





Mitschrift

Wahrscheinlichkeit

WS 2019



Vorbesprechung



GRILL 58801/10572

Zeiten:

Prüfung:

Sprechstunde: Mittwoch 13-14

Mittwoch 10⁰⁰ - 12⁰⁰ bzw

schriftlich & mündlich
praktisch - theoretisch

Freitag 10-11

Freitag 8⁰⁰ - 10⁰⁰

DA06B1R

UE im 5.Sem

4 BSP / nicht 1 pro Kapitel !

https://institute.tuwien.ac.at/mstech/mitarbeiterinnen/professoren/grill/karl_grill_1/

Inhalte & Übersicht

- 1) Kapitel → Wahrscheinlichkeit
- 2) Kapitel → Stochastische Prozesse
- 3) Kapitel → Informationstheorie (je unwar. desto größer Informationswert)
- 4) Kapitel → Statistik (WSLK umgedreht, Bedeutung IRL)

Ab Jänner EIX 8-11¹⁵ (nur noch Freitags!)

Wahrscheinlichkeitstheorie

Empirisches Gesetz der großen Zahlen:

Ein "zufälliges" Experiment wird sehr oft wiederholt.

zB: faire Münze (Kopf, Zahl), Würfel (1, ..., 6), Urne (Kugeln verschiedenfarbig, zahlen)

$$\frac{1}{2}$$

$$\frac{1}{6}$$

...

Die relativen Häufigkeiten "konvergieren" gegen "Wahrscheinlichkeit" Physikalisches Gesetz

Wahrscheinlichkeiten sind etwas, mit dem man rechnet wie mit (relativen) Häufigkeiten.

BSP Würfel Ausgänge 1...6 als Elementarereignis

Elementarereignisse (ω) werden zusammengefasst zur Grundmenge $\Omega = \{1, \dots, 6\}$ Würfel ↗

$\omega \in \Omega$ heißt Elementarereignis

bestimmte (komplexere) Ereignisse definieren : Augenzahl ist gerade / [Augenzahl ist 2, 4, 6] $\in \{2, 4, 6\}$

Augenzahl ist mindestens 4 [4, 5, 6] $\in \{4, 5, 6\}$

Ein Ereignis ist eine Teilmenge von Grundmenge $A \subseteq \Omega$

Elementarereignis \neq Ereignis

ω (Zahl) \neq Menge ↴

Wahrscheinlichkeit = Wahrscheinlichkeitsmaß (\approx Wahrscheinlichkeitsfunktion) ist eine Funktion, die in Ereignissen (= Teilmengen der Grundmenge Ω) Zahlenwerte zuordnet

Eigenschaften (Axiome von Kolmogorov)

1) $0 \leq P(A) \leq 1$ WSKL liegt immer zw 0 und 1

2) $P(\emptyset) = 0$, $P(\Omega) = 1$ \emptyset ... unmögliches Ereignis
 Ω ... sicheres Ereignis

Additivität $\left\{ \begin{array}{l} \rightarrow P(A \cup B) = P(A) + P(B) \quad \text{Wahrscheinlichkeiten addierbar wenn } A \overset{\text{Disjunkt}}{\wedge} B = \emptyset \\ P(A_1 \cup A_2 \cup \dots \cup A_n) = P(A_1) + P(A_2) + \dots + P(A_n) \quad \text{wenn } A_1 \dots A_n \text{ disjunkt sind.} \end{array} \right.$

Abschließbar / Sigma Additivität $\rightarrow P(\bigcup_{n \in \mathbb{N}} A_n) = \sum_{n \in \mathbb{N}} P(A_n) \quad \rightarrow A_i \wedge A_j = \emptyset \quad \forall i, j \quad i \neq j \quad 1 \leq i, j \leq n$

BSP fairer Würfel

- $\Omega = \{1 \dots 6\}$ mögliche Versuche Ereignisse: Alle Körper die aus 1-6 geformt werden - 64 Stück
- Alle Elementarereignisse sollen gleiche Wahrscheinlichkeit haben: $\frac{1}{6}$
- $P(\Omega) = P(\{1, 2, 3, 4, 5, 6\}) = P(\{1\} \cup \{2\} \cup \dots \cup \{6\}) = P(\{1\}) + \dots + P(\{6\})$

BSP unfairer Würfel: $P(\{6\}) = 0.5$
 $P(\{1\}) = \dots = P(\{5\}) = 0.1$

BSP Münze wird geworfen bis Kopf rauskommt

Girll
 "Türken haben sieben Söhne!"

•) $\Omega = \{1, 2, 3, \dots\}$ ^{Versuch} Möglichkeiten bis Kopf kommt (Grundmenge ist ∞)

•) $P(\{1\}) = \frac{1}{2}$

$P(\{2\}) = \frac{1}{4}$



$P(\{n\}) = \frac{1}{2^n}$

BSP zufälliger Zeitpunkt

zwischen 7 und 8 : wie ist die Wahrscheinlichkeit für eintreffen zwischen 7¹⁵ und 7³⁰

7:00 und 8:00 \rightarrow 60 Möglichkeiten

günstig 7:15:00 bis 7:30:00

$\Omega = [0, 1]$

Zeit in Sekunden 7:00:00 - 8:00:00 \rightarrow 3601

$P(A) = \frac{18}{61}$

7:15:00 - 7:00:00 \rightarrow 901

$P(A) = \frac{90}{3601}$

$P([a, b]) = b - a$

Wahrscheinlichkeit = Länge d. Intervalls


Zeit in hundertstel Sekunden $P(A) \sim \frac{90001}{360001}$

\rightarrow im Grenzwert $P(A) = \frac{1}{4}$

Albert kommt zufällig zwischen 7 und 8. Bettina auch. Jeder bleibt 10 min. Wie groß ist die Wahrscheinlichkeit, dass sie sich treffen?

Ankunftszeiten voneinander unabhängig.

$P(\text{treffen})$



Wsk ist Anteil an Gesamtfläche

$P(\text{treffen}) = \frac{\text{Fläche } \square}{\text{Fläche } \square} = \frac{3600 - 2500}{3600} = \frac{11}{36}$

Folgerungen (zusätzliche Eigenschaften)

$\rightarrow P(A^c) = 1 - P(A)$ weil $A \cap A^c = \emptyset$ $A \cup A^c = \Omega$
 $1 = P(\Omega) = P(A \cup A^c) = P(A) + P(A^c)$

$\rightarrow A \subseteq B \quad P(B \setminus A) = P(B) - P(A)$

$\rightarrow P(B \setminus A) = P(B \setminus (A \cap B))$
nur die Elemente weg, die auch in B liegen!
 $= P(B) - P(A \cap B)$


\rightarrow Additionstheorem: $P(A \cup B) = P(A \cup (B \setminus A)) =$
2 WSK
 $= P(A) + P(B \setminus A) =$
 $= P(A) + P(B) - P(A \cap B)$

3 WSK: $P(A \cup B \cup C) = \dots = P(A) + P(B) + P(C) - P(A \cap C) - P(B \cap C) - P(A \cap B) + P(A \cap B \cap C)$

n WSK: $2^n - 1$ Summanden

allgemeiner Fall $P(A_1 \cup \dots \cup A_n) = \sum_{k=1}^n (-1)^{k-1} \cdot S_k$ Siebformel

$S_k = \sum_{1 \leq i_1 < \dots < i_k} P(A_{i_1} \cap \dots \cap A_{i_k}) \Rightarrow P(\cup_{i=1}^n A_i) = \sum_{\substack{S \subseteq \{1, \dots, n\} \\ S \neq \emptyset}} (-1)^{|S|-1} P(\bigcap_{i \in S} A_i)$



BSP zufällige Vertauschung von n Elementen

$P(\text{kein Fixpunkt})$ WSK wenn die wählt kein FP
 Alle Permutationen die keinen FP hat!

$A_1, \dots, A_n: A_i = \text{FP}$

$S_1 - S_2 + S_3 - \dots \pm S_n$ letztes Glied Sieb

$P(\text{kein FP}) = 1 - P(\text{FP}) = 1 - P(\cup A_n) = 1 - (P(A_1) + \dots + P(A_n) - P(A_1 \cap A_2) - \dots + \dots)$

k facher Durchschnitt: $S_k = \frac{1}{k!}$

$S_1: P(A_1) = \frac{(n-1)!}{n!} = P(A_2) = \dots = P(A_n) \Rightarrow S_1 = n \cdot \frac{(n-1)!}{n!} = 1$

$S_2: P(A_1 \cap A_2) = \frac{(n-2)!}{n!} = P(A_1 \cap A_3) = \dots = P(A_1 \cap A_n) \Rightarrow S_2 = \binom{n}{2} \frac{(n-2)!}{n!} = \frac{1}{2!}$

$S_n: P(A_1 \cap \dots \cap A_n) = 1 - \frac{1}{2!} + \frac{1}{3!} - \dots + (-1)^{(n-1)} \frac{1}{n!}$

$P(\text{kein FP}) = \frac{0!}{1!} - \frac{1!}{1!} + \frac{1!}{2!} - \frac{1!}{3!} + \dots + (-1)^n \frac{1}{n!}$
 $= \sum_{k=0}^n (-1)^k \frac{1}{k!} \times \frac{1}{e}$ Taylorreihe Entwicklung

$\rightarrow A \subseteq B \Rightarrow P(A) < P(B)$ Monotonie

$\rightarrow A_1 \subseteq A_2 \subseteq \dots \subseteq A_n \dots$

$(\lim A_n) = \cup_n A_n \quad P(\cup_n A_n) = \lim_{n \rightarrow \infty} P(A_n)$

$B_1 = A_2$ $B_n = A_n \setminus A_{n-1}$
 $A_n = B_1 \cup \dots \cup B_n$

$P(\cup A_n) = P(\cup B_n) = \sum P(B_n) = \lim \sum P(B_n) = \lim \sum P(\cup B_n) = \lim \sum P(A_n)$

$\rightarrow P(A \cup B) \leq P(A) + P(B)$ Dreiecksungleichung

gilt auch für abzählbare Vereinigungen



Sprechweise:

$A \cup B$: A oder B tritt ein. (Oder ist inklusiv!)

