

2) Bedingte Wahrscheinlichkeiten und Unabhängigkeit.

2.1) Bedingte Wahrscheinlichkeit.

Beispiel: Aus Statistiken (hier sind fiktiven Daten) über Kleinkinder, sind 2 Merkmale "Krabbeln" und "Laufen" zeitlich gemessen.

Seien $A = \{\text{Läuft vor 10 Monaten}\}$
und $B = \{\text{Krabbelt vor 6 Monaten}\}$
zwei Ereignisse, mit

$$\mathbb{P}(\text{Läuft vor 10 Monaten}) = 0,25$$


$$\text{und } \mathbb{P}(\text{Krabbelt vor 6 Monaten}) = 0,20.$$

Frage: Sei nun ein Kind 6 Monaten alt und krabbelt (d.h., B tritt ein). Wie wahrscheinlich ist es, dass in 4 Monaten das Kind schon läuft?

Um die Frage eine Antwort zu geben braucht man mehr Informationen, z.B.

W-keit	A	A^c
B	0,15	0,05
B^c	0,10	0,70

Man kann dann die Frage beantworten, unter die Annahme, dass das Kind "ein" zufällige Kind der Statistik ist.



Wir wissen, dass B tritt ein.

⇒ Teilen wir $\Omega = \Omega_B \cup \Omega_B^c$
wobei $\Omega_B = \{\omega \in \Omega \mid \omega \in B\}$.

Um die Frage zu beantworten, definieren wir eine neue W-Kett auf Ω , mit Gewichte $p(\cdot|B)$, die die Information $\omega \in B$ berücksichtigt, d.h.,

$$p(\omega|B) := a \text{ für alle } \omega \in \Omega_B^c.$$

Da die Information $\omega \in B$ ist die gleiche $\forall \omega \in \Omega_B$, setzen wir

$$p(\omega|B) := \text{const.} \cdot p(\omega) \text{ für } \omega \in \Omega_B.$$

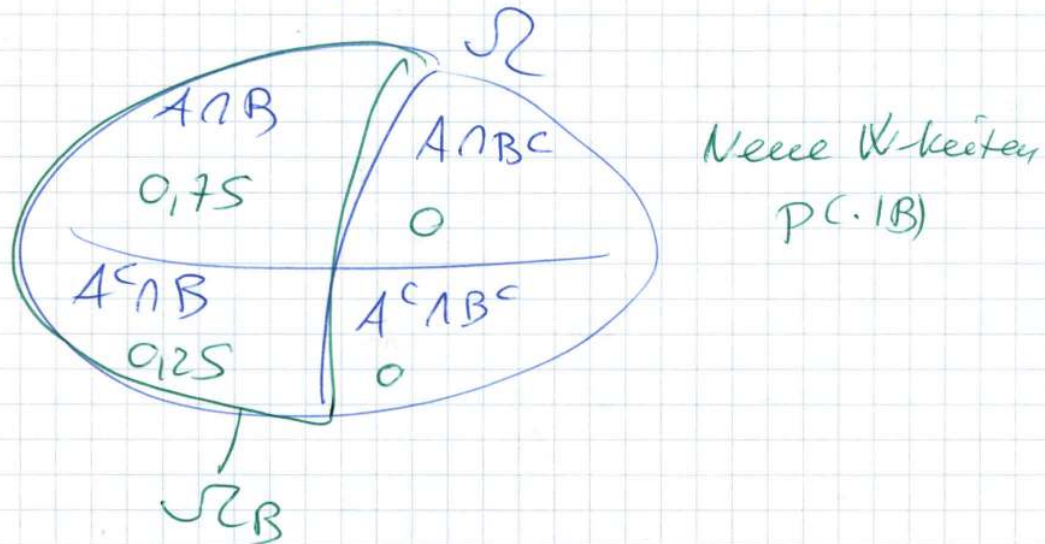
Die Normierung $\sum_{\omega \in \Omega} p(\omega|B) = \sum_{\omega \in \Omega_B} p(\omega|B) = 1$

liefert dann $\text{const} = \frac{1}{\mathbb{P}(B)}$, d.h.,

(42)

$$p(\omega|B) = \frac{p(\omega)}{\mathbb{P}(B)}$$

In unserem Beispiel, $\mathbb{P}(B) = 0,2$, deshalb



⇒ Antwort: Mit 75% wird das Kind mit 10 Monaten laufen.

Definition 1) Sei $(\Omega, \mathcal{F}, \mathbb{P})$ ein \mathbb{K} -raum,
 $A, B \in \mathcal{F}$ Ereignisse mit
 $\mathbb{P}(B) \neq 0$. Dann,
$$\mathbb{P}(A|B) := \frac{\mathbb{P}(A \cap B)}{\mathbb{P}(B)}$$

heißt die bedingte \mathbb{K} -keit von A gegeben B .

Bemerkung: a) $\mathbb{P}(\cdot|B) : A \mapsto \mathbb{P}(A|B)$

ist eine \mathbb{W} -Verteilung auf (Ω, \mathcal{F}) ,
die "bedingte Verteilung gegeben B".

b) $\mathbb{P}(\cdot|B)$ hat Gewichte

$$\mathbb{P}(w|B) = \begin{cases} \frac{\mathbb{P}(w)}{\mathbb{P}(B)} & , w \in B, \\ 0 & , w \notin B. \end{cases}$$

c) Sei $X : \Omega \rightarrow S \subset \mathbb{R}$ eine (diskrete)
Zufallsvariable mit Verteilung $\mathbb{P}(\cdot|B)$.
Dann X hat Erwartungswert

$$\mathbb{E}(X|B) = \sum_{s \in S} s \cdot \mathbb{P}(X=s|B),$$

die "bedingte Erwartung von X gegeben B".

Beispiel: n fairer Münzwürfer ergeben
 n mal die Zahl.

Was ist die \mathbb{W} -keit, dass bei den
ersten m Würfeln immer die Zahl fällt?

$$\cdot \Omega = \{w = (x_1, \dots, x_n) \mid x_k \in \{0, 1\}\}$$

wobei $x_k = \begin{cases} 1 & , \text{Ausgang } k.\text{te Wurf} \equiv \text{Zahl} \\ 0 & , \text{ " " " " " " } \equiv \text{Kopf.} \end{cases}$

mit (wegen "fairer") Gleichverteilung \mathbb{P} .

Sei $X_k(\omega) = x_k, k=1, \dots, N.$

$$\begin{aligned} \Rightarrow \mathbb{P}(X_1 = \dots = X_u = 1 \mid \sum_{k=1}^N X_k = u) &= \\ &= \mathbb{P}(X_1 = \dots = X_u = 1, \sum_{k=u+1}^N X_k = u-u) \\ &= \frac{\mathbb{P}(\sum_{k=1}^N X_k = u)}{\sum_{k=1}^N \mathbb{P}(X_k = u)} \\ &= \frac{2^{-N} \cdot \binom{N-u}{u-u}}{2^{-N} \cdot \binom{N}{u}} = \frac{(N-u)! \cdot u!}{N! \cdot (u-u)!} \end{aligned}$$

Bislang : $\mathbb{P} \rightarrow \mathbb{P}(\cdot | B).$

Es gilt aber auch eine Identität in die andere Richtung.

Satz 2) Sei $\Omega = \bigcup_{k \in I} H_k$ eine disjunkte

Zerlegung von Ω in (abzählbar) viele Hypothesen $H_k, k \in I.$

Dann, $\forall A \in \mathcal{F},$

$$\mathbb{P}(A) = \sum_{\substack{k \in I, \\ \mathbb{P}(H_k) > 0}} \mathbb{P}(A | H_k) \mathbb{P}(H_k).$$

Beweis: $\forall A \in \mathcal{F}, A = A \cap \Omega = A \cap (\bigcup_{k \in I} H_k) \stackrel{\text{disjunkte}}{=} \bigcup_{k \in I} (A \cap H_k)$

$$\Rightarrow \mathbb{P}(A) \stackrel{\sigma\text{-add.}}{=} \sum_{k \in I} \mathbb{P}(A \cap H_k) = \sum_{\substack{k \in I \\ \mathbb{P}(H_k) > 0}} \mathbb{P}(A \cap H_k) \text{ und mit } \mathbb{P}(A \cap H_k) = \mathbb{P}(A | H_k) \mathbb{P}(H_k)$$

Beispiel: Urne A enthält 2 rote und 3 blaue Kugeln, Urne B dagegen 3 rote und 2 blaue.

Wir ziehen eine Kugel (K_1) aus A und legen wir in B. Danach ziehen wir eine Kugel (K_2) aus B.

