

3) Konvergenzsätze und Monte Carlo Methoden.

3.1) Kovarianz.

- Wir haben schon die Varianz definiert.
Sei $(\Omega, \mathcal{F}, \mathbb{P})$ ein W-Raum und $X: \Omega \rightarrow \mathbb{R}$
eine diskrete reelle Z.V.

Def. 1) Falls $\mathbb{E}(X^2) < \infty$, dann

$$\text{Var}(X) := \mathbb{E}((X - \mathbb{E}(X))^2) \in [0, \infty)$$

ist die Varianz und

$$\sigma(X) := \sqrt{\text{Var}(X)}$$

ist die Standardabweichung von X .

Eigenschaften: • $\text{Var}(X + a) = \text{Var}(X)$, $\forall a \in \mathbb{R}$
fest.

$$\bullet \text{Var}(\lambda X) = \lambda^2 \text{Var}(X)$$

• Falls X_1, \dots, X_n unabhängig sind,
dann $\text{Var}(X_1 + \dots + X_n) = \text{Var}(X_1) + \dots + \text{Var}(X_n)$.

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

$$\bullet \text{Var}(X) = 0 \Leftrightarrow \mathbb{P}(X = \mathbb{E}(X)) = 1$$

Def. 2) (Kovarianz)

① Seien X, Y mit $\mathbb{E}(X^2) < \infty$, $\mathbb{E}(Y^2) < \infty$.

Dann

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

heißt die Kovarianz von X und Y .

(b) Falls $\sigma(X), \sigma(Y) \neq 0$, dann

$$\rho(X, Y) := \frac{\text{Cov}(X, Y)}{\sigma(X)\sigma(Y)}$$

heißt der Korrelationskoeffizient von X und Y.

(c) X und Y heißen unkorreliert, falls $\text{Cov}(X, Y) = 0$.

18. Mai

Bemerkung: (a) $|\rho(X, Y)| \leq 1$. (Siehe Übungen).

(b) $\text{Cov}(X, X) = \text{Var}(X)$

(c) Unabhängigkeit \Rightarrow Unkorreliertheit
 \Leftarrow

In der Tat:
$$\mathbb{E}(X \cdot Y) = \sum_{\substack{x \in S_1 \\ y \in S_2}} x \cdot y \mathbb{P}(X=x, Y=y)$$

$$\stackrel{X, Y \text{ unabh.}}{\downarrow} \sum_{x \in S_1} x \cdot \mathbb{P}(X=x) \sum_{y \in S_2} y \mathbb{P}(Y=y)$$

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

Andererseits: Sei $X = +1, 0, -1$ mit jeweils \mathbb{P} -Wert $\frac{1}{3}$, und $Y := X^2$.

$$\Rightarrow \mathbb{E}(X \cdot Y) = \mathbb{E}(X^3) = 0 \quad (\text{wegen Antisymmetrie})$$

und $\mathbb{E}(X) \mathbb{E}(Y) = 0$ (weil $\mathbb{E}(X) = 0$).

Aber,
$$\mathbb{P}(X \in \{-1, 1\}, Y=1) = \frac{2}{3} \neq \mathbb{P}(X \in \{-1, 1\}) \cdot \mathbb{P}(Y=1) = \frac{4}{9}.$$

(b) Falls $\mathbb{E}(X^2) < \infty$ und $\mathbb{E}(Y^2) < \infty$, dann

aus Cauchy-Schwarz: $\mathbb{E}(|X|) < \infty, \mathbb{E}(|Y|) < \infty$ und $\mathbb{E}(|X \cdot Y|) < \infty \Rightarrow \text{Cov}(X, Y)$ ist wohldefiniert.

Def 3) $\mathcal{L}^2(\Omega, \mathcal{F}, \mathbb{P}) := \{X: \Omega \rightarrow \mathbb{R} \mid \mathbb{E}(X^2) < \infty\}$.