$A \cap B$: A und B tritt ein.

$A \oplus B$: entweder A oder B (exklusives oder - Symmetrische Differenz)

$A \ominus B = (A \cup B) \setminus (A \cap B)$ oder $(A \setminus B) \cup (B \setminus A)$

$A^c = \Omega \setminus A$: Gegenereignis, A tritt nicht ein

Wahrscheinlichkeit für Durchschnitte - Bedingte Wahrscheinlichkeit

Wsk für A, wenn B eingetreten ist.

Frequenzistisch: Experiment N mal wiederholen

B wurde bei ca $N \cdot P(B)$ beobachtet, davon zirka $N \cdot P(A \cap B)$ mit A

wie oft A auftritt = $N \cdot P(A \cap B)$

$$P(A|B) = \frac{N \cdot P(A \cap B)}{N \cdot P(B)} \quad P(B) \neq 0$$

↓
"Wahrscheinlichkeit für A unter der Bedingung B"

$$P(A|B) = P(A)$$

$$\frac{P(A \cap B)}{P(B)} = P(A)$$

$$P(A \cap B) = P(A) \cdot P(B)$$

A und B heißen unabhängig, wenn $P(A|B) = P(A) \cdot P(B)$

Multiplikationstheorem: $P(A \cap B) = P(A|B) \cdot P(B)$ oder $P(A \cap B) = P(A) \cdot P(B|A)$

BSP Wir werfen Würfel, abh. von Ergebnis geben wir weiße Kugeln in Urne; immer eine schwarze dabei

→ $P(\text{schwarze Kugel})$

$A_1 \dots A_6$: A_i = Augenzahl
 B = schwarze Kugel gezogen

$$P(B \cap "i=1") = P(i=1) \cdot P(B | "i=1") = \frac{1}{6} \cdot \frac{1}{2} = \frac{1}{12}$$

↑ Bedingte Wskl ändert sich
↙ gleich Wskl für Würfel Ergebnis

$$\frac{1}{6} \cdot \frac{1}{3} \dots$$

$$\frac{1}{6} \cdot \frac{1}{4} \dots$$

$$\vdots$$

$$\frac{1}{6} \cdot \frac{1}{7}$$

Symmetrie: Alle Elementarereignisse haben die gleiche Wahrscheinlichkeit.

$|\Omega| < \infty$ wenn für $A \subseteq \Omega$: $P(A) = \frac{|A|}{|\Omega|}$ gilt, dann heißt (Ω, P) ein ^{Wskl. Raum} Laplacescher Wahrscheinlichkeitsraum

Unabhängig: Wenn ^{Genau dann, wenn} $P(A \cap B) = P(A) \cdot P(B)$ heißen A und B voneinander unabhängig.

paarweise unabhängig: $A_1 \cap \dots \cap A_k$: Wenn für je 2 Ereignisse die Unabhängigkeit gilt $1 \leq i < j \leq n$ bzw $1 \leq i < j \leq n$ $i \neq j$ dann heißen A_1, \dots, A_k paarweise unabhängig.

$$n=2 \quad P(A_1 \cap A_2) = P(A_1) \cdot P(A_2)$$

$$P(A_2 \cap A_3) = P(A_2) \cdot P(A_3)$$

$$P(A_1 \cap A_3) = P(A_1) \cdot P(A_3)$$

vollständig unabhängig: $A_1 \dots A_k$ heißen vollständig unabhängig, wenn für $2 \leq k \leq n$
 $1 \leq i_1 < i_2 < \dots < i_k$: $P(A_{i_1} \cap \dots \cap A_{i_k}) = P(A_{i_1}) \cdot P(A_{i_2}) \cdot \dots \cdot P(A_{i_k})$

$$P(A_1 \cap A_2 \cap A_3) = P(A_1) \cdot P(A_2) \cdot P(A_3)$$

Bei U : $\begin{matrix} 0 \times 2 \\ 1 \times 3 \\ 1 \times 2 \end{matrix}$ \neq $\begin{matrix} 2 \\ 2 \end{matrix}$ paarweise
 2^n Möglichkeiten

BSP Münzwurf

A_1 = 1. Wurf Kopf
 A_2 = 2. Wurf Kopf
 A_3 = beide Wk. verschieden

$\Omega = \{(K,K), (K,Z), (Z,K), (Z,Z)\}$

$A_1 = \{(K,K), (K,Z)\}$
 $A_2 = \{(K,K), (Z,K)\}$
 $A_3 = \{(K,Z), (Z,K)\}$

$P(A_1) = P(A_2) = P(A_3) = \frac{2}{4} = \frac{1}{2}$
 $A_1 \cap A_2 = \{(K,K)\}$
 $A_1 \cap A_3 = \{(K,Z)\}$
 $A_2 \cap A_3 = \{(Z,K)\}$
 $A_1 \cap A_2 \cap A_3 = \{\}$

$$P(A_1 \cap A_2) = \frac{1}{4} = P(A_1) \cdot P(A_2)$$

$$P(A_1 \cap A_2 \cap A_3) = 0 \neq \frac{1}{8} = P(A_1) \cdot P(A_2) \cdot P(A_3)$$

BSP Urne 3 weiße, 2 schwarze Kugeln, 3x ohne zurücklegen, wie groß ist WSW, dass alle 3 Kugeln weiß sind.

A_1 ... 1 Kugel weiß

A_2 ... 2 Kugel weiß

A_3 ... 3. Kugel weiß (A_3^c ... 3 Kugel schwarz)



$$\begin{aligned} \circ) \quad P(\text{alle weiß}) &= P(A_1 \cap A_2 \cap A_3) = P(A_1) \cdot P(A_2 | A_1) \cdot P(A_3 | A_1 \cap A_2) \\ &= \frac{3}{5} \cdot \frac{2}{4} \cdot \frac{1}{3} = \frac{6}{60} = \frac{1}{10} \end{aligned}$$

$\circ) P(2 \text{ wei\ss e Kugeln}) =$

$$\begin{aligned} P(\text{WWS} \vee \text{WSW} \vee \text{SWW}) &= P((A_1 \cap A_2 \cap A_3^c) \cup (A_1 \cap A_2^c \cap A_3) \cup (A_1^c \cap A_2 \cap A_3)) = \\ &= P(A_1 \cap A_2 \cap A_3^c) + P(A_1 \cap A_2^c \cap A_3) + P(A_1^c \cap A_2 \cap A_3) = \\ &= P(A_1) \cdot P(A_2 | A_1) \cdot P(A_3^c | A_1 \cap A_2) + P(A_1) \cdot P(A_2^c | A_1) \cdot P(A_3 | A_1 \cap A_2) + P(A_1^c) \cdot P(A_2 | A_1^c) \cdot P(A_3 | A_1^c \cap A_2) \\ &= \frac{3}{5} \cdot \frac{2}{3} \cdot \frac{2}{3} + \frac{3}{5} \cdot \frac{2}{4} \cdot \frac{2}{3} + \frac{2}{5} \cdot \frac{3}{4} \cdot \frac{2}{3} = \frac{3}{5} \end{aligned}$$

$\circ) P(1 \text{ wei\ss e})$

WSS
SWS
SSW } \rightarrow

$\circ) P(A_2) = P(2. \text{ Kugel weiß})$ nur 2 weil A_2 (nach 2 Zügen!)

$$\begin{aligned} P(WW) + P(SW) &= P(A_1^c \cap A_2) + P(A_1 \cap A_2) \\ &= P(A_1^c) \cdot P(A_2 | A_1^c) + P(A_1) \cdot P(A_2 | A_1) = \\ &= \frac{2}{5} \cdot \frac{3}{4} + \frac{3}{5} \cdot \frac{2}{4} = \frac{3}{5} \hat{=} P(A_1) \end{aligned}$$


$P(A_3) = P(3. \text{ Kugel weiß})$

$$= P(WWW) + P(SWW) + \dots$$

n=2
 B1 ... 1. Kugel weiß
 B2 ... 1. Kugel schwarz

Satz der vollständigen (totalen) Wahrscheinlichkeit

Ereignis A, Ereignis B1, B2, ..., Bn von denen genau eines eintreten muss
 (dh B1, ..., Bn disjunkt i ≠ j Bi ∩ Bj = ∅ und B1 ∪ ... ∪ Bn = Ω)




Bekannt: P(B1) ... P(Bn) und P(A|B1) ... P(A|Bn)

$$\Rightarrow P(A) = \sum_{i=1}^n P(B_i) \cdot P(A|B_i)$$


bleiben disjunkt ↗

$$P(A) = P(\Omega \cap A) = P((B_1 \cup \dots \cup B_n) \cap A) = P((B_1 \cap A) \cup (B_2 \cap A) \cup \dots \cup (B_n \cap A)) = P(A \cap B_1) + \dots + P(A \cap B_n) = P(B_1) \cdot P(A|B_1) + \dots + P(B_n) \cdot P(A|B_n)$$


BSP Urne



$$P(2W) = \frac{3}{10} + \frac{3}{10} = \frac{3}{5}$$



BSP Würfel - je nach Augenzahl: so viele weiße wie Augenzahl & eine schwarze Kugel, wslk das schwarze Kugel gezogen



$$\frac{1}{6} \cdot \frac{1}{2} + \frac{1}{6} \cdot \frac{1}{3} + \frac{1}{6} \cdot \frac{1}{4} + \frac{1}{6} \cdot \frac{1}{5} + \frac{1}{6} \cdot \frac{1}{6} + \frac{1}{6} \cdot \frac{1}{7} = \frac{223}{840}$$

totale Wk für 1 schwarze Kugel

falls man nur A2 kennt: (und A1 wissen will ...)

$$P(A_1|A_2) = \frac{P(A_1 \cap A_2)}{P(A_2)} = \frac{P(A_1) \cdot P(A_2|A_1)}{\frac{2}{5}} = \frac{\frac{3}{5} \cdot \frac{1}{3}}{\frac{2}{5}} = \frac{1}{2}$$

