > 0$
  - \* Wahrscheinlichkeitsdichtefunktion:  $f_X(x) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{(x-\mu)^2}{2\sigma^2}}$
  - \* Erwartungswert:  $\text{E}[X] = \mu$
  - \* Varianz:  $\text{Var}[X] = \sigma^2$
  - \* Charakteristische Funktion:  $\varphi_X(\omega) = e^{j\omega\mu - \frac{\omega^2\sigma^2}{2}}$

## 5 Erwartungswert und Varianz

→ Erwartungswert diskreter Zufallsvariablen

$$\text{E}[X] = \sum_{x \in \Omega'} x P(\{X = x\}) = \sum_{x \in \Omega'} x p_X(x)$$

Entsprechend folgt für Funktionen von Zufallsvariablen  $Y = g(X)$ :

$$\text{E}[Y] = \text{E}[g(X)] = \sum_{x \in \Omega'} g(x) p_X(x)$$

→ Erwartungswert, Varianz (mittlere quadratische Abweichung) und Kovarianz stetiger Zufallsgrößen

$$\text{E}[X] = \int_{-\infty}^{\infty} x f_X(x) dx$$

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

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

$$\text{Cov}[X, X] = \text{Var}[X]$$

Entsprechend folgt für Funktionen von Zufallsvariablen  $Y = g(X)$ :

$$\text{E}[Y] = \text{E}[g(X)] = \int_{-\infty}^{\infty} g(x) f_X(x) dx$$

→ **Eigenschaften von Erwartungswert, Varianz und Kovarianz**

- Linearität des Erwartungswerts:

$$E[aX + bY] = aE[X] + bE[Y]$$

- Ordnungserhaltung

$$X \leq Y \Rightarrow E[X] \leq E[Y]$$

Sind  $X$  und  $Y$  stochastisch unabhängig, gilt ferner:

$$E[XY] = \int_{-\infty}^{\infty} xy f_{X,Y}(x, y) dx dy = \int_{-\infty}^{\infty} x f_X(x) dx \int_{-\infty}^{\infty} y f_Y(y) dy = E[X] \cdot E[Y]$$

- Eigenschaften der Varianz und Kovarianz

$$\text{Var}[X] = \text{Cov}[X, X]$$

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

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

$$\text{Cov}[X + U, Y + V] = \text{Cov}[X, Y] + \text{Cov}[X, V] + \text{Cov}[U, Y] + \text{Cov}[U, V]$$

- Begriff der Unkorreliertheit zweier Zufallsgrößen:
- $X$
- und
- $Y$
- unkorreliert, falls

$$\text{Cov}[X, Y] = 0 \Leftrightarrow E[XY] = E[X] E[Y]$$

- Begriff der Orthogonalität zweier Zufallsgrößen:
- $X$
- und
- $Y$
- orthogonal, falls

$$E[XY] = 0$$

→ **Standardisierung von Zufallsvariablen:**  $X$  sei reelle Zufallsvariable,  $\mu$  und  $\sigma^2$  deren Erwartungswert und Varianz. Die Standardisierung von  $X$  ist:

$$Y = \frac{1}{\sigma}(X - \mu) \quad \Rightarrow \quad E[Y] = 0, \text{Var}[Y] = 1$$

→ **Korrelationskoeffizient:** Beschreibung der Güte eines möglichen linearen Zusammenhangs zwischen den Zufallsvariablen  $X$  und  $Y$ :

$$\rho_{X,Y} = \frac{\text{Cov}[X, Y]}{\sqrt{\text{Var}[X]} \sqrt{\text{Var}[Y]}} = \frac{c_{X,Y}}{\sigma_X \sigma_Y} \in [-1, 1]$$

Interpretation:

$$\rho_{X,Y} = \begin{cases} 1, & \text{falls } Y = aX + b \text{ mit } a > 0 \\ -1, & \text{falls } Y = aX + b \text{ mit } a < 0 \\ 0, & \text{falls } X \text{ und } Y \text{ unkorreliert} \end{cases}$$

## 6 Erzeugende und charakteristische Funktion

### Erzeugende Funktion (diskrete Zufallsvariablen)

→ **Wahrscheinlichkeitserzeugende Funktion:**  $X$  sei eine diskrete nichtnegative Zufallsvariable

$$G_X(z) = \mathbb{E} \left[ z^X \right] = \sum_{k=0}^{\infty} p_X(k) z^k, |z| \leq 1$$