Leim. 4) (a) Falls $X, Y \in \mathcal{L}^2$, $\mathbb{E}(X \cdot Y) \leq \sqrt{\mathbb{E}(X^2)} \sqrt{\mathbb{E}(Y^2)}$

(b) \mathcal{L}^2 ist ein Vektorraum mit

$$(X, Y)_{\mathcal{L}^2} := \mathbb{E}(X \cdot Y)$$

ein Skalarprodukt auf \mathcal{L}^2 .

(ohne Beweis \rightarrow siehe Skript).

Jetzt untersuchen wir den Zusammenhang zwischen Unabhängigkeit und Unkorreliertheit.

Satz 3) Seien $X: \Omega \rightarrow S \subset \mathbb{R}$, $Y: \Omega \rightarrow T \subset \mathbb{R}$ (diskrete) ZV. auf $(\Omega, \mathcal{F}, \mathbb{P})$. Dann haben wir zwei äquivalente Aussagen:

(a) X und Y sind unabhängig

$$\text{(d.h. } \mathbb{P}(X \in A, Y \in B) = \mathbb{P}(X \in A) \mathbb{P}(Y \in B), \\ \forall A, B \in \mathcal{F} \text{)}$$

(b) $f(X)$ und $g(Y)$ sind unkorreliert für alle Funktionen $f: S \rightarrow \mathbb{R}$, $g: T \rightarrow \mathbb{R}$ mit $f(X), g(Y) \in \mathcal{L}^2$.

Beweis: (a) \Rightarrow (b): Trivial: $\mathbb{E}(f(X)g(Y)) =$

$$= \sum_{a \in S} \sum_{b \in T} f(a)g(b) \mathbb{P}(X=a, Y=b)$$

$$\stackrel{\text{lin. ab.}}{=} \sum_{a \in S} f(a) \mathbb{P}(X=a) \sum_{b \in T} g(b) \mathbb{P}(Y=b) = \mathbb{E}(f(X)) \mathbb{E}(g(Y)).$$

(b) \Rightarrow (a): $\forall a \in S, b \in T,$

(83)

$$\mathbb{P}(X=a, Y=b) = \mathbb{E}(\mathbb{1}_{\{a\}}(X) \mathbb{1}_{\{b\}}(Y))$$

$$\stackrel{\text{unkor.}}{=} \mathbb{E}(\mathbb{1}_{\{a\}}(X)) \mathbb{E}(\mathbb{1}_{\{b\}}(Y))$$

$$= \mathbb{P}(X=a) \mathbb{P}(Y=b).$$

#

• Die Kovarianz spielt eine Rolle in die Summe von Z.V.

Satz 4) Seien $X_1, \dots, X_n \in \mathcal{Y}^2$. Dann,

$$\text{Var}(X_1 + \dots + X_n) = \sum_{k=1}^n \text{Var}(X_k) + 2 \sum_{1 \leq k < l \leq n} \text{Cov}(X_k, X_l)$$

Beweis: Die Kovarianz ist bilinear und $\text{Var}(Y) = \text{Cov}(Y, Y)$.

$$\text{So, } \text{Var}(X_1 + \dots + X_n) = \text{Cov}\left(\sum_{k=1}^n X_k, \sum_{e=1}^n X_e\right)$$

$$= \sum_{k,e=1}^n \text{Cov}(X_k, X_e) = \sum_{k=1}^n \text{Var}(X_k) + 2 \sum_{k < e} \text{Cov}(X_k, X_e).$$

#

3.2) Gesetze der grossen Zahlen.

• Falls wir unabhängige Versuche X_1, X_2, \dots mit $X_k \sim \mu, \forall k \geq 1$, dann ist

$$m_n = \frac{1}{n} \sum_{k=1}^n X_k,$$

das arithmetische Mittelwert von X_1, \dots, X_n

nicht so weit von $\mathbb{E}(m_n)$.