Satz von Bayes

Ausnahmen wie vorher (B_1, \dots, B_n, A)

$$P(B_i|A) = \frac{P(B_i \cap A)}{P(A)} = \frac{P(B_i) \cdot P(A|B_i)}{\sum_{j=1}^n P(B_j) P(A|B_j)} \quad \text{Summe der totalen Wahrscheinlichkeiten}$$

Häufigkeiten P_a, P_b, P_o

BSP Blutgruppe

Frau A

Sohn O


Psychogramm:

2 Allele a b o

$$p_o \approx \frac{10}{30} \approx 0.333$$

$$p_a = \frac{9}{30} \approx 0.3$$

$$p_b = \frac{2}{30} \approx 0.067$$



$$\begin{aligned} P(a, O) &= 2 p_a p_o \\ P(b, O) &= 2 p_b p_o \\ P(O, O) &= p_o^2 \end{aligned}$$

A, O^+

$$\begin{matrix} a a \\ a o \\ o a \end{matrix} \Bigg] A \quad P("A") = p_a^2 + 2 p_a p_o = 47\%$$

$$\begin{matrix} b b \\ o b \\ b o \end{matrix} \Bigg] B \quad P("B") = p_b^2 + 2 p_b p_o = 9\%$$

$$\begin{matrix} a b \\ b a \end{matrix} \Bigg] AB \quad P("AB") = 2 p_a p_b = 4\%$$

$$o o \Bigg] O \quad P("O") = p_o^2 = 10\%$$

Formeln aufschreiben:

$$P(\text{Sohn } oo | \text{Mutter } aO) = 1 \quad P(oo | aa) = 0$$

$$P(\text{Sohn } oo | \text{Mutter } bO) = \frac{1}{2} \quad P(oo | bb) = 0$$

$$P(\text{Sohn } oo | \text{Mutter } oO) = 1 \quad P(oo | ab) = 0$$

$$\begin{aligned} \Rightarrow P(\text{Sohn "OO"}) &= 2 p_a p_o \frac{1}{2} + 2 p_b p_o \frac{1}{2} + p_o^2 \cdot 1 \\ &= p_o (p_a + p_b + p_o) = p_o \end{aligned}$$

$$P(A|O) = \frac{P(A \text{ und } O)}{P(O)} = \frac{2 p_a p_o \frac{1}{2}}{p_o} = p_a = 0.3$$

Grill hat Blutgruppe A

$$P(B|O) = \frac{P(B \text{ und } O)}{P(O)} = p_b = 0.067$$

$$P(O|O) = p_o = 0.33$$

Zufallsvariablen

Eine Zufallsvariable ist ein zufälliger Zahlenwert.

Mathematisch: Wahrscheinlichkeitsraum (Ω, \mathcal{P}) , Zufallsvariable ist Abbildung $X: \Omega \rightarrow \mathbb{R}$

Verteilung einer Zufallsvariablen ist das Wahrscheinlichkeitsmaß, was angibt, mit welcher Wahrscheinlichkeit X gewisse Werte annimmt.



$$A \in \mathbb{R}: P_x(A) = P(X \in A) = P(\{\omega \in \Omega: X(\omega) \in A\})$$

BSP Werfen von 2 Würfeln

$$\Omega = \{(1,1), (1,2), \dots, (6,6)\} = \{(x,y) : 1 \leq x \leq 6, 1 \leq y \leq 6\}$$

X ... Differenz der Beiden Augenzahlen (absolut)

$$P_x(\{5\}) = P(X \in \{5\}) = P(X=5) = P(\{(x,y) : |y-x|=5\}) = P(\{(1,6), (6,1)\}) = \frac{2}{36}$$

$$P_x(\{4\}) = P(X \in \{4\}) = \frac{4}{36} = \frac{2}{18}$$

$$P_x(\{3\}) = P(X \in \{3\}) = \frac{4}{18}$$

$$P_x(\{2\}) = P(X \in \{2\}) = \frac{4}{18}$$

$$P_x(\{1\}) = P(X \in \{1\}) = \frac{5}{18}$$

$$P_x(\{0\}) = P(X \in \{0\}) = \frac{3}{18}$$

$$P(X \in \{0, 2, 4\}) = \frac{3+4+2}{18} = \frac{1}{2}$$

$$P(X = \pi) = 0$$

$$P(X = -10024) = 0$$

diskret: Eine Zufallsvariable heißt diskret, wenn sie nur endlich oder abzählbar viele Werte annimmt.

stetig: Wenn ZV alle reellen Werte / alle Werte in einem Intervall annimmt, heißt sie stetig.

Wahrscheinlichkeitsfunktion: $P_X(x) = \mathbb{P}(X=x) = \mathbb{P}_X(\{x\})$ $x \in \mathbb{R}$ Wenn X diskret ist

$$P_X(A) = \sum_{x \in A} P_X(x)$$

$$F_X(x) = \sum_{y \leq x} P_X(y)$$


Verteilungsfunktion: $F_X(x) = P_X((-\infty, x]) = \mathbb{P}(X \leq x)$

3 Arten von Verteilung an Beispielen

- Stufenförmig, stückweise konstant mit Sprüngen (Sprünge: Werte mit der einzelne Punktwerte angenommen werden)
- F ist monoton nicht fallend
- auch von rechtssteig

BSP Würfel (von vorher) mit Verteilungsfunktion


$$F_X(x) = \begin{cases} 0 & x < 0 \\ \frac{3}{18} & 0 \leq x < 1 & \mathbb{P}(X \leq x) = \mathbb{P}(X=0) = \frac{3}{18} \\ \frac{6}{18} & 1 \leq x < 2 & \mathbb{P}(X \leq x) = \mathbb{P}(X \leq 1) = \mathbb{P}(X=0) + \mathbb{P}(X=1) \\ \frac{12}{18} & 2 \leq x < 3 \\ \frac{17}{18} & 4 \leq x < 5 \\ 1 & 5 \leq x \end{cases}$$



BSP X stetig: Ankunftszeit im Kaffeehausbeispiel Verteilung von X auflesen

X Ankunftszeit (in Stunden nach 7 Uhr)

$$F_X(x) = \mathbb{P}(X \leq x) = \begin{cases} 0 & : x < 0 \\ \mathbb{P}(X \text{ zwischen } 0 \text{ und } x) = x & 0 \leq x < 1 \\ 1 & : x \geq 1 \end{cases}$$



F_X ist stetig nicht fallend

Sagt ein Autofahrer zum anderen am Schwarzenbergplatz: "Oh es ist rot, permanente auf an Kaffee!"

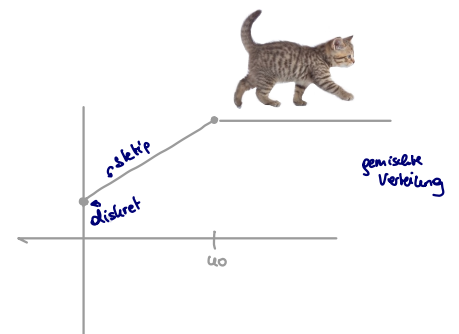
BSP Ankunftszeit (bei Ampel) zeigt 20 sek grün

40 sek rot

X ist Wartezeit

$$\mathbb{P}(X=0) = \frac{20}{60}$$


$$0 \leq X < 40 : F_X(x) = \mathbb{P}(X \leq x) = \frac{20+x}{60}$$



stetig: alle reellen
 diskret: endlich abzählbar
 gemischt:

Verteilungsfunktion $F_X(x) = \mathbb{P}(X < x)$

diskret: stückweise konstant, dazwischen Sprünge



stetig: stückweise differenzierbar, Gleichverteilung auf $[0,1]$

$$F_X = \begin{cases} 0 & x < 0 \\ x & 0 \leq x \leq 1 \\ 1 & x \geq 1 \end{cases}$$

$$f_X = F_X'(x) = \begin{cases} 0 & \text{sonst} \\ 1 & 0 \leq x \leq 1 \end{cases}$$

↳ für 0 und 1 gelogen!

Eigenschaften:

- rechtsstetig
- nicht fallend
- $F_X(-\infty) = \lim_{x \rightarrow -\infty} F_X(x) = 0$ "linkes Ende"
- $F_X(\infty) = \lim_{x \rightarrow \infty} F_X(x) = 1$ "rechtes Ende"

Dichtefunktion $f_X: \mathbb{R} \rightarrow \mathbb{R}^+$

$$F_X(x) = \int_{-\infty}^x f_X(t) dt$$

Analogie zur Wahrscheinlichkeitsfunktion $p_X(x) = \mathbb{P}(X=x)$

$$F_X(x) = \sum_{t \leq x} p_X(t)$$

Eigenschaften

- $f_X(x) \geq 0$
- $\int_{-\infty}^{\infty} f_X(x) dx = 1$

Eigenschaften Wahrscheinl.funktion


- $p_X(x) \geq 0$
- $\sum p_X(x) = 1$

gemischte Verteilungen

Hat sowohl eine "Dichtefunktion" als auch eine "Wahrscheinlichkeitsfunktion"




[BSP] komplizierte Wartezeit $\mathbb{P}(X=0) = \mathbb{P}(X=1) = \frac{1}{3}$ dazwischen gleichmäßig



Eigenschaften

$$F_X(x) = \sum_{t \leq x} p_X(t) + \int_{-\infty}^x f_X(t) dt$$

$$p_X(x) = \begin{cases} \frac{1}{2} & 0 \leq x \leq 1 \\ 0 & \text{sonst} \end{cases}$$



um auf nur WSL Fkt zu kommen $1 \rightarrow \frac{1}{2}$

Dichte: $0 \rightarrow \frac{1}{2}$

$$F_X(x) = \frac{1}{2} \sum_{t \leq x} p_X^*(t) + \frac{1}{2} \int_{-\infty}^x f_X^*(t) dt$$

$$f_X^*(x) = \begin{cases} 1 & 0 \leq x \leq 1 \\ 0 & \text{sonst} \end{cases}$$

Mischung von F_1 und F_2 mit den Gewichten α und $1-\alpha$ $0 \leq \alpha \leq 1$

$$F(x) = \alpha \cdot F_1(x) + (1-\alpha) F_2(x)$$

jede pers. Vert. kann als Mischung von stetig + diskreter Verteilung angesehen werden