$\mathbb{P}(K_2 \text{ ist rot}) = ?$



Ⓐ Falls K_1 rot \Rightarrow



Ⓑ Falls K_1 blau \Rightarrow



$$\begin{aligned} \Rightarrow \mathbb{P}(K_2 \text{ rot}) &= \mathbb{P}(K_2 \text{ rot} | K_1 \text{ rot}) \mathbb{P}(K_1 \text{ rot}) \\ &\quad + \mathbb{P}(K_2 \text{ rot} | K_1 \text{ blau}) \mathbb{P}(K_1 \text{ blau}) \\ &= \frac{4}{6} \cdot \frac{2}{5} + \frac{3}{6} \cdot \frac{2}{5} = \frac{17}{30} \end{aligned}$$

2.2) Bayessche Regel

In Bayessche Statistik $\mathbb{P}(H_k)$ ist die "a priori" Einschätzung der W-keit von Hypothese H_k

(Bsp: $H_k =$ Unfallkosten pro Jahr $\in [k, 100\text{€}, (k+1), 100\text{€})$)

Aus statistische Daten weiss man auch, dass ein Ereignis $A \in \mathcal{F}$ mit $\mathbb{P}(A) \neq 0$ eintritt
(Bsp: ein Auffahrunfall)

und dazu kennt man (die Bayesische)

$\mathbb{P}(A|H_k)$, die bedingte W-keit für das Eintreten von A unter Hypothese H_k .

(Bsp: W-keit, dass beim Auffahrtunfall die Unfallkosten in $[k \cdot 100 \text{ €}, (k+1) \cdot 100 \text{ €}]$ liegen).

Falls A passiert, wird man (die Versicherungskosten neu berechnen auf der Basis von) $\mathbb{P}(H_k|A)$: die "a posteriori"-Verteilung.

Korollar 3) Für $A \in \mathcal{F}$ mit $\mathbb{P}(A) \neq 0$, gilt es:

$$\mathbb{P}(H_k|A) = \frac{\mathbb{P}(A|H_k) \mathbb{P}(H_k)}{\sum_{e \in I, \mathbb{P}(H_e) \neq 0} \mathbb{P}(A|H_e) \cdot \mathbb{P}(H_e)}$$

$$\forall k \in I \text{ mit } \mathbb{P}(H_k) \neq 0.$$

Beweis:
$$\mathbb{P}(H_k|A) \stackrel{\text{Def}}{=} \frac{\mathbb{P}(A|H_k)}{\mathbb{P}(A)}$$

$$\stackrel{\text{Satz 7}}{=} \frac{\mathbb{P}(A|H_k) \mathbb{P}(H_k)}{\sum_{e \in I, \mathbb{P}(H_e) \neq 0} \mathbb{P}(A|H_e) \cdot \mathbb{P}(H_e)} \quad \#$$

Beispiel: Eine Krankheit K tritt mit 10^{-4} Häufigkeit ein.

Ein Test ist positiv (+) bei 96% der Kranken und 0,1% der Gesunden

Apriori: $P(K) = 10^{-4}$; $P(K^c) = 1 - 10^{-4}$

Bed.W.-keiten: $P(+|K) = 0,96$,
 $P(+|K^c) = 0,001$

A posteriori: $P(K|+) =$
 $= \frac{P(+|K)P(K)}{P(+|K)P(K) + P(+|K^c)P(K^c)}$
 $\approx 1/111$.

\Rightarrow Die W.-keit, dass man krank ist, wenn man positiv getestet ist nur $\approx 9\%$

2.3) Mehrstufige Modelle

Wir betrachten eine Folge von n (diskrete) Zufallsexperimenten, mit $\Omega_1, \dots, \Omega_n$ die Stichproberäume.

Damit definiert man ein n -stufiges Zufallsexp.

$$\Omega = \Omega_1 \times \dots \times \Omega_n = \left\{ \omega = (\omega_1, \dots, \omega_n) \mid \omega_k \in \Omega_k \right\}_{k=1, \dots, n}$$

und setzen wir

$$\mathcal{F} = \mathcal{P}(\Omega).$$

Dazu setzen wir die Zufallsvariablen

$$X_k(\omega) = \omega_k, \quad k=1, \dots, n.$$

Der Index "k" kann als "Zeit" gesehen.

Falls wir die Aufangsverteilung

$$\mathbb{P}(X_1 = x_1) =: p_1(x_1), \quad \forall x_1 \in \Omega_1$$

und die bedingten Verteilungen

$$\mathbb{P}(X_k = x_k \mid X_1 = x_1, \dots, X_{k-1} = x_{k-1}) =: p_k(x_k \mid x_1, \dots, x_{k-1})$$

$$\forall x_e \in \Omega_e, \quad e=1, \dots, k \quad \mathbb{P}(X_1 = x_1, \dots, X_{k-1} = x_{k-1}) > 0,$$

dann kann man die Verteilung \mathbb{P} auf Ω konstruieren.

Beispiel: Lotto Ziehung.

Satz 4) Seien $P_1(\cdot)$ und $P_k(\cdot | x_1, \dots, x_{k-1})$

$\forall k=2, \dots, n, x_i \in \Omega_i \rightarrow x_{k-1} \in \Omega_{k-1}$

Massefunktionen einer W -Verteilung auf Ω_n .

Dann, $\exists!$ W -Verteilung \mathbb{P} auf (Ω, \mathcal{F})

s.d. (a) $\mathbb{P}(X_1=x_1) = P_1(x_1)$

(b) $\mathbb{P}(X_k=x_k | X_1=x_1, \dots, X_{k-1}=x_{k-1}) = P_k(x_k | x_1, \dots, x_{k-1})$

\mathbb{P} hat die Massefunktion

$P(x_1, \dots, x_n) = P_1(x_1) P_2(x_2 | x_1) \dots P_n(x_n | x_1, \dots, x_{n-1})$

Beweis: Eindeutigkeit:

Zu zeigen: $\forall k=1, \dots, n, \mathbb{P}(X_1=x_1, \dots, X_k=x_k) = P(x_1, \dots, x_k)$ \otimes

IA: Für $k=1$ stimmt.

IV: Sei \otimes gültig für $k-1$. Dann:

(a) $P(x_1, \dots, x_{k-1}) = 0 \Rightarrow 0 = 0 \checkmark$

(b) Falls $P(x_1=x_1, \dots, x_{k-1}=x_{k-1}) \neq 0$, dann

$\mathbb{P}(X_1=x_1, \dots, X_k=x_k) = \mathbb{P}(X_1=x_1, \dots, X_{k-1}=x_{k-1})$

$\cdot \mathbb{P}(X_k=x_k | X_1=x_1, \dots, X_{k-1}=x_{k-1})$

$\stackrel{IV}{=} (P_1(x_1) \dots P_{k-1}(x_{k-1} | x_1, \dots, x_{k-2})) \cdot P_k(x_k | x_1, \dots, x_{k-1})$

Existenz: Normierung:

$\forall x \in \Omega \Rightarrow x = (x_1, \dots, x_n)$ mit $x_k \in \Omega_k$ i.d.H.,

$\sum_{x \in \Omega} P(x) = \sum_{x_1 \in \Omega_1} \dots \sum_{x_n \in \Omega_n} P(x_1, \dots, x_n)$

$$= \sum_{x_1 \in \mathcal{X}_1} P_1(x_1) \cdots \underbrace{\sum_{x_n \in \mathcal{X}_n} P_n(x_n | x_1, \dots, x_{n-1})}_{=1} = \dots = 1.$$

Dazu, (b) gilt weil:

$$\begin{aligned} \mathbb{P}(X_1=x_1, \dots, X_k=x_k) &= \sum_{x_{k+1} \in \mathcal{X}_{k+1}} \cdots \sum_{x_n \in \mathcal{X}_n} P(x_k, \dots, x_n) \\ &= \mathbb{P}(X_1=x_1, \dots, X_{k-1}=x_{k-1}) \\ &= P_1(x_1) \cdots P_{k-1}(x_{k-1} | x_1, \dots, x_{k-2}) \\ &\quad \cdot P_k(x_k | x_1, \dots, x_{k-1}) \end{aligned}$$

$$\Rightarrow \mathbb{P}(X_k=x_k | X_1=x_1, \dots, X_{k-1}=x_{k-1}) = P_k(x_k | x_1, \dots, x_{k-1}). \quad \#$$

Falls $P_k(x | x_1, \dots, x_{k-1})$ nur von $x_{k-1}, \dots, x_{k-m+1}$ hängt, dann sagen wir, dass unsere Modell hat ein "Gedächtnis" von " $m-1$ " Schritten.

2 Wichtige Klassen von Modellen:

- (a) $m = -1$: Produktmodelle
- (b) $m = 0$: Markovketten (MK).