→ **Berechnung von Wahrscheinlichkeiten, Erwartungswerten und Varianzen:**

$$\begin{aligned} P(\{X = n\}) &= \frac{1}{n!} \left[ \frac{d^n}{dz^n} G_X(z) \right]_{z=0} \\ \mathbb{E}[X] &= \left[ \frac{d}{dz} G_X(z) \right]_{z=1} \\ \text{Var}[X] &= \left[ \frac{d^2}{dz^2} G_X(z) \right]_{z=1} - \mathbb{E}[X]^2 + \mathbb{E}[X] \end{aligned}$$

→ **Erzeugende Funktion einer Summe  $Z = \sum_{i=1}^n X_i$  von stochastisch unabh. Zufallsvariablen  $X_i$ :**

$$G_Z(z) = \prod_{i=1}^n G_{X_i}(z)$$

### Charakteristische Funktion (stetige Zufallsvariablen)

→ **Charakteristische Funktion:**  $X$  sei eine reelle Zufallsvariable

$$\varphi_X(\omega) = \mathbb{E} \left[ e^{j\omega X} \right] = \int_{-\infty}^{\infty} e^{j\omega x} f_X(x) dx$$

→ **Berechnung des Erwartungswerts und höherer Momente:**

$$\mathbb{E}[X^n] = \frac{1}{j^n} \left[ \frac{d^n}{d\omega^n} \varphi_X(\omega) \right]_{\omega=0}$$

→ **Charakteristische Funktion einer Summe  $Z = \sum_{i=1}^n X_i$  von stochastisch unabh. Zufallsvariablen  $X_i$ :**

$$\varphi_Z(\omega) = \prod_{i=1}^n \varphi_{X_i}(\omega)$$

### Zentraler Grenzwertsatz

Aussage: normierte und zentrierte Summe einer großen Anzahl an unabhängigen und identisch verteilter Zufallsgrößen mit endlichen Erwartungswerten und Varianz ist annähernd standardnormalverteilt

## 7 Stochastische Prozesse

### 7.1 Reelle Zufallsfolge

→ **Ensemble und Pfad**: beschreibt unterschiedliche Betrachtungsweise einer Zufallsfolge ( $\mathbf{X}_n : n \in \mathbb{N}$ )

– Ensemble-Darstellung:  $\mathbf{S}_n : \Omega_n \times \Omega_{n-1} \times \dots \times \Omega_1 \rightarrow \mathbb{R}$

$$(w_n, w_{n-1}, \dots, w_1) = s_n(w_n, w_{n-1}, \dots, w_1)$$

– Pfad-Darstellung:  $\mathbf{S}_n = (S_n, S_{n-1}, \dots, S_1) : \Omega^{(n)} \rightarrow \mathbb{R}^n$

$$w_n = s_n(w_n) = (s_n(w_n), s_{n-1}(w_n), \dots, s_1(w_n))$$

→ **Autokorrelations- und Autokovarianzfolge**:

$$r_{\mathbf{X}}(k, l) = \mathbb{E}[\mathbf{X}_k \mathbf{X}_l]$$

$$c_{\mathbf{X}}(k, l) = r_{\mathbf{X}}(k, l) - \mu_{\mathbf{X}}(k)\mu_{\mathbf{X}}(l)$$

→ **Random Walk**: mathematische Modellierung eines des Vorgangs, dass ein Teilchen bei jedem Schritt (Schrittweite  $\delta$ ) mit der Wahrscheinlichkeit  $p$  bzw.  $p - 1$  einen Schritt nach rechts oder links macht; die Richtung der einzelnen Schritte ist hierbei unabhängig voneinander:

$$S_n = \sum_{i=1}^n X_i, \text{ wobei } P(\{X_i = +\delta\}) = p \text{ und } P(\{X_i = -\delta\}) = 1 - p$$

$$\mathbb{E}[X_i] = \delta p - \delta(1 - p) = (2p - 1)\delta$$

$$\text{Var}[X_i] = \mathbb{E}[X_i^2] - \mathbb{E}[X_i]^2 = 4p(1 - p)\delta^2$$

$$\mathbb{E}[S_n] = \mathbb{E}\left[\sum_{i=1}^n X_i\right] = n(2p - 1)\delta$$

$$\text{Var}[S_n] \stackrel{X_i \text{ i.i.d.}}{=} \text{Var}[X_i] = 4np(1 - p)\delta^2$$

→ **Stationarität von Zufallsfolgen**: Folgeelemente sind invariant gegenüber einer Verschiebung der Indizes