Spezielle Verteilungen

1) Diskrete Verteilungen endlich höchstens abzählbar viele endliche Werte

$D(a)$ deterministisch $\mathbb{P}(X=a) = 1$ $p_x(x) = \begin{cases} 1 & x=a \\ 0 & \text{sonst} \end{cases}$ aka degeneriert (verfallen)

$A(p)$ Alternativverteilung $\mathbb{P}(X=0) = 1-p$ $0 \leq p \leq 1$ $\mathbb{P}(X=1) = p$ $p_x(x) = \begin{cases} p & x=1 \\ 1-p & x=0 \\ 0 & \text{sonst} \end{cases}$

$D(a,b)$ Diskrete Gleichverteilung $\mathbb{P}(X=a) = \mathbb{P}(X=a+1) = \dots = \mathbb{P}(X=b) = \frac{1}{b-a+1}$ $p_x(x) = \begin{cases} \frac{1}{b-a+1} & a \leq x \leq b, x \in \mathbb{Z} \\ 0 & \text{sonst} \end{cases}$
 aka Laplace'scher WkR Raum
 $a, b \in \mathbb{Z}$ $a \leq b$

BSP Würfel $a=1$
 $b=6$

$B(n,p)$ Binomialverteilung $p_x(x) = \begin{cases} \mathbb{P}(X=x) = \binom{n}{x} p^x (1-p)^{n-x} & 0 \leq x \leq n \\ 0 & \text{sonst} \end{cases}$

n unabhängige Versuche, Jeder Versuch Erfolg oder Misserfolg

$X = \text{Anzahl der Erfolge}$ $p = \mathbb{P}(\text{Erfolg})$

BSP $n=5$ Möglichkeiten 2 Erfolge auf 5 Plätze aufzuteilen:
 $X=2$
 $(p = \frac{1}{3})$

EEMMH HEEEM MHEEM
 EMEMH HEMEM HMEME
 EMMEH MEMHE MMHEE
 EHHHE

$\rightarrow 10$

$p_x(2) = \mathbb{P}(X=2) =$
 $= 10 p^2 (1-p)^3 = \binom{5}{2} p^2 (1-p)^3$
 Fallunterscheidungen
 (fallen eigentlich weg)

$H(N,A,n)$ Hypergeometrische Verteilung $p_x(x) = \frac{\binom{A}{x} \cdot \binom{N-A}{n-x}}{\binom{N}{n}}$
 $(n, A \leq N)$

$[\max(0, n+A-N) \leq x \leq \min(n, A)]$

BSP Urne: N Kugeln, A weiß, n Kugeln ohne Zurücklegen ziehen
 $[N=5, A=3, 3 \text{ bereits gezogen}]$

$G^*(p)$
 $G(p)$ } Geometrische Verteilung

$\mathbb{P}(X=x) = (1-p)^{x-1} \cdot p$ $x=1, 2, \dots$

unabhängige Versuche bis zum ersten Erfolg

$X = \text{Anzahl der Versuche}$

$\mathbb{P}(X=x) = (1-p)^x \cdot p$ $x=0, 1, \dots$

$X = \text{Anzahl der Misserfolge}$

$NB^*(n,p)$
 $NB(n,p)$ } Negative Binomialverteilung

$\mathbb{P}(X=x) = \binom{x-1}{n-1} p^n$

bis zum n ten Erfolg
 $x=n, n+1$

$\mathbb{P}(X=x) = \binom{x+n-1}{n-1} (1-p)^x p^n = \binom{x+n-1}{x} (1-p)^x p^n$

Zählen der Misserfolge
 $x=0, 1, \dots$

$\binom{x+n-1}{x} = \frac{(x+n-1) \dots (n+1)n}{x!}$

geht für jedes positive n ,
 n muss nicht ganzzahlig sein

$P(\lambda)$ Poisson Verteilung
 (Verteilung für seltene Ereignisse
 ↓ sehr viele Versuche mit kl. Erfolgswk)

$p_x(x) = \frac{\lambda^x}{x!} e^{-\lambda}$ $\lambda=0$
 $x=0, 1, \dots$

aka Grenzfall der Binomialverteilung

$n \rightarrow \infty$
 $n \cdot p \rightarrow \lambda$

Spezielle Verteilungen (=>)

stetige Verteilungen

stetige Gleichverteilung: $U(a, b)$


$a < b$

Dichte $f(x) = \begin{cases} \frac{1}{b-a} & a \leq x \leq b \\ 0 & \text{sonst} \end{cases}$

Standardgleichverteilung $U(0, 1)$

$a=0, b=1$

BSP Position von x des ersten realierten Intervalls



$P(X \leq x) = P(\text{es gibt Realisierung links von } x)$

$1 - P(\text{es gibt keine Realisierung links von } x) = 1 - (1 - \frac{1}{2^{n+1}})^{\lfloor 2^n \cdot x \rfloor} \rightarrow 1 - e^{-x}$

Exponentialverteilung $E(\lambda)$ $\lambda > 0$

$F(x) = \begin{cases} 1 - e^{-\lambda x} & x > 0 \\ 0 & x < 0 \end{cases}$ Dichte $f(x) : f(x) = \begin{cases} \lambda e^{-\lambda x} & x \geq 0 \\ 0 & x < 0 \end{cases}$

Gammaverteilung: $\Gamma(\alpha, \lambda)$

$f(x) = \frac{1}{\Gamma(\alpha)} \cdot \lambda^\alpha x^{\alpha-1} e^{-\lambda x} \quad x > 0$

Vorlesungsinhalte:
 Gammafunktion $\Gamma(\alpha) = \int_0^\infty x^{\alpha-1} e^{-x} dx \quad \alpha > 0$
 Funktionalgleichung: $\Gamma(\alpha+1) = \alpha \cdot \Gamma(\alpha)$
 $\Gamma(1) = 1, \Gamma(n) = (n-1)!$ $n \in \mathbb{N}$
 $\Gamma(\frac{1}{2}) = \sqrt{\pi}$

$F(x)$ = möglich wenn α Ganzzahlige
 -> partielle Integration
 Gert & Poissonver. Mix

Interpolation der Fakultätsfunktion

Betafunktion: $B(\alpha, \beta) = \int_0^1 x^{\alpha-1} (1-x)^{\beta-1} dx \quad \alpha, \beta > 0$
 $B(\alpha, \beta) = \frac{\Gamma(\alpha) \cdot \Gamma(\beta)}{\Gamma(\alpha+\beta)}$

Verteilungsfunktion

$F(x) = \int_{-\infty}^x f(u) du$

nicht geschlossen integrierbar

Betaverteilung (erster Art) $B_1(\alpha, \beta)$

$f(x) = \frac{x^{\alpha-1} (1-x)^{\beta-1}}{B(\alpha, \beta)} \quad [0 < x < 1]$

Betaverteilung (zweiter Art) $B_2(\alpha, \beta)$

$f(x) = \frac{1}{B(\alpha, \beta)} \frac{x^{\alpha-1}}{(1+x)^{\alpha+\beta}} \quad 0 < x$

Normalverteilung $N(\mu, \sigma^2)$

$f(x) = \frac{1}{\sqrt{2\pi \cdot \sigma^2}} e^{-\frac{(x-\mu)^2}{2\sigma^2}} \quad N(0, 1) \quad \mu=0 \quad \sigma^2=1$

Standardnormalverteilung

$\varphi(x) = \frac{1}{\sqrt{2\pi}} e^{-\frac{x^2}{2}}$

$\Phi(x) = \int_{-\infty}^x \frac{1}{\sqrt{2\pi}} e^{-\frac{u^2}{2}} du$ Verteilungsfunktion der StNV

$N(\mu, \sigma^2) \rightarrow F_{\mu, \sigma^2}(x) = P(X \leq x) = \Phi\left(\frac{x-\mu}{\sigma}\right)$

Errorfunction: $\text{erffun}(x) = \int_0^x e^{-u^2} du \quad \Phi(x) = \dots \text{erffun}\left(\frac{x}{\sqrt{2}}\right)$

BSP $X \sim N(0,1)$

Die Verteilungsfunktion der Standardnormalverteilung:

$$\Phi(x) = \int_{-\infty}^x \frac{1}{\sqrt{2\pi}} e^{-\frac{t^2}{2}} dt$$

| x | 0 | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 |
|-----|-----|-----|-----|-----|-----|-----|-----|-----|-----|-----|
| 0.0 | 500 | 594 | 508 | 512 | 516 | 520 | 524 | 528 | 532 | 536 |
| 0.1 | 540 | 544 | 548 | 552 | 556 | 560 | 564 | 567 | 571 | 575 |
| 0.2 | 579 | 583 | 587 | 591 | 595 | 599 | 603 | 606 | 610 | 614 |
| 0.3 | 618 | 622 | 626 | 629 | 633 | 637 | 641 | 644 | 648 | 652 |
| 0.4 | 655 | 659 | 663 | 666 | 670 | 674 | 677 | 681 | 684 | 688 |
| 0.5 | 691 | 695 | 698 | 702 | 705 | 709 | 712 | 716 | 719 | 722 |
| 0.6 | 726 | 729 | 732 | 736 | 739 | 742 | 745 | 749 | 752 | 755 |
| 0.7 | 758 | 761 | 764 | 767 | 770 | 773 | 776 | 779 | 782 | 785 |
| 0.8 | 788 | 791 | 794 | 797 | 800 | 802 | 805 | 808 | 811 | 813 |
| 0.9 | 816 | 819 | 821 | 824 | 826 | 829 | 831 | 834 | 836 | 839 |
| 1.0 | 841 | 844 | 846 | 848 | 851 | 853 | 855 | 858 | 860 | 862 |
| 1.1 | 864 | 867 | 869 | 871 | 873 | 875 | 877 | 879 | 881 | 883 |
| 1.2 | 885 | 887 | 889 | 891 | 893 | 894 | 896 | 898 | 900 | 901 |
| 1.3 | 903 | 905 | 907 | 908 | 910 | 911 | 913 | 915 | 916 | 918 |
| 1.4 | 919 | 921 | 922 | 924 | 925 | 926 | 928 | 929 | 931 | 932 |
| 1.5 | 933 | 934 | 936 | 937 | 938 | 939 | 941 | 942 | 943 | 944 |
| 1.6 | 945 | 946 | 947 | 948 | 949 | 951 | 952 | 953 | 954 | 954 |
| 1.7 | 955 | 956 | 957 | 958 | 959 | 960 | 961 | 962 | 962 | 963 |
| 1.8 | 964 | 965 | 966 | 966 | 967 | 968 | 969 | 969 | 970 | 971 |
| 1.9 | 971 | 972 | 973 | 973 | 974 | 974 | 975 | 975 | 976 | 977 |
| 2.0 | 977 | 978 | 978 | 979 | 979 | 980 | 980 | 981 | 981 | 982 |
| 2.1 | 982 | 983 | 983 | 984 | 984 | 984 | 985 | 985 | 985 | 986 |
| 2.2 | 986 | 986 | 987 | 987 | 987 | 988 | 988 | 988 | 989 | 989 |
| 2.3 | 989 | 990 | 990 | 990 | 991 | 991 | 991 | 991 | 991 | 992 |
| 2.4 | 992 | 992 | 992 | 993 | 993 | 993 | 993 | 993 | 993 | 994 |
| 2.5 | 994 | 994 | 994 | 994 | 994 | 995 | 995 | 995 | 995 | 995 |
| 2.6 | 995 | 995 | 996 | 996 | 996 | 996 | 996 | 996 | 996 | 996 |
| 2.7 | 997 | 997 | 997 | 997 | 997 | 997 | 997 | 997 | 997 | 997 |
| 2.8 | 997 | 998 | 998 | 998 | 998 | 998 | 998 | 998 | 998 | 998 |
| 2.9 | 998 | 998 | 998 | 998 | 998 | 998 | 999 | 999 | 999 | 999 |

$P(X \leq 1,96) = 0,975$


$\Phi(1,96)$

gleich weit relative Verteilung!

$P(X \leq -1,96) = P(X < -1,96) = 1 - 0,975 = 0,025$

$X \sim N(3, 16)$

$P(-2,12 \leq X \leq 9,58) = \Phi\left(\frac{9,58-3}{4}\right) - \Phi\left(\frac{-2,12-3}{4}\right) = \Phi(1,645) - \Phi(-1,28) = 0,95 - (1-0,9) = 0,85$



R... Statistikpaket pnorm(1,96)

pnorm(9,58; 3; sqrt(16))

$X \sim F_x$ suche x so, dass $F_x(x) = p$ ($0 < p \leq 1$)

solches x heißt p -Quantil

$p = \frac{1}{2}$ Median

$p = \frac{1}{4}, \frac{3}{4}$ Quartile

Chi-Quadrat Verteilung χ^2_f

$\chi^2_p = \Gamma\left(\frac{f}{2}, \frac{1}{2}\right)$

f... Anzahl der Freiheitsgrade

$\chi^2_{1-p} = \Gamma\left(\frac{f}{2}, \frac{1}{2}\right)$

t Verteilung

F Verteilung

} mehr als eine Zufallsvariable, X und Y dichot

... Mehr als eine Zufallsvariable ...

Zufallsvariable: gemeinsame Verteilung von zwei oder mehr Zufallsvariablen (mehrdimensional = Zufallsvektor)

$$P_{x,y}(x,y) = P(X=x, Y=y) \dots \text{gemeinsame Wahrscheinlichkeitsfunktion von } X \text{ und } Y$$

BSP 2mal Würfeln

X kleinere Augenzahl

Y größere Augenzahl

$$P_X(x) = P(X=x) = P(X=1) = \dots$$

$$P(X=1, Y=1) + \dots + P(X=1, Y=6) = \frac{11}{36}$$

mehrdimensionale Zufallsvariable $Z(X,Y)$ "Zufallsvektor"

$$\text{Wahrscheinlichkeitsfunktion: } p_z(z) = p_z(x,y) = P_{x,y}(x,y)$$

stetige Verteilung

$$\text{Verteilungsfunktion: } F_z(z) = P(Z \leq z) \quad z(x,y) = P(X \leq x, Y \leq y)$$

soll heißen $x \in X$ und $y \in Y$

im diskreten Fall: $F_{x,y}(x,y) = \sum_{u \leq x} \sum_{v \leq y} P(x=u, y=v) = \sum_{u \leq x} \sum_{v \leq y} P_{x,y}(u,v)$ (2 Variablen)

$$F_x(x) = \sum_y P_x(y) = \sum_y \sum_x \dots \sum_x P_{x_1, \dots, x_n}(y_1, \dots, y_n)$$
 (n Variablen)

BSP $F_{x,y}(x,y) = \begin{cases} 0 & x < 1, y < 1 \\ \dots & \dots \end{cases}$ $u = \begin{matrix} 1 & v=1 \\ 2 & v=2 \\ 3 & v=3 \\ \vdots & \vdots \end{matrix}$ $F_{x,y}(3,2) = P_{x,y}(1,1) + \dots + P(3,2) = 1,9$

mehrdimensionale Verteilungsfunktion

$$F_x(x) = P(X \leq x) = P(X \leq x_1, \dots, X \leq x_n)$$

$$x = (x_1, \dots, x_n)$$

stetig: $F_x(x) = P(X \leq x) = P(X \leq x_1, \dots, X \leq x_n) = \int_{-\infty}^{x_1} \dots \int_{-\infty}^{x_n} f_{x_1, \dots, x_n}(y_1, \dots, y_n) dy_1 \dots dy_n = \int_{-\infty}^{x_n} \dots \int_{-\infty}^{x_1} \dots$

Grenzen vertauscht

Eigenschaften einer Wahrscheinlichkeitsfunktion in n Dimensionen

$$P_x(x) \geq 0 \quad \forall x \in \mathbb{R}$$

$$\sum_{x \in \mathbb{R}^n} P_x(x) = 1 = \sum_{x_1} \dots \sum_{x_n} P_x(x_1, \dots, x_n)$$

(monoton, rechteckig, $x \rightarrow 0 / x \rightarrow -1$)

Eigenschaften einer Verteilungsfunktion: $F(x_1, \dots, x_n)$ $n=2$

1) $F(x_1, x_2)$ rechteckig (wie in \mathbb{R})

2) $F(x_1, x_2)$ nichtfallend

$$3a) \lim_{x_1 \rightarrow -\infty} F(x_1, x_2) = \lim_{x_2 \rightarrow -\infty} F(x_1, x_2) = 0$$

$$3b) \lim_{x_1, x_2 \rightarrow \infty} F(x_1, x_2) = 1$$

$$3c) \lim_{x_2 \rightarrow \infty} F(x_1, x_2) = F_{x_1}(x_1) \text{ Randverteilungsfunktion}$$

*) stetig, zweidimensional: $f_{x,y}(x,y) = f(y,y) = c(x^2+y^2) \quad 0 \leq x \leq y \leq 1$


Eigenschaften einer Dichtefunktion:

$$f_x(x) \geq 0 \quad \forall x \in \mathbb{R}$$

$$\int_{-\infty}^{\infty} \dots \int_{-\infty}^{\infty} f_x(x) dx_1 \dots dx_n = f_x(x_1, \dots, x_n) = f_{x_1, \dots, x_n}(x_1, \dots, x_n) = 1$$

4) $a_1 < b_1 \quad a_2 < b_2$

$$F(b_1, b_2) - F(b_1, a_2) - F(a_1, b_2) + F(a_1, a_2) \geq 0$$



mehrdimensional:
Additionstheorem
2ⁿ Summanden

BSP zum Punkt 4)

$$f_{x,y}(x,y) = f(x,y) = c(x^2+y^2) \quad 0 \leq x \leq y \leq 1$$

$\rightarrow c?$

$$\text{Randbedingung } \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} f_{x,y}(x,y) dx dy = 0$$

$$1 = \int_0^1 \int_0^y (x^2+y^2) dx dy = c \int_0^1 \left[\frac{1}{3}x^3 + y^2x \right]_0^y dy = \int_0^1 \frac{4y^3}{3} dy = c \frac{y^4}{6} \Big|_0^1 = \frac{c}{6} \rightarrow c = 3$$

$$f_x(x) = \int_{-\infty}^{\infty} f_{x,y}(x,y) dy = \int_{x}^1 c(x^2+y^2) dy = \dots$$

Wichtig: $\int_{-\infty}^{\infty} f_{x,y}(x,y) dx = \dots$

$$f_y(y) = \int_{-\infty}^{\infty} f_{x,y}(x,y) dx = \int_0^y c(x^2+y^2) dx = 4y^3 \quad 0 \leq y \leq 1$$



Erwartungswert



Gewinne $x_1 \dots x_n$ mit Wahrscheinlichkeiten $p(x_1), \dots, p(x_n)$

$$\begin{aligned}
 N \text{ Versuche} &: N \cdot p(x_1) \text{ mal } x_1 \rightarrow N \cdot p(x_1) \cdot x_1 \\
 &\quad \vdots \\
 &N \cdot p(x_n) \text{ mal } x_n \rightarrow N \cdot p(x_n) \cdot x_n \\
 &= N(p(x_1)x_1 + \dots + p(x_n)x_n)
 \end{aligned}$$

X reelle Zufallsvariable

$$E(X) = \sum x p_x(x) = \int_{-\infty}^{\infty} x f_X(x) dx \quad \text{diskret}$$