2.3.1) Produktmodelle

Falls $P_k(x_k | x_1, \dots, x_{k-1}) = P_k(x_k)$, dann aus Satz 4 folgt:

$$P(x_1, \dots, x_n) = \prod_{k=1}^n P_k(x_k), \quad x = (x_1, \dots, x_n) \in \mathcal{X}.$$

Def. 5) Die W -Verteilung P auf

$\Omega = \Omega_1 \times \dots \times \Omega_n$ mit Massenfunktion

$$P(x_1, \dots, x_n) = \prod_{k=1}^n P_k(x_k)$$

heißt Produkt von P_1, \dots, P_n .

Notation: $P = P_1 \otimes \dots \otimes P_n$.

Beispiel: Seien n unabhängige 0-1-Experimente mit Erfolgswahrscheinlichkeit p ,

d.h., $\Omega_1 = \dots = \Omega_n = \{0, 1\}$

mit $P_k(1) = p = 1 - P_k(0)$, $k=1, \dots, n$.

Dann, $P_k(1) = (1-p) \cdot \left(\frac{p}{1-p}\right)^1$ und

$$P_k(0) = (1-p) \left(\frac{p}{1-p}\right)^0$$

$$\Rightarrow P(x_1, \dots, x_n) = (1-p)^n \prod_{k=1}^n \left(\frac{p}{1-p}\right)^{x_k}$$

heißt die n -dimensionale Bernoulli Verteilung (zum Parameter p).

Beweis:

Produktmodelle



Unabhängige Z.V.
(siehe Kapitel 2.4).

Satz 6) Sei $(\Omega, \mathcal{F}, \mathbb{P})$ ein Produktmodell (52)

Dann, für beliebige Ereignisse

$A_k \subseteq \Omega_k, k=1, \dots, n$ gilt:

$$\mathbb{P}(A_1 \times \dots \times A_n) = \prod_{k=1}^n \mathbb{P}_k(A_k)$$

(und $\mathbb{P}(A_k) = \mathbb{P}_k(A_k)$).

Beweis: $\mathbb{P}(A_1 \times \dots \times A_n) = \mathbb{P}((X_1, \dots, X_n) \in A_1 \times \dots \times A_n)$

$$= \sum_{(x_1, \dots, x_n) \in A_1 \times \dots \times A_n} \underbrace{\mathbb{P}(x_1, \dots, x_n)}_{\text{Prod. Modell}} = \sum_{x_1 \in A_1} \dots \sum_{x_n \in A_n} \prod_{k=1}^n \mathbb{P}_k(x_k)$$

$$= \prod_{k=1}^n \sum_{x_k \in A_k} \mathbb{P}_k(x_k) = \prod_{k=1}^n \mathbb{P}_k(A_k).$$

Aussordnen, $\mathbb{P}(X_k \in A_k) =$

$$= \mathbb{P}(X_\ell \in \Omega_\ell, \ell \neq k, X_k \in A_k)$$

$$= \underbrace{\prod_{\ell \neq k} \mathbb{P}_\ell(X_\ell \in \Omega_\ell)}_{=1} \cdot \mathbb{P}_k(X_k \in A_k) \neq$$

2.3.2) Markovkette (MK)

• Kein Gedächtnis: $m=0$.

• Es ist üblich statt mit 1, mit 0 anzufangen.

Betrachten $\Omega_k = \mathcal{S}$ für ein festes (abzählbares)

\mathcal{S} und

$$\Omega = \mathcal{S}^{n+1} = \{(x_0, \dots, x_n) \mid x_k \in \mathcal{S}, k=0, \dots, n\}.$$

Da $n=0$: $P_k(x_k | x_1, \dots, x_{k-1}) = P_k(x_k | x_{k-1})$.

Def. 7) Eine Markovkette^(MK) ist ein zweistufiges Modell mit
 $P_k(x_k | x_1, \dots, x_{k-1}) = P_k(x_k | x_{k-1})$.

Def. 8) Eine Matrix $P(x, y)$, $x, y \in S$ mit
a) $P(x, y) \geq 0$, $\forall x, y \in S$
und
b) $\sum_{y \in S} P(x, y) = 1$, $\forall x \in S$
heißt eine stochastische Matrix auf S .

Was ist der Link zwischen MK und stochastische Matrizen?

Lemma 9) Sei $P_k(x, y) := P_k(y | x)$,
ist eine stochastische Matrix.

Beweis: a) v. klar.

b) $\sum_{y \in S} P(x, y) = \sum_{y \in S} \mathbb{P}(X_k = y | X_{k-1} = x)$
 $\stackrel{\sigma\text{-add.}}{=} \mathbb{P}\left(\underbrace{\bigcup_{y \in S} \{X_k = y\}}_{= S_k = S} \mid X_{k-1} = x\right) \stackrel{\text{Normierung}}{=} 1. \quad \#$

- Fragen:
- $\mathbb{P}(X_k = x) = ?$
 - $\lim_{k \rightarrow \infty} \mathbb{P}(X_k = x) = ?$
 - Ist \uparrow von x_0 abhängig?

4. Mai

Bemerkung: Seien P und Q zwei stochastische Matrizen auf S , dann ist $P \cdot Q$ auch eine stochastische Matrix auf S .

In der Tat, positivität ist klar und

$$\sum_{\gamma \in S'} (P \cdot Q)(x, \gamma) = \sum_{\gamma \in S'} \sum_{z \in S'} P(x, z) P(z, \gamma)$$

$$= \sum_{z \in S'} P(x, z) \cdot \underbrace{\sum_{\gamma \in S'} P(z, \gamma)}_{=1} = 1.$$

F: Wie berechnet man die Verteilung zur Zeitpunkt n ?

Satz 10: Sei μ_0^t den ^{Zeiten} Vektor mit $\mu_0(x), x \in S$ ^{als Einträge} und P_1, \dots, P_n die "Übergangsmatrizen" einer MK auf S . Dann die Verteilung zur Zeit n ist $\mu_n^t(x) = \mathbb{P}(X_n = x) = (P_0 P_1 \dots P_n)(x), x \in S$ ^{durch} gegeben.

Beweis: Aus Satz 4 und Def 7 gilt

$$P(x_0, \dots, x_n) = P_0(x_0) \cdot \underbrace{P_1(x_1|x_0)}_{=P_1(x_0, x_1)} \cdot P_2(x_2|x_1) \cdot \dots \cdot \underbrace{P_n(x_n|x_{n-1})}_{=P_n(x_{n-1}, x_n)}$$


$$\mu_n^t(x) = \sum_{x_0 \in S} \dots \sum_{x_{n-1} \in S} P(x_0, \dots, x_n) = (P_0 P_1 \dots P_n)(x) \neq$$

Beispiele: (a) Produktmodelle sind MK.


(b) Random walk auf $S = \mathbb{Z}^d$, $d \in \mathbb{N}$.

(symmetrische) (auf Deutsch: "Irrfahrt").

$$P_K(x, y) = \begin{cases} \frac{1}{2d}, & \text{falls } \|x - y\| = 1, \\ 0, & \text{sonst.} \end{cases}$$



(c) Uhrmodell von Ehrenfest



• N Teilchen verteilt in A und B.

Zu jeder Zeit $t \in \mathbb{N}$ wechselt eine zufällig ausgewählte Kugel die Urne.

• makroskopische Grösse:

Sei $n_A = \#$ Kugeln in Urne A, dann eine makroskopische Grösse ist

$$S_A := \frac{n_A}{N} \in \left\{ 0, \frac{1}{N}, \frac{2}{N}, \dots, \frac{N-1}{N}, 1 \right\} = S'$$

Die Markkette mit Übergangsmatrix

$$P(x, y) = \begin{cases} x, & \text{falls } y = x - \frac{1}{D}, \\ 1-x, & \text{falls } y = x + \frac{1}{D}, \\ 0, & \text{sonst} \end{cases}$$

beschreibt die (diskrete) Zeitentwicklung von S_A .

Mikroskopisches Modell:

• Sei $S^N = \{0, 1\}^N = \{(\sigma_1, \dots, \sigma_N) = \sigma \mid \sigma_k \in \{0, 1\}\}$

wobei $\tau_k = \begin{cases} 1, & \text{falls Teilchen } k \text{ ist in Urne } A, \\ 0, & \text{sonst.} \end{cases}$

Dann, die MK die die Zeitentwicklung von $\sigma \in S^N$ beschreibt ist gegeben durch

$$P(\sigma, \tilde{\sigma}) = \begin{cases} \frac{1}{D}, & \text{falls } \sum_{k=1}^N |\sigma_k - \tilde{\sigma}_k| = 1, \\ 0, & \text{sonst.} \end{cases}$$

d.h., $\|\sigma - \tilde{\sigma}\| = 1$.

\Rightarrow Das ist ein Random Walk auf dem Hyperwürfel
 $\{0, 1\}^N$.