Für die Praxis weitaus wichtiger ist die Stationarität im weiteren Sinne, WSS (wide sense stationary):

$$\mu_{\mathbf{X}}(i) = \mu_{\mathbf{X}}(i + k)$$

$$r_{\mathbf{X}}(i_1, i_2) = r_{\mathbf{X}}(i_1 + k, i_2 + k) = r_{\mathbf{X}}(i_1 - i_2) = r_{\mathbf{X}}(\tau), \text{ mit } \tau = i_1 - i_2$$

→ **Konvergenz reeller Zufallsfolgen**

– konvergiert fast sicher (almost surely, a.s.):

$$P\left(\left\{\omega : \lim_{n \rightarrow \infty} \mathbf{X}_n(\omega) = \mathbf{X}(\omega)\right\}\right) = 1, \mathbf{X} \stackrel{\text{a.s.}}{\rightarrow} \mathbf{X}$$

– konvergiert in Wahrscheinlichkeit (in probability, p.):

$$P(\{\omega : |\mathbf{X}_n(\omega) - \mathbf{X}(\omega)| > \varepsilon\}) = 0, \mathbf{X}_n \stackrel{p.}{\rightarrow} \mathbf{X}$$

– konvergiert im quadratischen Mittel (in the mean square sense, m.s.):

$$\lim_{n \rightarrow \infty} \mathbb{E} [(X_n(\omega) - \mathbf{X}(\omega))^2] = 0, \mathbf{X} \xrightarrow{m.s.} \mathbf{X}$$

– konvergiert in Verteilung (in distribution, d.):

$$\lim_{n \rightarrow \infty} F_{X_n}(x) = F_{\mathbf{X}}(x), \mathbf{X}_n \xrightarrow{d} \mathbf{X}$$

→ **Markow-Ungleichung**

$$P(\{|\mathbf{X}| \geq \varepsilon\}) \leq \frac{\mathbb{E}[|\mathbf{X}|]}{\varepsilon}$$

→ **Tschebyschow-Ungleichung**

$$P(\{|\mathbf{X} - \mathbb{E}[\mathbf{X}]| \geq \varepsilon\}) < \frac{\text{Var}[\mathbf{X}]}{\varepsilon^2}$$

## 7.2 Markowketten

→ **Definition Markowkette:**

$$\begin{aligned} p_{\mathbf{X}_{n_k} | \mathbf{X}_{n_{k-1}}, \dots, \mathbf{X}_{n_1}}(x_{n_k}, \dots, x_{n_1}) &= p_{\mathbf{X}_{n_k} | \mathbf{X}_{n_{k-1}}}(x_{n_k} | x_{n_{k-1}}) \\ f_{\mathbf{X}_{n_k} | \mathbf{X}_{n_{k-1}}, \dots, \mathbf{X}_{n_1}}(x_{n_k}, \dots, x_{n_1}) &= f_{\mathbf{X}_{n_k} | \mathbf{X}_{n_{k-1}}}(x_{n_k} | x_{n_{k-1}}) \end{aligned}$$

Interpretation: Die Verteilung einer Zufallsvariable unter der Bedingung einer gegebenen Vergangenheit ( $\mathbf{X}_{n_{k-1}}, \dots, \mathbf{X}_{n_1}$ ) wird nur von der zeitlich am nächsten liegenden Variablen ( $\mathbf{X}_{n_{k-1}}$ ) beeinflusst.

Homogene Markowketten liegen vor, falls die Übergangswahrscheinlichkeiten bzw. Übergangsdichten unabhängig vom Index  $n$  sind.

→ Beispiele für Markowketten: Randomwalk ( $\mathbf{S}_n = \sum_{i=1}^n \mathbf{X}_i$ ) oder  $\mathbf{X}_n = \prod_{i=1}^n \mathbf{W}_i$ , mit ( $\mathbf{W}_i : i \in \mathbb{N}$ ) paarweise stochastisch unabhängig

→ **Darstellung von gemeinsamen Zähl-dichten bzw. Wahrscheinlichkeitsdichten:**

$$\begin{aligned} p_{\mathbf{X}_1, \dots, \mathbf{X}_n}(x_1, \dots, x_n) &= p_{\mathbf{X}_1} \prod_{i=2}^n p_{\mathbf{X}_i | \mathbf{X}_{i-1}}(x_i | x_{i-1}) \\ f_{\mathbf{X}_1, \dots, \mathbf{X}_n}(x_1, \dots, x_n) &= f_{\mathbf{X}_1} \prod_{i=2}^n p_{\mathbf{X}_i | \mathbf{X}_{i-1}}(x_i | x_{i-1}) \end{aligned}$$