Annäherung:

$$x^1 \text{ auf ganze Zahlen gerundet} \quad x^1 = \lfloor x \rfloor \cdot \mathbb{I}(x^1) = \sum_n n \mathbb{P}(n \leq X < n+1) = \sum_n \int_n^{n+1} f_X(x) dx = \int_{-\infty}^{\infty} \lfloor x \rfloor f_X(x) dx$$

x^2 auf zehntel gerundet

diskret $E(X) = \sum x p_X(x)$

gewichtetes Mittel

stetig $E(X) = \int_{-\infty}^{\infty} x f_X(x) dx = \left(\int_{-\infty}^{\infty} x f_X(x) dx + \int_{-\infty}^{\infty} x f_X(x) dx \right)$

gemischt: $E(X) = \sum x p_X(x) + \int_{-\infty}^{\infty} x f_X(x) dx$

alles was in diskret existiert, kann in

stetig übersetzt werden

$$\sum \rightarrow \int \quad \text{Wahrsch.} \rightarrow \text{Dichtefunkt.}$$

Abhängigkeiten und Unabhängigkeiten von Zufallsvariablen

Zwei Ereignisse A, B heißen unabhängig, wenn $\mathbb{P}(A \cap B) = \mathbb{P}(A) \mathbb{P}(B)$

Zwei Zufallsvariablen X und Y heißen unabhängig, wenn für alle $A, B \in \mathcal{R}$ gilt: $\mathbb{P}(X \in A, Y \in B) = \mathbb{P}(X \in A) \cdot \mathbb{P}(Y \in B)$

oder $F_{X,Y}(x,y) = F_X(x) \cdot F_Y(y)$ oder (X diskret): $P_{X,Y}(x,y) = p_X(x) \cdot p_Y(y) \rightarrow \mathbb{P}(X=x, Y=y) = \mathbb{P}(X=x) \cdot \mathbb{P}(Y=y)$

oder (X stetig): $f_{X,Y}(x,y) = f_X(x) \cdot f_Y(y)$

mehr als 2 Zufallsvariablen $x_1 \dots x_n$

"wenn jede endliche Auswahl unabhängig ist"

• paarweise unabhängig x_i, x_j sind unabhängig $\forall 1 \leq i < j \leq n$

• vollständig unabhängig $F_{x_1, \dots, x_n}(x_1, \dots, x_n) = F_{x_1}(x_1) \dots F_{x_n}(x_n)$

- diskret: $P_{x_1, \dots, x_n}(x_1, \dots, x_n) = p_{x_1}(x_1) \dots p_{x_n}(x_n)$

- stetig: $f_{x_1, \dots, x_n}(x_1, \dots, x_n) = f_{x_1}(x_1) \dots f_{x_n}(x_n)$

X und Y sind nicht unabhängig: $P_{X,Y}(x,y) = \mathbb{P}(X=x, Y=y) = \underbrace{\mathbb{P}(X=x)}_{p_X(x)} \underbrace{\mathbb{P}(Y=y|X=x)}_{p_{Y|X}(y|x)}$

$$\left. \begin{matrix} p_{Y|X}(y|x) \\ p_Y(y|x=x) \end{matrix} \right\} \mathbb{P}(Y=y|X=x) = \frac{p_{X,Y}(x,y)}{p_X(x)}$$

Beispiele für Anwendung des Erwartungswertes

BSP Würfeln, Augenzahl als Belohnung wird ca. $6 \cdot 10^6$ mal wiederholt

$$\begin{array}{l} 10^6 \cdot 1 = 1 \cdot 10^6 \\ 10^6 \cdot 2 = 2 \cdot 10^6 \\ 10^6 \cdot 3 = 3 \cdot 10^6 \\ \vdots \\ 5 \cdot 10^6 \\ 6 \cdot 10^6 \\ \hline 21 \cdot 10^6 \end{array}$$

Stundenlohn:
 $\frac{21 \cdot 10^6}{6 \cdot 10^6} = 3,5$ pro Wurf

BSP $P(X=2^n) = \frac{1}{2^n}$ (St. Petersburg Spiel)

② $E(X) = \sum_{n=1}^{\infty} 2^n \cdot \frac{1}{2^n} = \sum 1 = \infty$

BSP $P(X=(-1)^n(n+1)) = \frac{1}{n(n+1)} = \frac{1}{n} - \frac{1}{n+1} = 1$

③ $E(X) = \sum \frac{1}{n(n+1)}$ existiert nicht

BSP faires Würfeln

④ $E(X) = 1 \cdot \frac{1}{6} + 2 \cdot \frac{1}{6} + \dots + 6 \cdot \frac{1}{6} = \frac{7}{2}$

⑤

BSP $B(n, p)$

$P(X=x) = \binom{n}{x} p^x (1-p)^{n-x}$ $x=0, \dots, n$

$$\begin{aligned} E(X) &= \sum x \binom{n}{x} p^x (1-p)^{n-x} = \sum x \frac{n!}{(n-x)! x!} p^x (1-p)^{n-x} \\ &= \sum_{x=1}^n \frac{n!}{(x-1)! (n-x)!} p^x (1-p)^{n-x} = \sum_{k=x-1}^{n-1} \frac{n!}{k! (n-1-k)!} p^{k+1} (1-p)^{n-1-k} \\ &= \sum_{k=0}^{n-1} n \binom{n-1}{k} p^{k+1} (1-p)^{n-1-k} = np \sum \binom{n-1}{k} p^k (1-p)^{n-1-k} \\ &\quad \text{Binomische Formel} \\ &\rightarrow E = n \cdot p \end{aligned}$$

BSP ⑥

D(a,b): $f(x) = \begin{cases} \frac{1}{b-a} & a \leq x \leq b \\ 0 & \text{sonst} \end{cases}$

$E(X) = \int_a^b \frac{x}{b-a} dx = \frac{1}{b-a} \left(\frac{b^2}{2} - \frac{a^2}{2} \right) = \frac{b^2 - a^2}{2(b-a)} = \frac{b+a}{2}$

⑦ **BSP** $N(0,1) \cdot \varphi(x) = \frac{1}{\sqrt{2\pi}} e^{-\frac{x^2}{2}}$

$E(X) = \int_{-\infty}^{\infty} \frac{x}{\sqrt{2\pi}} e^{-\frac{x^2}{2}} dx = \left. -\frac{x e^{-\frac{x^2}{2}}}{\sqrt{2\pi}} \right|_{-\infty}^{\infty} = 0$

⑧


BSP Cauchyverteilung $f(x) = \frac{1}{\pi(1+x^2)}$

$E(X) = \int_{-\infty}^{\infty} \frac{x}{\pi(1+x^2)} dx$

positiv: $\int_0^{\infty} \frac{x}{\pi(1+x^2)} dx = \left. \frac{\log(1+x^2)}{2\pi} \right|_0^{\infty} = \infty$

negativ: $\int_{-\infty}^0 \frac{x}{\pi(1+x^2)} dx = -\infty$

BSP ⑨ Ampel



$f_{00} = \begin{cases} 0 & x < 0 \\ \frac{1}{3} + \frac{x}{60} & 0 < x < 40 \\ 1 & x \geq 40 \end{cases}$

$P_X(0) = \frac{1}{3}$

$f_X(x) = \frac{1}{60}$

$E(X) = \underbrace{0 \cdot \frac{1}{3}}_{\sum x P_X(x)} + \int_0^{40} x \frac{1}{60} dx = 0 + \frac{40}{3}$

König:

$$\left. \begin{array}{l} f_Y(y|X=x) \\ f_{Y|X}(y|x) \end{array} \right\} \frac{f_{XY}(x,y)}{f_X(x)} \quad \text{bedingte Dichte} \quad P(Y=y|X=x) = \int_{-\infty}^{\infty} f_Y(t|X=x) dt$$

Weg um bedingte Wahrscheinlichkeit mit einem bedingten Ereignis mit WSK θ zu berechnen (Funktioniert nur wenn Bedingung ≥ 0)

kann als Grenzwert von $P(Y=y | x-\epsilon < X < x+\epsilon)$ verstanden werden.

Bedingter Erwartungswert

Y, X diskret $E(Y|X=x) = \sum_i y \cdot P_Y(y|X=x) = \sum_i y P_Y(Y=y|X=x) = \sum_i y \frac{xY(x,y)}{P_X(x)}$

Y, X stetig $E(Y|X=x) = \int y \cdot f_Y(y|X=x) dy$

Eigenschaften des Erwartungswertes

1) Satz vom unvollkommenen Statistiker

$$X, g: \mathbb{R} \rightarrow \mathbb{R}, Y = g(X) \quad E(Y) = E(g(X)) = \begin{cases} \sum p(x) \cdot g(x) \\ \int g(x) f(x) dx \end{cases}$$

geht auch mehrdimensional



2) Linearität

$$E(aX+b) = aE(X) + b$$

$$E(aX+b) = \sum (ax+b) P_X(x) = a \underbrace{\sum x P_X(x)}_{E(X)} + b \cdot \underbrace{\sum P_X(x)}_1 = \sum y P(aX+b=y)$$

$$P(g(X=Y)) = \sum_{x:P(x)=y} P(X=x)$$

$$E(g(X)) = \sum y P(g(X=y)) = \sum_y y \cdot \sum_x P(X=x) = \sum_y \sum_x y P(X=x) = \sum_x \sum_y g(x) P(X=x) = \sum_x g(x) \cdot P_X(x)$$

[BSP] Alpenzahl, $P = (X-3)^2$

$$P(g(X)=0) = P((X-3)^2=0) = P(X=3) = \frac{1}{6}$$

$$P(g(X)=1) = P((X-3)^2=1) = P(X=2 \text{ or } X=4) = P(X=2) + P(X=4)$$

3) Additivität

$$X, Y \quad E(X+Y) = E(X) + E(Y) \quad z = (X, Y) \text{ zweidimensional}$$

$$g(x,y) = x+y \quad g(z) = X+Y$$

$$g(x,y) = x \quad g(z) = X$$

$$g(x,y) = y \quad g(z) = Y$$

$$\begin{aligned} E(X+Y) &= E(g(z)) = \sum_{z \in \mathbb{R}^2} g(z) \cdot P(z=z) = \sum_{x,y} g(x,y) \cdot P(X=x, Y=y) = \sum_{x,y} (x+y) P(X=x, Y=y) \\ &= \sum_x \sum_y x P(X=x, Y=y) + \sum_x \sum_y y P(X=x, Y=y) \\ &= \underbrace{\sum_x x P(X=x)}_{E(X)} + \underbrace{\sum_y y P(Y=y)}_{E(Y)} = E(X) + E(Y) \end{aligned}$$