Frage: Wie berechnet man die Übergangswkkeit zwischen zwei Zeiten $0 \leq k < e \leq n$?

Satz 11) (Markov Eigenschaft)

Für alle $0 \leq k < e \leq n$ und $x_0, \dots, x_e \in S^N$ mit $\mathbb{P}(X_0 = x_0, \dots, X_k = x_k) \neq 0$ gilt:

$$\begin{aligned} \mathbb{P}(X_e = x_e \mid X_0 = x_0, \dots, X_k = x_k) &= \mathbb{P}(X_e = x_e \mid X_k = x_k) \\ &= (P_{k+1} \dots P_e)(x_k, x_e). \end{aligned}$$

Beweis:
$$\mathbb{P}(X_e = x_e | X_0 = x_0, \dots, X_k = x_k) =$$

$$= \frac{\mathbb{P}(X_0 = x_0, \dots, X_k = x_k, X_e = x_e)}{\mathbb{P}(X_0 = x_0, \dots, X_k = x_k)}$$

$$= \frac{\sum_{x_{k+1}, \dots, x_{e-1} \in S} P_0(x_0) P_1(x_0, x_1) \dots P_k(x_{k-1}, x_k) P_{k+1}(x_k, x_{k+1}) \dots P_e(x_{e-1}, x_e)}{P_0(x_0) P_1(x_0, x_1) \dots P_k(x_{k-1}, x_k)}$$

$$= (P_{k+1} \dots P_e)(x_k, x_e).$$


und
$$\mathbb{P}(X_e = x_e | X_k = x_k) = \frac{\mathbb{P}(X_e = x_e, X_k = x_k)}{\mathbb{P}(X_k = x_k)}$$

$$\stackrel{\text{Satz 10}}{=} \sum_{x_{k+1}, \dots, x_{e-1} \in S} \frac{(\cancel{P_0} \dots \cancel{P_k})(x_k) \cdot P_{k+1}(x_k, x_{k+1}) \dots P_e(x_{e-1}, x_e)}{(\cancel{P_0} \dots \cancel{P_k})(x_k)}$$

$$= (P_{k+1} \dots P_e)(x_k, x_e). \quad \#$$

Bem.: Falls $P_k = P \forall k$, dann die MK ist homogen.

Beispiel 1: $S = \{0, 1\}$ und $\alpha, \beta \in (0, 1)$.



Matrix:
$$P = \begin{pmatrix} 1-\alpha & \alpha \\ \beta & 1-\beta \end{pmatrix}$$

Um P^n zu berechnen kann man:

- (falls möglich) P diagonalisieren
- eine Formel finden und durch Induktion beweisen.

Fangen wir von ⑥:

Man weiss:
$$\left. \begin{aligned} P^n(0,0) + P^n(0,1) &= 1 \\ P^n(1,0) + P^n(1,1) &= 1 \end{aligned} \right\} \textcircled{*}$$

weil P^n ist eine stochastische Matrix.

Dazu:
$$\begin{aligned} P^n(0,0) &= P^{n-1}(0,0)P(0,0) + P^{n-1}(0,1)P(1,0) \\ &= P^{n-1}(0,0) \cdot (1-\alpha) + \underbrace{P^{n-1}(0,1)}_{=1-P^{n-1}(0,0)} \cdot \beta \\ &= P^{n-1}(0,0) \cdot (1-\alpha-\beta) + \beta \end{aligned}$$

$$\begin{aligned} \Rightarrow \boxed{P^n(0,0)} &= P^{n-2}(0,0) \cdot (1-\alpha-\beta)^2 + \beta(1-\alpha-\beta) + \beta \\ &= \dots = P^0(0,0)(1-\alpha-\beta)^n + \sum_{k=0}^{n-1} \beta(1-\alpha-\beta)^k \\ &= (1-\alpha-\beta)^n + \beta \cdot \frac{1-(1-\alpha-\beta)^n}{1-(1-\alpha-\beta)} \\ &= \frac{\beta}{\alpha+\beta} + (1-\alpha-\beta)^n \cdot \left(1 - \frac{\beta}{\alpha+\beta}\right) \\ &= \frac{\beta}{\alpha+\beta} + \frac{\alpha}{\alpha+\beta} \cdot (1-\alpha-\beta)^n \end{aligned}$$

Zusammen mit ④ und, dass die Formel für $P^n(1,1)$ ist die gleiche aber mit α, β vertauscht, findet man: **Exponentiell schnell Verfall!**

$$P^n = \begin{pmatrix} \frac{\beta}{\alpha+\beta} & \frac{\alpha}{\alpha+\beta} \\ \frac{\beta}{\alpha+\beta} & \frac{\alpha}{\alpha+\beta} \end{pmatrix} + (1-\alpha-\beta)^n \cdot \begin{pmatrix} \frac{\alpha}{\alpha+\beta} & -\frac{\alpha}{\alpha+\beta} \\ -\frac{\beta}{\alpha+\beta} & \frac{\beta}{\alpha+\beta} \end{pmatrix}$$

Inbesondere: $\lim_{n \rightarrow \infty} P^n = \begin{pmatrix} \frac{\beta}{\alpha+\beta} & \frac{\alpha}{\alpha+\beta} \\ \frac{\beta}{\alpha+\beta} & \frac{\alpha}{\alpha+\beta} \end{pmatrix}$ weil $|1-\alpha-\beta| < 1$.

Bem.: Da $\lim_{n \rightarrow \infty} P^n$ ist eine Matrix mit Gleichen Zeilen
 ist kein Zufall.
 Es folgt, dass

$$\lim_{n \rightarrow \infty} \mathbb{P}(X_n = 0) = (P_0(0) \quad P_0(1)) \begin{pmatrix} \frac{\beta}{\alpha+\beta} & \frac{\alpha}{\alpha+\beta} \\ \frac{\beta}{\alpha+\beta} & \frac{\alpha}{\alpha+\beta} \end{pmatrix}$$

$$= \begin{pmatrix} \frac{\beta}{\alpha+\beta} & \frac{\alpha}{\alpha+\beta} \\ \frac{\beta}{\alpha+\beta} & \frac{\alpha}{\alpha+\beta} \end{pmatrix} \text{ ist unabhängig$$

Von der Anfangsbedingung

$P_0(0), P_0(1)$.

$$\uparrow \\ P_0(0) + P_0(1) = 1$$

Methode @: Eigenwerte von P :

(Skip-vertl.)
$$\det(\lambda \mathbb{1} - P) = \det \begin{pmatrix} \lambda - (1-\alpha) & -\alpha \\ -\beta & \lambda - (1-\beta) \end{pmatrix}$$

$$= \lambda^2 - (2 - \alpha - \beta)\lambda - \alpha^2 + (1-\alpha)(1-\beta) = 0$$

$$\Leftrightarrow \begin{cases} \lambda_1 = 1 & \rightarrow \vec{r}_1 = (1, 1)^t \\ \lambda_2 = 1 - \alpha - \beta & \rightarrow \vec{r}_2 = (\alpha, -\beta)^t \end{cases}$$

Bem.: $\lambda_1 = 1$ ist immer dabei, weil P eine
 Stochastische Matrix.

In der Tat, $\vec{r} = (1, 1, \dots, 1)^t$ ist ein Eigenvektor
 von P mit Eigenwert 1:

$$(P \cdot \vec{r})(x) = \sum_{y \in S} P(x, y) \underbrace{\vec{r}(y)}_{=1} = 1 = \vec{r}(x)$$

Da die Eigenwerte (alle) verschiedene sind,
 kann man P diagonalisieren:

$$\text{Sei } U = (\vec{r}_1 \mid \vec{r}_2) \Rightarrow P = U \begin{pmatrix} \lambda_1 & 0 \\ 0 & \lambda_2 \end{pmatrix} U^{-1} \\ = \begin{pmatrix} 1 & \alpha \\ 1 & -\beta \end{pmatrix}$$

$$\Rightarrow P^4 = U \begin{pmatrix} \lambda_1^4 & 0 \\ 0 & \lambda_2^4 \end{pmatrix} U^{-1}$$

(60)

$$= \begin{pmatrix} 1 & \alpha \\ 1 & -\beta \end{pmatrix} \begin{pmatrix} 1 & \alpha \\ 0 & (1-\alpha-\beta)^4 \end{pmatrix} \begin{pmatrix} \frac{\beta}{\alpha+\beta} & \frac{\alpha}{\alpha+\beta} \\ \frac{1}{\alpha+\beta} & -\frac{1}{\alpha+\beta} \end{pmatrix}$$

2.4) Unabhängigkeit von Ereignissen

• Seien A und B zwei Ereignisse und $(\Omega, \mathcal{F}, \mathbb{P})$ den \mathbb{W} -raum.