• Falls aber X_1, X_2, \dots sind 100% korreliert, d.h.,

$$X_1 = X_2 = \dots = X_n, \text{ dann } m_n \neq \mathbb{E}(m_n).$$

• Warum ist $m_n = \mathbb{E}(m_n)$?

Satz 5) (Schwaches Gesetz der grossen Zahlen).

• Seien $X_1, X_2, \dots, X_n \in \mathcal{L}^2(\mathcal{R}, \mathcal{F}, \mathbb{P})$, mit

- (a) $\text{Cov}(X_k, X_\ell) = 0, \forall k \neq \ell$, (Unabhängigkeit ist nicht vorausgesetzt)
- (b) $\sigma := \sup_{k \in \mathbb{N}} \text{Var}(X_k) < \infty$.

• Sei $S_n := X_1 + \dots + X_n$. Dann, $\forall \varepsilon > 0$,

$$\lim_{n \rightarrow \infty} \mathbb{P}\left(\left|\frac{S_n}{n} - \frac{\mathbb{E}(S_n)}{n}\right| \geq \varepsilon\right) \leq \frac{\sigma}{\varepsilon^2 n} \xrightarrow{n \rightarrow \infty} 0$$

Bem.: • Falls (dazu) $\mathbb{E}(X_k) = m \forall k \geq 1, \mathbb{E}(S_n) = m$
 und man sagt, dass $\frac{S_n}{n}$ Konvergiert
Stochastisch gegen m , d.h.,

$$\lim_{n \rightarrow \infty} \mathbb{P}\left(\left|\frac{S_n}{n} - m\right| \geq \varepsilon\right) = 0, \forall \varepsilon > 0.$$

• Zum Beweis benötigen wir die Tchebischev-Ungleichung.

Lemma 6) Sei $X \in \mathcal{L}^2$ und $a > 0$. Dann,

$$\mathbb{P}(|X - \mathbb{E}(X)| \geq a) \leq \frac{\text{Var}(X)}{a^2}.$$

Beweis: $\mathbb{P}(|X - \mathbb{E}(X)| \geq a) = \mathbb{E}\left(\mathbb{1}_{\{|X - \mathbb{E}(X)| \geq a\}}\right).$

• Aber $\mathbb{1}_{\{|X - \mathbb{E}(X)| \geq a\}} \cdot \frac{a^2}{a^2} \leq \frac{|X - \mathbb{E}(X)|^2}{a^2}$

$$\Rightarrow \mathbb{P}(|X - \mathbb{E}(X)| \geq a) \leq \mathbb{E}\left(\frac{|X - \mathbb{E}(X)|^2}{a^2}\right) = \frac{\text{Var}(X)}{a^2} \quad \#$$

Beweis von Satz 5) Sei $\varepsilon > 0$. Dann,

$$\begin{aligned} \mathbb{P}\left(\left|\frac{S_n}{n} - \mathbb{E}\left(\frac{S_n}{n}\right)\right| \geq \varepsilon\right) &\leq \\ &\leq \frac{\text{Var}\left(\frac{S_n}{n}\right)}{\varepsilon^2} \stackrel{\text{Lemab}}{=} \frac{1}{\varepsilon^2 n^2} \text{Var}\left(\sum_{k=1}^n X_k\right) \\ &\stackrel{\text{a)}}{\leq} \frac{n \cdot \sigma^2}{n^2 \varepsilon^2} = \frac{\sigma^2}{n \varepsilon^2} \quad \# \end{aligned}$$

Es gibt noch zwei wichtige Ungleichungen, die wir der Vollständigkeit halber geben.