4) Monotonie

$$X \leq Y \Rightarrow E(X) = E(Y) \quad \text{Spezialfall } X \geq 0 \Rightarrow E(X) \geq 0$$

Wenn X und Y unabhängig sind: $E(X \cdot Y) = E(X) \cdot E(Y)$

$$E(X \cdot Y) = \sum_{x,y} xy P(X=x) \cdot P(Y=y) = \sum_x \sum_y xy P(X=x) P(Y=y) = \sum_x x P(X=x) \cdot \sum_y y P(Y=y) = E(X) \cdot E(Y)$$

[BSP] $P(X=-1) = P(X=0) = P(X=1) = \frac{1}{3}$

$$Y = X^2 \quad P(Y=0) = \frac{1}{3} \\ P(Y=1) = \frac{2}{3}$$


$$X, Y = X^2 - X \quad E(X \cdot Y) = E(X) \cdot E(Y)$$

$$E(Y) = \frac{2}{3}$$

$$P(X=0, Y=1) \neq P(X=0) P(Y=1)$$

Philosophisch: Erwartungswert ist ein "Mittelwert" (vom frequentistischen Standpunkt aus)

Lageparameter - typischer Wert




Wie genau gibt ein Lageparameter die Verteilung wieder?

Maßzahl: aka Mean Absolute Deviation \rightarrow MAD mittlere absolute Abweichung von m

$$MAD(m) = E(|X - m|)$$

$m = E(X)$ oder ein anderer Lageparameter

Betrag ist Pfi \rightarrow viel beliebter: Quadrieren, MSD, MSQ, MSE (m) = $E((X - m)^2)$



"in θ hat man Ableitung θ "

notum non facis salus

Varianz: $V(X) = E((X - E(X))^2)$

verschiebung ändert nichts an Varianz!

$$V(aX+b) = E((aX+b - E(aX+b))^2) = E[(aX+b - aE(X)-b)^2] = E[a(X - E(X))^2] = E[a^2(X - E(X))^2] = a^2 E((X - E(X))^2) = a^2 \cdot V(X)$$

Standardabweichung / Streuung: $\sqrt{V(X)}$ RMSE

Kovarianz $Cov(X, Y) = E((X - E(X))(Y - E(Y)))$

Herleitung:

Wenn X und Y unabhängig sind, gilt $Cov(X, Y) = 0$

Beweis: $E((X - E(X))(Y - E(Y))) =$

$$E(XY - XE(Y) - YE(X) + E(X)E(Y)) =$$

$$E(XY) - E(X)E(Y) - E(X)E(Y) + E(X)E(Y) =$$

$$= E(XY) - E(X)E(Y)$$

2x Produkt des

$$\begin{aligned} V(X+Y) &= E((X+Y - E(X+Y))^2) = E((X+Y - E(X) - E(Y))^2) \\ &= E((X - E(X))^2) + E((Y - E(Y))^2) + 2E((X - E(X))(Y - E(Y))) = \\ &= V(X) + V(Y) + 2Cov(X, Y) \end{aligned}$$

unkorreliert: $E(X) \cdot E(Y) = E(XY)$

$$V(X+Y) = V(X) + V(Y)$$

Korrelation (Korrelationskoeffizient)

$$\rho(X, Y) = \frac{Cov(X, Y)}{\sqrt{V(X) \cdot V(Y)}} \quad -1 \leq \rho \leq 1$$

Stoner-Movement - Senke

Steinersche Verschiebungssatz:

$$V(X) + 0 + (E(X) - m)^2$$

Herleitung

$$E((X-m)^2) = E((X-E(X) + E(X)-m)^2) = E((X-E(X))^2 + 2(X-E(X))(E(X)-m) + (E(X)-m)^2)$$

$$= E((X-E(X))^2) + 2(E(X)-m)E(X-E(X)) + (E(X)-m)^2$$

↪ $E(X) - E(X) = 0$

WIR SEHEN: $m=0 \Rightarrow E(X^2) = V(X) + (E(X))^2$

1) $V(X) = E(X^2) - (E(X))^2$

2) $E(X^2) \geq (E(X))^2$

3) $E(X)$ ist bester Lageparameter (der mit der kleinsten Abweichung)

[BSP] $f(x,y) = 3(x^2+y^2) : 0 < x < y < 1$

$$p(x,y) = \frac{\text{Conv}(x,y)}{V(X)V(Y)}$$

$$E(X), E(Y), E(X^2), E(XY), E(Y^2)$$

$$E(XY) = \int_0^1 \int_0^y 3xy(x^2+y^2) dx dy = 3 \int_0^1 \int_0^y x^3 y^2 + x^2 y^3 dx dy = 3 \int_0^1 \left[\frac{y^3 x^4}{4} + \frac{y^4 x^3}{3} \right]_0^y dy = 3 \int_0^1 \left(\frac{y^7}{4} + \frac{y^7}{3} \right) dy = 3 \left[\frac{y^8}{28} + \frac{y^8}{24} \right]_0^1 = \frac{3}{8}$$

Durch a,b ersetzen $\rightarrow 3 \int_0^1 \int_0^y x^{a+2} y^{b+2} + x^{a+1} y^{b+3} dx dy = 3 \int_0^1 \left[\frac{y^{b+2} x^{a+3}}{a+3} + \frac{y^{b+3} x^{a+2}}{a+2} \right]_0^y dy = \frac{3(2a+4)}{(a+3)(a+2)(a+1)}$ Formel für Erwartungswerte

$a=0, b=1 \rightarrow E(Y) = \frac{3 \cdot 1}{3 \cdot 2} = \frac{1}{2}$
 $a=1, b=0 \rightarrow E(X) = \frac{3 \cdot 1}{3 \cdot 2} = \frac{1}{2}$
 $a=0, b=2 \rightarrow E(Y^2) = \frac{3 \cdot 2}{3 \cdot 3} = \frac{2}{3}$
 $a=2, b=0 \rightarrow E(X^2) = \frac{3 \cdot 2}{3 \cdot 3} = \frac{2}{3}$

$V(X) = \frac{2}{3} - \left(\frac{1}{2}\right)^2 = \frac{8-3}{12} = \frac{5}{12}$
 $V(Y) = \frac{2}{3} - \left(\frac{1}{2}\right)^2 = \frac{8-3}{12} = \frac{5}{12}$
 $\text{Cov}(X,Y) = \frac{3}{8} - \frac{1}{2} \cdot \frac{1}{2} = \frac{3-2}{8} = \frac{1}{8}$
 $\rho = \frac{\frac{1}{8}}{\sqrt{\frac{5}{12} \cdot \frac{5}{12}}} = \frac{1}{5} = 0,2$

[BSP] $f(x,y) = c \cdot \frac{x}{y} \quad 0 < x < y < 1$

mit zweidimensionalen Dille ableiten

$X \sim B(n,p), E(X) = np \rightarrow V(X) ?$

uff ?? ↯ *

$$E(X^2) = \sum_{k=0}^n k^2 \binom{n}{k} p^k (1-p)^{n-k} = \sum_{k=0}^n k^2 \binom{n}{k} p^k (1-p)^{n-k} = \dots = np \sum_{k=0}^{n-1} k \binom{n-1}{k} p^k (1-p)^{n-1-k} =$$

$$= np \sum_{l=0}^{n-1} (l+1) \binom{n-1}{l} p^l (1-p)^{n-1-l} =$$

$$= np [(n-1)p + 1] = n^2 p^2 - np^2 + np$$

$$V(X) = E(X^2) - (E(X))^2 = n^2 p^2 - np^2 + np - np^2 = np(1-p)$$

* Trick für den Kauderwelsch: Indikatorvariable 0 oder 1

$$Y_i = \begin{cases} 1 & \text{iter Versuch = Erfolg} \\ 0 & \text{Misserfolg} \end{cases}$$

$$X = \sum_{i=1}^n Y_i$$

$$E(X) = \sum E(Y_i) = np$$

$$V(X) = \sum V(Y_i) = np(p-p^2)$$

↪ weil unabhängig!

Quantil:


(also p -Fraktion)

x_p heißt p -Quantil wenn $F_x(x_p - \theta) \leq p \leq F_x(x_p)$

$$P(x < x_p) \leq p \leq P(x < x_p)$$

Wahl des Praktikers: Mittelpunkt (Mittelwert) von kleinstem und größtem Quantil

Wahl des Mathematikers: linker Endpunkt (kleinster Wert)



Versuchen F_x umzukehren

x_p wenn $\exists! x_p : F_x(x_p) = p$

x wenn $F(x)$ über y springt ($\exists x : F_x(x) = y$)

kleinstes x wenn es mehr als ein x gibt für $F_x(x) = y$

verallgemeinerte Inverse: $F^{-1}(y) = \inf \{x : F(x) \geq y\} =$

Für welches m wird $f(m) = E(|x-m|)$ minimal?

solange: $f'(m) = 0 \quad \frac{d}{dm} E(|x-m|) = 0$

$$E\left(\frac{d}{dm} |x-m|\right) = E(\operatorname{sgn}(x-m) \cdot (-1)) = 0$$

$$= (-1) [P(x > m) - P(x < m)] \quad P(x = m) \cong 0$$

$$\Rightarrow P(x < m) = \frac{1}{2} \Rightarrow F_x(m) = \frac{1}{2}$$



Transformationsätze:

X Zufallsvariable (ein oder mehrdimensional)

Funktion $g: \mathbb{R} \rightarrow \mathbb{R}$ oder $\mathbb{R}^n \rightarrow \mathbb{R}$ oder $\mathbb{R}^n \rightarrow \mathbb{R}^n$