• A und B sind unabhängig, falls die Information dass A eintritt hat keinen Einfluss auf die \mathbb{W} -keit dass B eintritt, und viceversa.

$$\Rightarrow \mathbb{P}(A|B) = \mathbb{P}(A) \quad \text{falls } \mathbb{P}(B) \neq 0$$

$$\text{und } \mathbb{P}(B|A) = \mathbb{P}(B) \quad \text{falls } \mathbb{P}(A) \neq 0.$$

$$\Rightarrow \mathbb{P}(A \cap B) = \mathbb{P}(A) \cdot \mathbb{P}(B).$$

Def. 12) Sei $(\Omega, \mathcal{F}, \mathbb{P})$ ein \mathbb{W} -raum.

Ⓐ $A, B \in \mathcal{F}$ sind unabhängig (bzgl. \mathbb{P})

falls

$$\mathbb{P}(A \cap B) = \mathbb{P}(A) \cdot \mathbb{P}(B)$$

Ⓑ Eine Familie $A_k, k \in I$, von Ereignissen

heißt unabhängig, falls

$$\mathbb{P}(A_{i_1} \cap \dots \cap A_{i_n}) = \prod_{k=1}^n \mathbb{P}(A_{i_k})$$

$\forall n \leq |I|$ und paarweise verschiedenen $i_1, \dots, i_n \in I$.

Beispiele: a) Falls $\mathbb{P}(A) \in \{0, 1\}$, dann ist A unabhängig von B, $\forall B \in \mathcal{F}$.

In der Tat: Falls $\mathbb{P}(A) = 0$, dann

$$0 \leq \mathbb{P}(A \cap B) \leq \mathbb{P}(A) = 0$$

$$\Rightarrow \mathbb{P}(A \cap B) = 0 = \mathbb{P}(A) \cdot \mathbb{P}(B).$$

Falls $\mathbb{P}(A) = 1$, dann

$$\mathbb{P}(A \cap B) + \underbrace{\mathbb{P}(A^c \cap B)}_{=0} = \mathbb{P}(B) = \mathbb{P}(B) \cdot \mathbb{P}(A).$$

b) Wir werfen 3 mal eine faire Münze.

$\Omega = \{0, 1\}^3$, $\mathbb{P} =$ Gleichverteilung.
↑ ↑
Kopf Zahl

$X_k(\omega) = \omega_k$: k-te Würfel.

Betrachten wir die Ereignisse

$$A_1 = \{X_1 = X_2\}$$

$$A_2 = \{X_2 = X_3\}$$

$$A_3 = \{X_3 = X_1\}$$

Dann, $\mathbb{P}(A_1) = \mathbb{P}(A_2) = \mathbb{P}(A_3) = \frac{4}{8} = \frac{1}{2}$.

Dazu, $\mathbb{P}(A_1 \cap A_2) = \frac{2}{8} = \frac{1}{4} = \mathbb{P}(A_1) \mathbb{P}(A_2)$

(ähnlich mit $(1,2) \rightarrow (2,3)$; $(1,3) \rightarrow (3,1)$).

→ Man sagt, dass A_1, A_2, A_3 sind paarweise unabhängig.

Aber: $\mathbb{P}(A_1 \cap A_2 \cap A_3) = \frac{2}{8} = \frac{1}{4} \neq \mathbb{P}(A_1) \mathbb{P}(A_2) \mathbb{P}(A_3) = \frac{1}{8}$

9. May

(62)

Lemma 13) Seien $A_1, \dots, A_n \in \mathcal{F}$ unabhängig und
 $B_k = A_k$ oder $B_k = A_k^c, \forall k=1, \dots, n$.
 Dann sind B_1, \dots, B_n unabhängig.

Beweis: o.b.d.A., $B_1 = A_1, \dots, B_\ell = A_\ell, B_{\ell+1} = A_{\ell+1}^c, \dots, B_n = A_n^c$.

$$\Rightarrow \mathbb{P}(B_1 \cap \dots \cap B_n) = \mathbb{P}\left(\left(\bigcap_{k=1}^{\ell} A_k\right) \cap \left(\bigcap_{m=\ell+1}^n A_m^c\right)\right)$$

$$= \mathbb{E}\left(\prod_{k=1}^{\ell} \mathbb{1}_{A_k} \cdot \prod_{m=\ell+1}^n (1 - \mathbb{1}_{A_m})\right)$$

$$= \sum_{J \subseteq \{\ell+1, \dots, n\}} (-1)^{|J|} \prod_{j \in J} \mathbb{1}_{A_j}$$

linearität \downarrow

$$= \sum_{J \subseteq \{\ell+1, \dots, n\}} (-1)^{|J|} \mathbb{E}\left(\prod_{k=1}^{\ell} \mathbb{1}_{A_k} \prod_{j \in J} \mathbb{1}_{A_j}\right)$$

unab. Vor A_j 's \downarrow

$$= \prod_{k=1}^{\ell} \mathbb{P}(A_k) \prod_{j \in J} \mathbb{P}(A_j)$$

$$= \prod_{k=1}^{\ell} \mathbb{P}(A_k) \prod_{m=\ell+1}^n (1 - \mathbb{P}(A_m))$$

$\underbrace{\prod_{k=1}^{\ell} \mathbb{P}(A_k)}_{= \mathbb{P}(B_k)} \quad \underbrace{\prod_{m=\ell+1}^n (1 - \mathbb{P}(A_m))}_{= \mathbb{P}(A_m^c) = \mathbb{P}(B_m)}$

$$= \prod_{k=1}^n \mathbb{P}(B_k). \quad \#$$

2.4.1) Verteilung der Wartezeit.

- Seien $A_1, A_2, \dots, A_L \in \mathcal{F}$ unabhängige Ereignisse bzgl. \mathbb{P} mit $\mathbb{P}(A_k) = p \in [0, 1]$.

• Betrachten wir die Zufallsvariable

$$T_L(\omega) = \inf\{n \in \mathbb{N}_{1, \dots, L} \mid \omega \in A_n\}$$

mit $\inf \emptyset := \infty$

$T_L(\omega)$ ist die Wartezeit auf das erste Eintreten der Ereignisse A_1, \dots, A_L .

Was ist die Verteilung von T_L ?

Für $n \leq L$:
$$\mathbb{P}(T_L = n) = \mathbb{P}(A_1^c \cap \dots \cap A_{n-1}^c \cap A_n)$$

$$\begin{aligned} &\stackrel{\text{Leibniz}}{=} \mathbb{P}(A_n) \cdot \prod_{k=1}^{n-1} \mathbb{P}(A_k^c) \\ &= p \cdot (1-p)^{n-1} \end{aligned}$$

und für $n = \infty$: $\mathbb{P}(T_L = \infty) = \mathbb{P}(A_1^c \cap \dots \cap A_L^c) = (1-p)^L$

• Im Limes $L \rightarrow \infty$, sei $T = \lim_{L \rightarrow \infty} T_L$.

Dann

$$\mathbb{P}(T = n) = p(1-p)^{n-1}, \quad n \geq 1$$

Bemerkung: Die Verteilung mit Massenfunktion

$$p(n) = p(1-p)^{n-1}, \quad n \geq 1$$

ist eine geometrische Verteilung zum Parameter p .

Die Verteilung mit Massenfunktion

$$p(n) = (1-p)p^n, \quad n \geq 0$$

heißt ebenfalls geometrische Verteilung zum Parameter p .

⇒ Es gibt zwei "standards".

• $\mathbb{P}(T \geq n) = \mathbb{P}(A_1^c \cap \dots \cap A_{n-1}^c) = (1-p)^{n-1}$

• Was ist den Erwartungswert von T?

$$E(T) \underset{\substack{\uparrow \\ \text{(Siehe \\ \u00c4bungen)}}}{=} \sum_{n \geq 1} P(T \geq n) = \sum_{n \geq 1} (1-p)^{n-1} \underset{\substack{\uparrow \\ \text{geom. \\ Reihe}}}{=} \frac{1}{1-(1-p)} = \frac{1}{p}$$

2.4.2) Verteilung der eingetretenen Ereignisse

• Seien $A_1, \dots, A_n \in \mathcal{F}$ unabhängig mit $P(A_k) = p$ und die Zufallsvariable

$$S(\omega) = |\{1 \leq k \leq n \mid \omega \in A_k\}| = \sum_{k=1}^n \mathbb{1}_{A_k}(\omega),$$

die die Anzahl der eingetretenen Ereignisse z\u00e4hlt.

Dann, $P(S = k) = \binom{n}{k} \cdot p^k (1-p)^{n-k}$.