Markov Ungleichung: Falls $\mathbb{E}(X)$ existiert, $\forall a > 0$,

$$\mathbb{P}(|X| \geq a) \leq \frac{\mathbb{E}(|X|)}{a}$$

Jensen Ungleichung: Sei $\varphi: \mathbb{R} \rightarrow \mathbb{R}$ konvex, dann
 falls $\mathbb{E}(|X|) < \infty$ und $\mathbb{E}(\varphi(X)) < \infty$, dann

$$\varphi(\mathbb{E}(X)) \leq \mathbb{E}(\varphi(X)).$$

Bem.: Statt $\text{Cov}(X_k, X_l) = 0$ für $k \neq l$, kann man die Bedingung schwächer (z.B., $|\text{Cov}(X_k, X_l)| \leq f(|k-l|)$ mit $f(x) \xrightarrow{x \rightarrow \infty} 0$) ersetzen.

3.3) Monte-Carlo Verfahren.

Ziel: Wir wollen unabhängige, identische verteilte Versuche benutzen um

$$\theta := \mathbb{E}_\mu(\varphi) = \sum_{x \in S'} \varphi(x) \mu(x)$$

zu approximieren. Für $\varphi(x) = x$, Satz 5 sagt uns, dass wenn $X_1, X_2, \dots, X_n \sim \mu$, dann

$$\mathbb{E}_\mu(x) = \mathbb{E}(X) \approx \frac{1}{n} \sum_{k=1}^n X_k.$$

• Sei S' abzählbar, μ eine W-Verteilung auf S' .

Notation: $\mu(x) := \mu(\{x\})$.

• Sei $\varphi: S' \rightarrow \mathbb{R}$ mit

$$\mathbb{E}_\mu(\varphi^2) = \sum_{x \in S'} \varphi(x)^2 \mu(x) < \infty.$$

• Ein Schätzer von θ ist, nach Satz 5,

$$\hat{\theta}_n = \frac{1}{n} \sum_{k=1}^n \varphi(X_k)$$

wobei X_1, X_2, \dots, X_n sind unabhängige Z.V.

Lemma 7) $\forall \varepsilon > 0 \quad \mathbb{P}(|\hat{\theta}_n - \theta| \geq \varepsilon) \leq \frac{\text{Var}_\mu(\varphi^2)}{n \varepsilon^2} \xrightarrow{n \rightarrow \infty} 0$

Bem.: Eine Folge von Schätzern $\hat{\theta}_n$ (mit der Eigenschaft $\lim_{n \rightarrow \infty} \mathbb{P}(|\hat{\theta}_n - \theta| \geq \varepsilon) = 0, \forall \varepsilon > 0$), heißt Konsistent.

Beweis: X_k unabh. $\Rightarrow f(x_k)$ sind unkorreliert.
Satz 3

$$\mathbb{E}(f(X_k)) = \sum_{x \in S} f(x) \mu(x) = \mathbb{E}_\mu(f) = \theta, \quad \forall k$$

$$\text{und } \text{Var}(f(X_k)) = \sum_{x \in S} (f(x) - \theta)^2 \mu(x) = \text{Var}_\mu(f) < \infty.$$

\Rightarrow Folgt aus Satz 5. $(X_k \rightarrow f(X_k))$
#

Bem.: $\hat{\theta}_n$ ist ^{ein} erwartungstreu Schätzer für θ ,
falls $\mathbb{E}(\hat{\theta}_n) = \theta$.

Das mittlere quadratische Fehler
von $\hat{\theta}_n$, definiert als

$$\mathbb{E}((\hat{\theta}_n - \theta)^2) = \frac{1}{n} \text{Var}_\mu(f).$$

$$\Rightarrow \|\hat{\theta}_n - \theta\|_{L^2} = \sqrt{\mathbb{E}((\hat{\theta}_n - \theta)^2)} = O\left(\frac{1}{\sqrt{n}}\right).$$

MC nützlich, wenn wir μ nicht explizit kennen wissen.

23. Mai

Beispiel: (1) Monte-Carlo-Schätzung von $\theta = \int_0^1 f(x) dx$

Seien $u_1, u_2, \dots, u_n \in [0, 1)$ Pseudozahlen
mit $u_k \sim \text{Unif}([0, 1))$.

$$\text{Dann } \hat{\theta}_n = \frac{1}{n} \sum_{k=1}^n f(u_k)$$

ist ein konsistent Schätzer für $\theta = \int_0^1 f(x) dx$,

$$\text{und } \sqrt{\mathbb{E}((\hat{\theta}_n - \theta)^2)} = O(1/n).$$

(2) Schätzung von W-Keiten.