Beispiel für  $n = 3$ :

$$p_{\mathbf{X}_1, \mathbf{X}_2, \mathbf{X}_3}(x_1, x_2, x_3) = p_{\mathbf{X}_3 | \mathbf{X}_2, \mathbf{X}_1}(x_3 | x_2, x_1) p_{\mathbf{X}_2 | \mathbf{X}_1}(x_2 | x_1) p_{\mathbf{X}_1}(x_1) \stackrel{\text{Markow}}{=} p_{\mathbf{X}_3 | \mathbf{X}_2}(x_3 | x_2) p_{\mathbf{X}_2 | \mathbf{X}_1}(x_2 | x_1) p_{\mathbf{X}_1}(x_1)$$

→ **Chapman-Kolmogorow-Gleichung:** beschreibt Möglichkeiten zur Berechnung von  $m$ -Schritt Übergangswahrscheinlichkeiten,- dichten der Form  $p_{\mathbf{X}_{n+m} | \mathbf{X}_n}(x_{n+m} | x_n)$ ,  $f_{\mathbf{X}_{n+m} | \mathbf{X}_n}(x_{n+m} | x_n)$

$$p_{\mathbf{X}_{n+m} | \mathbf{X}_n}(x_{n+m} | x_n) = \underbrace{\sum_{x_{n+1}} \cdots \sum_{x_{n+m-1}}}_{\text{Marginalisierung}} \prod_{i=n+1}^{n+m} p_{\mathbf{X}_i | \mathbf{X}_{i-1}}(x_i | x_{i-1})$$

### 7.3 Reelle Zufallsprozesse

→ **Wiener-Prozess:**

– Definition:

$$S_t = \sum_{i=1}^n X_i u(t - iT)$$

– Eigenschaften:

\* Autokovarianzfunktion, Autokorrelationsfunktion

$$\begin{aligned} \mu_W(t) &= E[W_t] = E[W_t - W_0] = 0 \\ r_W(s, t) &= c_W(s, t) = \sigma^2 \min(s, t) \quad (\text{nicht WSS, daher auch nicht stationär!}) \end{aligned}$$

→ **Poisson-Prozess:**

– Definition:

$$\begin{aligned} N_t &= \sum_{i=1}^{\infty} u(t - T_i), & T_i &= \sum_{j=1}^i X_j \\ P(\{N_t = n\}) &= \frac{(\lambda t)^n}{n!} e^{-\lambda t} \end{aligned}$$

– Eigenschaften:

- \* Zählprozess, die Musterfunktionen sind entsprechend monoton steigend
- \* Zeitintervalle zwischen den Inkrementierungen sind unabhängige identisch verteilte Zufallsvariablen mit Parameter  $\lambda$
- \* Autokorrelationsfunktion, Autokovarianzfunktion

$$\begin{aligned} \mu_N(t) &= E[N_t] = E[N_t - N_0] = \lambda t \\ r_N(s, t) &= \lambda \min(s, t) + \lambda^2 st \\ c_N(s, t) &= r_N(s, t) - \mu_N(s)\mu_N(t) = \lambda \min(s, t) \end{aligned}$$

### 7.4 Eigenschaften der Korrelationsfunktion von gemeinsam WSS Zufallsprozessen

→ Eigenschaften:

$$\begin{aligned} r_X(\tau) &\leq r_X(0) \\ |r_{X,Y}(\tau)| &\leq \sqrt{r_X(0)r_Y(0)} \\ r_X(\tau) &= r_X(-\tau) \\ \mathbf{a}^T \mathbf{R}_X \mathbf{a} &\geq 0, [\mathbf{R}]_{k,l} = r_X(t_k, t_l) \end{aligned}$$

### 7.5 Leistungsdichtespektrum

→ **Definition:**

$$\begin{aligned} S_X(f) &= \int_{-\infty}^{\infty} r_X(\tau) e^{-j\omega\tau} d\tau \\ S_X(f) &\bullet \longleftrightarrow r_X(\tau) \end{aligned}$$

→ **Eigenschaften:**

$$S_X(f) = S_X^*(f), \forall f \in \mathbb{R}$$

$$S_X(f) = S_X(-f), \forall f \in \mathbb{R}$$

$$\int_{-\infty}^{\infty} S_X(f) df = r_X(0) = \sigma_X^2 + \mu_X^2$$

$$S_X(f) \geq 0, \forall f \in \mathbb{R}$$

→ **Zusammenhang Leistungsdichtespektrum und Übertragungsfunktion  $A(f)$  eines LTI-Systems**

$$S_Y(f) = |A(f)|^2 S_X(f)$$

$$S_{Y,X}(f) = A(f) S_X(f)$$

$$S_{X,Y}(f) = A^*(f) S_X(f)$$