Das haben wir schon nach Def. 12, Kap 1 gezeigt.

$$P(S_n = k) = \sum_{\substack{I \subseteq \{1, \dots, n\} \\ |I| = k}} P\left(\left(\bigcap_{j \in I} A_j\right) \cap \left(\bigcap_{e \notin I} A_e^c\right)\right)$$

$$\stackrel{\text{Lem. 13}}{=} \sum_{\substack{I \subseteq \{1, \dots, n\} \\ |I| = k}} \prod_{j \in I} P(A_j) \prod_{e \notin I} P(A_e^c)$$

$$= \sum_{\substack{I \subseteq \{1, \dots, n\} \\ |I| = k}} p^k (1-p)^{n-k} = \binom{n}{k} p^k (1-p)^{n-k}$$

• Wir haben schon gesehen, dass $E(S_n) = n \cdot p$.

$$\Rightarrow E\left(\frac{S_n}{n}\right) = p \quad \forall n.$$

Das folgende Satz, gibt uns Informationen \u00fcber die W-keit, dass $\frac{S_n}{n}$ aus p abweicht.

Satz 14) $\forall \varepsilon > 0$ und $n \in \mathbb{N}$ gilt:

$$\mathbb{P}\left(\frac{S_n}{n} \geq p + \varepsilon\right) \leq e^{-2\varepsilon^2 n}$$

und $\mathbb{P}\left(\frac{S_n}{n} \leq p - \varepsilon\right) \leq e^{-2\varepsilon^2 n}$.

Insbesondere gilt:

$$\mathbb{P}\left(\left|\frac{S_n}{n} - p\right| \geq \varepsilon\right) \leq 2 \cdot e^{-2\varepsilon^2 n}$$

Bem.: (a) Die relative Häufigkeit bei n unabhängigen Stichproben ist $\frac{S_n}{n} \approx p$ für grosse n .

Beweis: Setze $q = 1 - p$.

$$\begin{aligned} \forall \lambda > 0: \quad \mathbb{P}(S_n \geq n(p + \varepsilon)) &= \sum_{k \geq n(p + \varepsilon)} \binom{n}{k} p^k q^{n-k} \\ &\leq \sum_{k \geq n(p + \varepsilon)} \binom{n}{k} p^k q^{n-k} \cdot e^{\lambda(k - n(p + \varepsilon))} \\ &\leq \sum_{k=0}^n \binom{n}{k} (pe^\lambda)^k \cdot q^{n-k} \cdot e^{-n(p + \varepsilon)\lambda} \\ &\leq (pe^\lambda + q)(e^{-\lambda p})^n \cdot e^{-n\lambda\varepsilon} \\ &= (pe^{\lambda q} + qe^{-\lambda p})^n \cdot e^{-n\lambda\varepsilon} \end{aligned}$$

Behauptung: $pe^{\lambda q} + qe^{-\lambda p} \leq e^{\frac{\lambda^2}{8}}$ (*)

Mit (*) folgt: $\mathbb{P}(S_n \geq n(p + \varepsilon)) \leq e^{n\left(\frac{\lambda^2}{8} - \lambda\varepsilon\right)}$

Wählen wir nun $\lambda = 4\varepsilon$. Dann,

$$\mathbb{P}(S_n \geq n(p + \varepsilon)) \leq e^{-2n\varepsilon^2}$$

• Für die zweite Ungleichung:

$$\text{Sei } \tilde{S}_n = n - S_n \Rightarrow \tilde{S}_n \sim \text{Bin}(n, q).$$

$$\mathbb{P}(\tilde{S}_n > n(q + \varepsilon)) = \mathbb{P}(S_n < n(p - \varepsilon))$$

$$L \leq e^{-2\varepsilon^2 n}$$

Nach zu zeigen, \otimes .

$$\cdot \text{Sei } f(\lambda) = \ln(pe^{\lambda q} + qe^{-\lambda p})$$

$$\Rightarrow f(\lambda) = -\lambda p + \ln(pe^{\lambda} + q).$$

$$\cdot f(0) = 0 \text{ weil } p+q=1.$$

$$\cdot f'(\lambda) = -p + \frac{pe^{\lambda}}{pe^{\lambda} + q} = -p + \frac{p}{p+qe^{\lambda}} \text{ und } f'(0) = 0$$

$$\cdot f''(\lambda) = \frac{p \cdot q \cdot e^{-\lambda}}{(p+qe^{-\lambda})^2}$$

Wegen

$$\left. \begin{aligned} (a+b)^2 &= a^2 + b^2 + 2ab \\ (a-b)^2 &= a^2 + b^2 - 2ab \geq 0 \end{aligned} \right\} \Rightarrow (a+b)^2 \geq 4ab,$$

$$f''(\lambda) \leq \frac{p \cdot q \cdot e^{-\lambda}}{4p \cdot q \cdot e^{-\lambda}} = \frac{1}{4}.$$

$$\text{Aber: } f(\lambda) = f(0) + \int_0^{\lambda} f'(x) dx$$

$$= \int_0^{\lambda} dx \int_0^x dy f''(y) \leq \int_0^{\lambda} dx \frac{x}{4} = \frac{\lambda^2}{8} \quad \forall \lambda \geq 0.$$

#

Do: Beispiele / "Illustrationen" mit Mathematica.

2.5) Unabhängige ZV und Random Walk.

Def. 15) Seien $X_k: \Omega \rightarrow S_k, k=1, \dots, n$ diskrete ZV auf $(\Omega, \mathcal{F}, \mathbb{P})$.

Die Verteilung μ_{X_1, \dots, X_n} des Zufallsvektor

(X_1, \dots, X_n) heisst gemeinsame Verteilung der ZV X_1, \dots, X_n und hat Massenfunktion

$$P_{X_1, \dots, X_n}(a_1, \dots, a_n) = \mathbb{P}(X_1 = a_1, \dots, X_n = a_n).$$

Def. 16) Die diskreten ZV X_1, \dots, X_n heissen unabhängig, falls gilt:

$$\mathbb{P}(X_1 = a_1, \dots, X_n = a_n) = \prod_{k=1}^n \mathbb{P}(X_k = a_k),$$

$$\forall a_k \in S_k, k=1, \dots, n.$$

Satz 17) Die folgende Aussagen sind äquivalent:

(a) X_1, \dots, X_n sind unabhängig,

(b) $P_{X_1, \dots, X_n}(a_1, \dots, a_n) = \prod_{k=1}^n P_{X_k}(a_k), \forall a_k \in S_k, k=1, \dots, n$

(c) $\mu_{X_1, \dots, X_n} = \bigotimes_{k=1}^n \mu_{X_k}$.

(d) Die Ereignisse $\{X_1 \in A_1\}, \dots, \{X_n \in A_n\}$ sind unabhängig $\forall A_k \subset S_k, k=1, \dots, n$.

(e) Die Ereignisse $\{X_1 = a_1\}, \dots, \{X_n = a_n\}$ sind unabhängig $\forall a_k \in S_k, k=1, \dots, n$.

Beweis: a) ⇔ b): Folgt aus der Def. 15.

b) ⇔ c): Folgt aus der Def. von $\prod_{k=1}^n \mu_{X_k}$.

c) ⇔ d): Seien $1 \leq i_1 < i_2 < \dots < i_m \leq n$

und $A_{i_k} \in \mathcal{S}_{i_k}$, $k=1, \dots, m$.

Setzen wir $A_i = \Omega$ für $i \notin \{i_1, \dots, i_m\}$.

Dann aus c) folgt (zusammen mit Satz 4):

$$\begin{aligned} \mathbb{P}(X_{i_1} \in A_{i_1}, \dots, X_{i_m} \in A_{i_m}) &= \mathbb{P}(X_k \in A_k, k=1, \dots, n) \\ &= \mu_{X_1, \dots, X_n}(A_1 \times \dots \times A_n) \\ &= \prod_{k=1}^n \mu_{X_k}(A_k) = \prod_{k=1}^n \mathbb{P}(X_k \in A_k) \\ &= \prod_{k=1}^m \mathbb{P}(X_{i_k} \in A_{i_k}) \end{aligned}$$

d) ⇒ c) ⇒ a): klar. #

Def. 18) Eine (beliebige) Kollektion $X_k: \Omega \rightarrow \mathcal{S}_k$, $k \in I$, von diskreten ZV heisst unabhängig, falls die Ereignisse

$\{X_k = a_k\}$, $k \in I$, $\forall a_k \in \mathcal{S}_k$, unabhängig sind.

2.5.1) Der Random Walk auf \mathbb{Z} .