• Sei \mathcal{S} diskret und $B \subseteq \mathcal{S}$.

Gesucht ist $p := \mu(B)$ (unbekannt).

Da $\mu(B) = E_{\mu}(\mathbb{1}_B)$, ein MC Schätzer von p

ist
$$\hat{p}_n := \frac{1}{n} \sum_{k=1}^n \mathbb{1}_B(X_k)$$

mit $X_k \sim \mu$ unabhängig.

• Wie gut ist die Schätzung von p ?

Tchebischew:

$$\begin{aligned} \mathbb{P}(|\hat{p}_n - p| \geq \varepsilon) &\leq \frac{1}{\varepsilon^2} \text{Var}(\hat{p}_n) \\ &= \frac{1}{n \varepsilon^2} \text{Var}_{\mu}(\mathbb{1}_B) = \frac{p(1-p)}{n \varepsilon^2} \leq \frac{1}{4n \varepsilon^2}. \end{aligned}$$

3.3.1) Varianzreduktion durch Importance Sampling.

Idee: Wenn wir weniger Punkte (Samples), wo $f(x)$ klein ist, nehmen, wird die Varianz kleiner.

• Sei μ die W-keit auf \mathcal{S} , $f: \mathcal{S} \rightarrow \mathbb{R}$ s.d.

$$E_{\mu}(f^2) = \sum_{x \in \mathcal{S}} f^2(x) \mu(x) < \infty.$$

• Sei ν eine weitere W-keit auf \mathcal{S} mit

$$\nu(x) = \nu(\{x\}) > 0, \forall x \in \mathcal{S}.$$

Dann, haben wir:

$$\begin{aligned}\theta &:= \mathbb{E}_{\mu}(f) = \sum_{x \in S} f(x) \mu(x) \\ &= \sum_{x \in S} f(x) \frac{\mu(x)}{\nu(x)} \cdot \nu(x) = \mathbb{E}_{\nu}(f \cdot g)\end{aligned}$$

Wobei: $g(x) = \frac{\mu(x)}{\nu(x)}$.

Dann, kann man statt

$$\hat{\theta}_n = \frac{1}{n} \sum_{k=1}^n f(X_k), \quad X_k \sim \mu,$$

den Schätzer $\tilde{\theta}_n := \frac{1}{n} \sum_{k=1}^n f(Y_k) g(Y_k), \quad Y_k \sim \nu.$

$\mathbb{E}_{\nu}(\tilde{\theta}_n) = \mathbb{E}_{\nu}(f \cdot g) = \theta$; $\mathbb{E}_{\mu}(\hat{\theta}_n) = \theta$: Beide Erwartungstreue.

$$\left\{ \begin{aligned} \text{Var}_{\nu}(\tilde{\theta}_n) &= \frac{1}{n} \text{Var}_{\nu}(f \cdot g) = \frac{1}{n} \left(\sum_{x \in S} f^2(x) g^2(x) \nu(x) - \theta^2 \right) \\ \text{Var}_{\mu}(\hat{\theta}_n) &= \frac{1}{n} \left(\sum_{x \in S} f^2(x) \mu(x) - \theta^2 \right) \end{aligned} \right.$$

• Ziel: Wahl von ν s.d. $\text{Var}_{\nu}(\tilde{\theta}_n) \ll \text{Var}_{\mu}(\hat{\theta}_n).$

Da $\sum_{x \in S} f^2(x) g^2(x) \nu(x) = \sum_{x \in S} f^2(x) \mu(x) \frac{\mu(x)}{\nu(x)}$

wird man $\nu(x)$ gross wählen für $f(x)$ gross.