Seien X_1, X_2, \dots iid Z.V. auf $(\mathcal{R}, \mathcal{F}, \mathbb{P})$,
mit

$$\begin{cases} \mathbb{P}(X_k = 1) = p \\ \mathbb{P}(X_k = -1) = 1-p \end{cases}, \quad p \in (0, 1).$$

Betrachten wir die MK auf \mathbb{Z} mit

$$\begin{cases} S_0 = a, \quad a \in \mathbb{Z} \text{ fest} \\ S_{n+1} = S_n + X_{n+1}. \end{cases}$$

Dann,
$$S_n = \sum_{k=1}^n X_k + a.$$

(S_0, S_1, \dots) ist ein Random Walk auf \mathbb{Z}

mit $S_n =$ Position zur Zeit n .

Fragen: (1) Rückkehrwahrscheinlichkeit

$$\mathbb{P}(S_n = a) = ?$$

(2) Tritzeitverteilung

Sei $\lambda \in \mathbb{Z}$ und

$$T_\lambda(\omega) = \inf \{n \geq 1 \mid S_n(\omega) = \lambda\}$$

mit $\inf \emptyset = \infty$.

$$\Rightarrow \mathbb{P}(T_\lambda \leq n) = ?$$

• Für $a = \lambda$, T_λ ist die erste Rückkehrzeit.

• Für $a \neq \lambda$, T_λ ist die erste Treffzeit von λ .

(3) Verteilung vom Maximum.

70

$$\cdot \text{Sei } M_n := \max_{0 \leq k \leq n} S_n.$$

$$\Rightarrow \mathbb{P}(M_n \leq \delta) = ?$$

Zuerst berechnen wir die Verteilung von S_n .

Prop. 19) Für $k \in \mathbb{Z}$,

$$\mathbb{P}(S_n = a+k) = \begin{cases} 0, & |k| > n \text{ oder } n+k \text{ ungerade,} \\ \binom{n}{\frac{n+k}{2}} \cdot p^{\frac{n+k}{2}} \cdot (1-p)^{\frac{n-k}{2}}, & \text{sonst.} \end{cases}$$

Beweis: $S_n = a+k \Leftrightarrow X_1 + \dots + X_n = k$

$$\Leftrightarrow \frac{n+k}{2} \text{-mal } X_i = +1$$

$$\text{und } \frac{n-k}{2} \text{-mal } X_i = -1.$$

#

(1) Rückkehrzeit.

$$\cdot \mathbb{P}(S_{2n-1} = a) = 0 \text{ für } n \in \mathbb{N}$$

$$\cdot \mathbb{P}(S_{2n} = a) = \frac{(4p(1-p))^n}{\sqrt{\pi n}} \cdot (1 + o(\frac{1}{n}))$$

für $n \in \mathbb{N}$.

• In der Tat, aus Stirling Formel,

$$n! = \sqrt{2\pi n} \cdot n^n \cdot e^{-n} \cdot (1 + o(\frac{1}{n}))$$

folgt:

$$\begin{aligned}
 \mathbb{P}(S_{2n} = a) &= \binom{2n}{n} p^n (1-p)^n \\
 &= \frac{(2n)!}{(n!)^2} \cdot p^n (1-p)^n \\
 &= \frac{\sqrt{4\pi n} \cdot 2^{2n} \cdot n^{-2n} \cdot e^{-2n}}{(\sqrt{2\pi n} \cdot n^n \cdot e^{-n})^2} \cdot p^n (1-p)^n \left(1 + O\left(\frac{1}{n}\right)\right) \\
 &= \frac{(4p(1-p))^n}{\sqrt{\pi n}} \cdot \left(1 + O\left(\frac{1}{n}\right)\right).
 \end{aligned}$$

Bemerkung: Falls $p \neq \frac{1}{2} \Rightarrow \mathbb{P}(S_{2n} = a) \xrightarrow[n \rightarrow \infty]{} 0$

exponentiell schnell, d.h.;

$$c := \lim_{n \rightarrow \infty} -\frac{\ln(\mathbb{P}(S_{2n} = a))}{n} \in (0, \infty)$$

$$(= -\ln(4p(1-p))).$$

Falls $p = \frac{1}{2} \Rightarrow \mathbb{P}(S_{2n} = a) \approx \frac{1}{\sqrt{\pi n}} \xrightarrow[n \rightarrow \infty]{} 0$

sehr langsam.

2.5.2) Symmetrischer R.W.

$P = \frac{1}{2}$

Wir wollen T_λ berechnen.

Es gilt: $\mathbb{P}(T_\lambda \leq n) = \mathbb{P}\left(\bigcup_{k=1}^n \{S_k = \lambda\}\right)$

\Rightarrow Brauchen wir die gemeinsame Verteilung μ_a , von $S^t(\omega) := (S_0(\omega), S_1(\omega), \dots, S_t(\omega))$.

(72)

Lemma 20) μ_a ist die Gleichverteilung
auf dem Pfadraum

$$\tilde{\mathcal{Z}}_{a,n} := \left\{ (s_0, \dots, s_n) \mid s_0 = a, s_k \in \mathbb{Z} \text{ mit} \right. \\ \left. |s_k - s_{k-1}| = 1, k=1, \dots, n \right\}.$$

Beweis:

$$\begin{aligned} \mu_a((s_0, \dots, s_n)) &= \mathbb{P}(S_0 = s_0, \dots, S_n = s_n) \\ &= \mathbb{P}(S_0 = s_0, X_1 = s_1 - s_0, \dots, X_n = s_n - s_{n-1}) \\ &\stackrel{MK}{=} \delta_{s_0, a} \cdot \prod_{k=1}^n \mathbb{P}(X_k = s_k - s_{k-1}) \\ &= \begin{cases} 0, & \text{für } (s_0, \dots, s_n) \notin \tilde{\mathcal{Z}}_{a,n}, \\ \frac{1}{2^n}, & \text{für } (s_0, \dots, s_n) \in \tilde{\mathcal{Z}}_{a,n}. \quad \# \end{cases} \end{aligned}$$

Die Treffzeit wird mit Hilfe vom
Reflexionsprinzip berechnet:


Satz 21) Seien $\lambda, b \in \mathbb{Z}$ mit $\lambda \neq a$.

(a) Falls $(a < \lambda \text{ und } b \geq \lambda)$ oder $(a > \lambda \text{ und } b \leq \lambda)$

$$\Rightarrow \mathbb{P}(T_\lambda \leq n, S_n = b) = \mathbb{P}(S_n = b)$$

(b) Falls $(a < \lambda \text{ und } b \leq \lambda)$ oder $(a > \lambda \text{ und } b \geq \lambda)$

$$\Rightarrow \mathbb{P}(T_\lambda \leq n, S_n = b) = \mathbb{P}(S_n = 2\lambda - b).$$



Beweis: (a) klar, weil $\{T_\lambda \leq n\} \subseteq \{S_n = b\}$.

(b) Fall $a < \lambda, b \leq \lambda$; der andere ist analog.

$$(*) \mathbb{P}(T_\lambda \leq n, S_n = b) = \frac{\# \text{ Pfade mit } T_\lambda \leq n, S_n = b}{2^n}$$

$$(**) \mathbb{P}(S_n = 2\lambda - b) = \frac{\# \text{ Pfade mit } S_n = 2\lambda - b}{2^n}$$

$(*) = (**)$ falls \exists bijektive ^{zwischen} Pfaden in $(*)$ und in $(**)$.

Sei ω in $(*)$. Definiere

$$\underline{\Phi}: \omega \rightarrow \underline{\Phi}(\omega)$$

$$\text{mit } \begin{cases} (\underline{\Phi}(\omega))_k = \omega_k, & k \leq T_\lambda \\ (\underline{\Phi}(\omega))_k = 2\lambda - \omega_k, & k > T_\lambda. \end{cases}$$

$\underline{\omega} = \underline{\Phi}(\omega)$ ist in $(**)$ und $\underline{\Phi}(\underline{\Phi}(\omega)) = \omega$. #
 $\Rightarrow \underline{\Phi}$ ist eine Bijektion.

• Aus Satz 21, wenn wir über $b \in \mathbb{Z}$ summieren erhalten wir $\mathbb{P}(T_\lambda \leq u)$.

Kor. 22) (a) $\mathbb{P}(T_\lambda \leq u) = \begin{cases} \mathbb{P}(S_u \geq \lambda) + \mathbb{P}(S_u > \lambda), & \lambda > a, \\ \mathbb{P}(S_u \leq \lambda) + \mathbb{P}(S_u < \lambda), & \lambda < a, \end{cases}$

(b) $\mathbb{P}(T_\lambda = u) = \begin{cases} \frac{1}{2} \mathbb{P}(S_{u-1} = \lambda-1) - \frac{1}{2} \mathbb{P}(S_{u-1} = \lambda+1), & \lambda > a, \\ \frac{1}{2} \mathbb{P}(S_{u-1} = \lambda+1) - \frac{1}{2} \mathbb{P}(S_{u-1} = \lambda-1), & \lambda < a. \end{cases}$

Beweis: (für $\lambda > a$).