Beispiel: Siehe Skript / Übung.

3.4) Gleichgewichte von Markovketten

• Die Übergangsmatrizen einer MK sind stochastische Matrizen (siehe Kap 2).

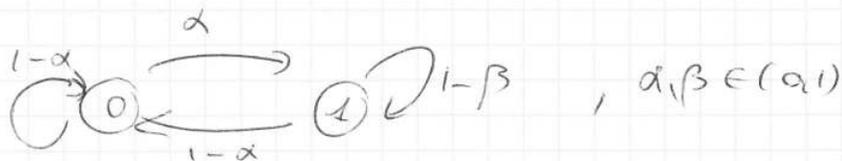
Def. 8) Eine MK heisst homogen (zeitlich homogen) falls die Übergangsmatrizen $P_k, k \geq 1$, sind unabhängig von der Zeit k , d.h., $P_k = P, \forall k \geq 1$.

• Wir haben schon gesehen wie erhält man die Verteilung μ_n zur Zeit n , falls die Verteilung zur Zeit $t=0$ ist μ_0 :

$$\mu_n = \mu_0 P^n$$

(siehe Kap 2, Satz 10).

• Im Beispiel



haben wir gesehen, dass $\lim_{n \rightarrow \infty} \mu_0 P^n = \left(\frac{\beta}{\alpha+\beta}, \frac{\alpha}{\alpha+\beta} \right)$ unabhängig von μ_0 .

• Falls $\mu_\infty = \lim_{n \rightarrow \infty} \mu_n$ existiert, dann $\mu_{n+1} \approx \mu_n$ für $n \gg 1$

$$\mu_{n+1} = \mu_n P \Rightarrow \underline{\mu_\infty = \mu_\infty \cdot P}$$

• μ_∞ ist eine stationäre Verteilung, weil nicht mehr ^{sie entwickelt}

Def. 9) @ Stationäre Verteilung:

• Eine W -Verteilung μ auf S^1 heisst stationäre ^{eine}

~~Verteilung~~ Verteilung einer MK mit Übergangsmatrix P falls $\mu = \mu P$.

(b) Detailed-Balance

- μ erfüllt die Detailed-Balance Bedingung bzgl. P falls

$$\mu(x)P(x,y) = \mu(y)P(y,x), \quad \forall x,y \in S.$$

↳ Das ist die lokale Gleichgewichtsbedingung, d.h., den Flux von "Mass" (W-mass) zwischen jede 2 Zustände ist neutral (Null).

Satz 10) Detailed Balance von μ erfüllt $\Rightarrow \mu$ ist stationär.

Beweis: Zu zeigen: $\mu P = \mu$.

$$(\mu P)(x) = \sum_{y \in S} \mu(y)P(y,x) \stackrel{\text{Det. Bal.}}{=} \sum_{y \in S} \mu(x)P(x,y) \\ \stackrel{P \text{ stoch.}}{=} \mu(x). \quad \#$$

Bem: μ stationär $\not\Rightarrow \mu$ erfüllt Detailed Balance.

Beispiel:



Wegen Translationsinvarianz ist es klar, dass

$$\mu = \left(\frac{1}{3}, \frac{1}{3}, \frac{1}{3}\right) \text{ ist stationär.}$$

Aber, $\mu(1)P(1,2) = \frac{1}{3} \cdot p \neq \frac{1}{3} \cdot q = \mu(2)P(2,1)$

für alle $p \neq \frac{1}{2}$.

Weitere Beispiele: Siehe Eberle's Skript.

(insbesondere, Beispiel d: Random Walks auf Graphen)

• Der Rest dieses Kapitel ist nicht handgeschrieben:

Siehe Seiten 87 bis 96 von Eberle's Skript.

Die wichtige Inhalte sind:

Kap 3.4 } → Metropolis-Algorithmus
 { → Gibbs-Sampler

Kap 3.5 { → Konvergenz ins Gleichgewicht (Satz 3.16)