(a) $\mathbb{P}(T_\lambda \leq u) = \sum_{b \in \mathbb{Z}} \mathbb{P}(T_\lambda \leq u, S_u = b)$

Satz 21
 $= \sum_{b \geq \lambda} \mathbb{P}(S_u = b) + \sum_{b < \lambda} \mathbb{P}(S_u = 2d - b)$
 $= \sum_{b > \lambda} \mathbb{P}(S_u = b)$


σ -add.
 $= \mathbb{P}(S_u \geq \lambda) + \mathbb{P}(S_u > \lambda).$

(b) $\mathbb{P}(T_\lambda = u) = \mathbb{P}(T_\lambda \leq u) - \mathbb{P}(T_\lambda \leq u-1)$

(a) $\mathbb{P}(S_u \geq \lambda) + \mathbb{P}(S_{u-1} > \lambda)$
 $+ \mathbb{P}(S_u > \lambda+1) - \mathbb{P}(S_{u-1} > \lambda+1)$

• Aus $\mathbb{P}(A) - \mathbb{P}(B) = \mathbb{P}(A \setminus B) - \mathbb{P}(B \setminus A)$ folgt:

$$\mathbb{P}(\underbrace{S_n > \lambda}_A) - \mathbb{P}(\underbrace{S_{n-1} > \lambda}_B) =$$



$$\downarrow$$

$$= \mathbb{P}(S_{n-1} = \lambda - 1, S_n = \lambda) - \mathbb{P}(S_{n-1} = \lambda, S_n = \lambda - 1)$$

$$\stackrel{M_k}{=} \mathbb{P}(S_{n-1} = \lambda - 1) \cdot \frac{1}{2} - \mathbb{P}(S_{n-1} = \lambda) \cdot \frac{1}{2}$$

$$\Rightarrow \mathbb{P}(T_\lambda = n) = \frac{1}{2} \left(\mathbb{P}(S_{n-1} = \lambda - 1) - \cancel{\mathbb{P}(S_{n-1} = \lambda)} + \cancel{\mathbb{P}(S_{n-1} = \lambda)} - \mathbb{P}(S_{n-1} = \lambda + 1) \right) \#$$

(3) Maximum.

Kor-23) Sei $M_n := \max_{0 \leq k \leq n} S_k$.

Für $\lambda > a$,
 $\mathbb{P}(M_n > \lambda) = \mathbb{P}(T_\lambda \leq n)$.

Beweis: klar. #


2.6) Simulationsverfahren.

(76)

Def. 24) (a) U ist eine veellwertige ZV, falls
 $\{\omega \in \Omega \mid U(\omega) \leq x\} \in \mathcal{F}, \forall x \in \mathbb{R}$

(b) $U: \Omega \rightarrow \Sigma[0,1]$ ist gleichverteilt auf
 $\Sigma[0,1]$ falls

$$\mathbb{P}(U \leq x) = x, \forall x \in \Sigma[0,1].$$



Notation: $U \sim \text{Unif}(\Sigma[0,1])$ oder $U \sim U(\Sigma[0,1])$


(c) $U_k: \Omega \rightarrow \mathbb{R}, k \in I$, heißen unabhängig
falls $\{U_k \leq x_k\}, k \in I, \forall x_k \in \mathbb{R}$
unabhängig sind.

2.6.1) Direkte Verfahren.

• Sei $S = \{a_1, a_2, \dots\}$ diskret,
 μ eine \mathbb{W} -Verteilung auf S mit Gewichte

$$p_k := \mathbb{P}(a_k)$$

Wegen $\sum_{k=1}^{\infty} p_k = 1$, setzen wir $S_{n+1} = \sum_{k=1}^n p_k, n \geq 1$.
 $S_0 = 0$



Lemma: Sei $U: \Omega \rightarrow [0,1)$, $U \sim \text{Unif}([0,1))$,
 und $X(\omega) := a_n$, falls $s_{n-1} < U(\omega) \leq s_n$,
 $n \geq 1$.
 Dann, $X \sim \mu$.

Beweis: $\forall n \geq 1$,

$$\begin{aligned} \mathbb{P}(X = a_n) &= \mathbb{P}(s_{n-1} < U(\omega) \leq s_n) \\ &= \mathbb{P}(U(\omega) \leq s_n) - \mathbb{P}(U(\omega) \leq s_{n-1}) \\ &= s_n - s_{n-1} = p_n. \quad \neq \end{aligned}$$

Mit Hilfe von Lemma 25:

Algo 26)
Input: p_1, p_2, \dots
Output: X mit $X \sim \mu$.
 $n := 1$;
 $s := p_1$;
 erzeuge $u \sim \text{Unif}([0,1))$
 while $u > s$ do
 $n := n + 1$;
 $s := s + p_n$;
 end while
 return $x := a_n$

Bemerkung: $\mathbb{E}(\# \text{Schritte}) = \sum_{n=1}^{\infty} n \cdot p_n$.

Problem: Falls $|S|$ gross ist,
 kann der Verfahren nicht
 so gut sein (siehe Übungen).

2.6.2) Acceptance-Rejection-Verfahren.

• Sei μ eine W-Vert. mit Massenfunktion p ,
 ν u q
s.d. $\exists c \in [1, \infty)$ mit $\underline{p(x) \leq c \cdot q(x), \forall x \in S}$

$\Rightarrow 0 \leq \frac{p(x)}{c \cdot q(x)} \leq 1, \forall x \in S$

↑ Das wird die "AkzeptanzW-keit".

Ziel: μ Simulieren wenn ν leicht zu simulieren ist.

Algo 27) Input: $p(x), q(x), x \in S, c$.

Output: x mit $x \sim \mu$.

```
repeat
  erzeuge  $x \sim \nu$ ;
  erzeuge  $u \sim \text{Unif}([0,1])$ ;
until  $\left( \frac{p(x)}{c \cdot q(x)} \geq u \right)$  (d.h., Akzeptiere den Vorschlag mit W-keit  $\frac{p(x)}{c \cdot q(x)}$ ).
return  $x$ ;
```

zu zeigen: Algo funktioniert und ist "schnell".

• Seien $X_1, X_2, \dots \sim \nu$ die Vorschläge,
 $U_1, U_2, \dots \sim \text{Unif}([0,1])$;

Setze $T := \min \{n \geq 1 \mid \frac{p(X_n)}{c \cdot q(X_n)} \geq U_n\}$ und
 $X_T(\omega) = X_{T(\omega)}(\omega)$.

Satz 25)

(a) $X_T \sim \mu$

(b) $T \sim \text{geom}(1/c)$:

$$P(T=u) = \frac{1}{c-1} \left(1 - \frac{1}{c}\right)^{u-1}, u \geq 1$$

$$\Rightarrow E(T) = c.$$

Beweis: (b) Wegen unabh. von X_1, X_2, \dots und U_1, U_2, \dots

sind $A_n := \left\{ \frac{P(X_u)}{c \cdot q(X_u)} \geq U_u \right\}$

unabhängig für verschiedene n .

$$P(T=u) = P(A_1^c \cap \dots \cap A_{u-1}^c \cap A_u).$$

\Rightarrow Berechnen wir $P(A_u)$:

$$P(A_u) = \sum_{a \in S}^{s\text{-add.}} P\left(\left\{U_u \leq \frac{P(a)}{c \cdot q(a)}\right\} \cap \{X_u = a\}\right)$$

$$= \sum_{a \in S}^{unabh.} P\left(U_u \leq \frac{P(a)}{c \cdot q(a)}\right) \cdot \underbrace{P(X_u = a)}_{= q(a)}$$

$$= \frac{P(a)}{c \cdot q(a)} \text{ weil}$$

$$0 \leq \frac{P(a)}{c \cdot q(a)} \leq 1$$

$$= \sum_{a \in S} \frac{P(a)}{c \cdot q(a)} \cdot q(a) = \frac{1}{c}.$$

$$\Rightarrow P(T=u) \stackrel{unabh.}{=} \left(1 - \frac{1}{c}\right)^{u-1} \cdot \frac{1}{c} = \frac{1}{c-1} \cdot \left(1 - \frac{1}{c}\right)^{u-1}, u \geq 1.$$

$$\textcircled{a} P(X_T = a) = \sum_{u \geq 1} P(X_T = a, T = u)$$

$$= \sum_{u \geq 1} P(A_1^c \cap \dots \cap A_{u-1}^c \cap \{X_T = a \cap A_u\})$$

$$= \sum_{u \geq 1} \left(1 - \frac{1}{c}\right)^{u-1} \cdot \frac{q(a) \cdot P(a)}{c \cdot q(a)} = P(a). \quad \#$$