X diskret: mit möglichen Werten x_1, \dots, x_k --
möglichen Werte für $g(x)$ sind $g(x_1), g(x_2), \dots$
müssen nicht alle verschieden sein!

$$P_Y(y) = \mathbb{P}(Y=y) = \mathbb{P}(g(X)=y) = \sum_{x: g(x)=y} \mathbb{P}(X=x) = \sum_{x: g(x)=y} P_X(x)$$

BSP $U(0,1)$ Gleichverteilung
 $f(x) = x^a \quad g(x) = x^a \quad a > 0$
 $Y = g(X) = X^a$

$$F_Y(y) = F_Y^{-1}(y) = \begin{cases} \frac{1}{a} y^{\frac{1}{a}} + 0 & 0 \leq y < 1 \\ 0 & \text{sonst} \end{cases}$$

$$F_Y(y) = \mathbb{P}(Y \leq y) = \mathbb{P}(X^a \leq y) = \mathbb{P}(X \leq \sqrt[a]{y}) = y^{\frac{1}{a}} \quad \left. \begin{array}{l} 0: y < 0 \\ 0 \leq y < 1 \\ \mathbb{P}(X^a \leq y) = \mathbb{P}(X \leq \sqrt[a]{y}) = y^{\frac{1}{a}} \\ 1: y \geq 1 \end{array} \right\}$$

Allgemein: g umkehrbar $g' > 0$ oder $g' < 0$

2. Fall:

$Y = g(X) \quad X \sim f_X = f$ mögliche Werte für $y: \{g(x) : x \in \mathbb{R}\} =]g(\infty), g(-\infty)[$ Transformierte Zufallsvariable hat nur positive Werte

$$F_Y(y) = \mathbb{P}(Y \leq y) = \mathbb{P}(g(X) \leq y) = \mathbb{P}(X \geq g^{-1}(y)) = 1 - \mathbb{P}(X < g^{-1}(y)) = 1 - F_X(g^{-1}(y))$$

$$f_Y(y) = F_Y'(y) = -(g^{-1})'(y) \cdot f_X(g^{-1}(y)) = |g^{-1}'(y)| \cdot f_X(g^{-1}(y)) = \frac{1}{|g'(g^{-1}(y))|} \cdot f_X(g^{-1}(y)) \quad y \in g(\mathbb{R}) = \{g(x) : x \in \mathbb{R}\}$$

$$f_Y(y) = \left| \frac{d g^{-1}(y)}{d y} \right| \cdot f_X(g^{-1}(y)) \cdot [y \in g(\mathbb{R})] = \frac{1}{|d g(x)|} \cdot f_X(g^{-1}(y)) [y \in g(\mathbb{R})]$$

BSP $p(x) = e^{-x} \quad X \sim E(\lambda)$

$$f_X(x) = \begin{cases} \lambda e^{-x} & x > 0 \\ 0 & x < 0 \end{cases}$$

$$g^{-1}(y) = -\log(y) \quad \frac{d g^{-1}(y)}{d y} = -\frac{1}{y} \quad \frac{d g}{d x}(x) = -e^{-x}$$

$$f_Y(y) = \left| -\frac{1}{y} \right| \cdot \lambda e^{-(-\log y)} = \frac{1}{y} \cdot \lambda e^{\log y} = \lambda \cdot \frac{1}{y} = \lambda y^{-1}$$

$\begin{cases} y > 0 / -\log y > 0 & \log y < 0 \Rightarrow y e^0 = 1 \\ y \leq 1 & 0 \text{ weil } f_X(p^{-1}(y)) = 0 \\ y \leq 0 & 0 \text{ weil } p^{-1}(y) \text{ nicht definiert} \end{cases}$

BSP $X \sim N(0,1) \quad p(x) = x^2 \quad Y = X^2$

$$y > 0 \quad F_Y(y) = \mathbb{P}(Y \leq y) = \mathbb{P}(X^2 \leq y) = \mathbb{P}(|X| \leq \sqrt{y}) = \mathbb{P}(-\sqrt{y} \leq X \leq \sqrt{y}) = \Phi(\sqrt{y}) - \Phi(-\sqrt{y})$$

$$f_Y(y) = \frac{d}{d y} F_Y(y) = \frac{1}{2\sqrt{y}} \varphi(\sqrt{y}) + \frac{1}{2\sqrt{y}} \varphi(-\sqrt{y}) = \frac{1}{2\sqrt{y}} \frac{1}{\sqrt{2\pi}} e^{-\frac{(\sqrt{y})^2}{2}} + \frac{1}{2\sqrt{y}} \frac{1}{\sqrt{2\pi}} e^{-\frac{(-\sqrt{y})^2}{2}} = \frac{1}{2\sqrt{y}} e^{-\frac{y}{2}} + \frac{1}{2\sqrt{y}} e^{-\frac{y}{2}} = \frac{1}{\sqrt{2\pi y}} e^{-\frac{y}{2}} \quad y > 0 = \frac{y^{\frac{1}{2}-1} (\frac{1}{2})^{\frac{1}{2}}}{\Gamma(\frac{1}{2})} e^{-\frac{y}{2}}$$

\hookrightarrow Gamma-Verteilung mit $a = \frac{1}{2} \quad y = \frac{1}{2}$

$$f_Y(y) = \left| \frac{d g^{-1}(y)}{d y} \right| \cdot f_X(g^{-1}(y)) \cdot [y \in g(\mathbb{R})] = \frac{1}{|d g(x)|} \cdot f_X(g^{-1}(y)) [y \in g(\mathbb{R})] \quad (\text{Funktioniert genauso wenn } p: \mathbb{R}^n \rightarrow \mathbb{R}^n, g \text{ diff, umkehrbar})$$

$$g(x) = \begin{pmatrix} g_1(x_1, \dots, x_n) \\ g_2(x_1, \dots, x_n) \end{pmatrix} \rightarrow \frac{d g}{d x} = \begin{pmatrix} \frac{d g_1}{d x_1} & \dots & \frac{d g_1}{d x_n} \\ \frac{d g_2}{d x_1} & \dots & \frac{d g_2}{d x_n} \end{pmatrix}$$

Anwendung: Verteilung einer Summe X, Y gemeinsame Verteilung mit Dichte $f_{X,Y} \quad S = X+Y \quad T = X$

$$(s, t) = g(x, y) = (x+y, x)$$

$$g_1(x, y) = x+y$$

$$g_2(x, y) = x$$

$$g(x, y) = \begin{pmatrix} x+y \\ x \end{pmatrix}$$

$$g^{-1}(s, t) = (t, s-t)$$

$$\frac{d g^{-1}(s, t)}{d (s, t)} = \begin{vmatrix} \frac{d t}{d s} & \frac{d t}{d t} \\ \frac{d (s-t)}{d s} & \frac{d (s-t)}{d t} \end{vmatrix} = \begin{vmatrix} 0 & 1 \\ 1 & -1 \end{vmatrix} = -1$$

$$f_{S,T} = |-1| \cdot f_{X,Y}(g^{-1}(s, t)) = f_{X,Y}(t, s-t)$$

$$\text{Dichte von } S: \text{Randdichte } f_S(s) = \int_{-\infty}^{\infty} f_{S,T}(s, t) dt = \int_{-\infty}^{\infty} f_{X,Y}(t, s-t) dt$$

$$X \text{ und } Y \text{ unabhängig: } f_{X,Y}(x, y) = f_X(x) \cdot f_Y(y) \quad f_S(s) = \int_{-\infty}^{\infty} f_X(t) f_Y(s-t) dt = \int_{-\infty}^{\infty} f_X * f_Y(z) dz$$

$\xrightarrow{\text{Faltung!}}$

im Diskreten: X, Y sind diskret $S = X+Y$

$$P_S(s) = P(S=s) = P(X+Y=s) = \sum_x P(X=x, Y=s-x) = \sum_x P_X(x) P_Y(s-x) \quad \text{statt } x=t \rightarrow \text{von stetig in Diskret}$$

wenn X, Y unabhängig

$$P_S(s) = \sum_x P_X(x) P_Y(s-x) = P_X * P_Y(s) \quad \text{diskrete Faltung!}$$

Transformationsformel

$$\gamma: \mathbb{R}^n \rightarrow \mathbb{R}^n \quad f_{\gamma \circ \gamma^{-1}}(\gamma) = \begin{cases} f_X(\gamma^{-1}(\gamma)) \left| \frac{\partial \gamma^{-1}}{\partial \gamma}(\gamma) \right| & \gamma \in \text{Im}(\gamma) \\ 0 & \text{sonst (wobei } \exists x \in \mathbb{R}^n \rightarrow \gamma(x)) \end{cases}$$

X und Y unabhängig und stetig

$$f_{X+Y}(t) = \int_{-\infty}^{\infty} f_X(x) f_Y(t-x) dx = f_X * f_Y \quad \text{Faltung}$$

$$f_{\frac{X}{Y}}(z) = \int_{-\infty}^{\infty} |y| f_Y(y) \cdot f_X(z \cdot y) dy =$$

Hinweis:
 $f_{(X,Y)} = f_{(Y,X)}$

BSP $X, Y \sim E(\lambda)$ unabhängig

$$S = X+Y$$

$$Q = X/Y$$

$$f_X(x) = f_Y(x) = \lambda e^{-\lambda x} \quad [x \geq 0]$$

$$f_S(z) = f_X * f_Y(z) = \int_{-\infty}^{\infty} f_X(x) f_Y(z-x) dx = \int_0^z \lambda e^{-\lambda x} \cdot \lambda e^{-\lambda(z-x)} dx = \lambda^2 e^{-\lambda z} \int_0^z dx = \begin{cases} z \geq 0: \lambda^2 z e^{-\lambda z} \\ z < 0: 0 \end{cases}$$

$$f_{\frac{X}{Y}}(z) = \begin{cases} z \geq 0: \int_{-\infty}^{\infty} |y| f_Y(y) \cdot f_X(z \cdot y) dy = \int_0^{\infty} |y| \lambda^2 e^{-\lambda y(1+z)} dy = \int_0^{\infty} \frac{u e^{-\lambda u}}{(1+z)^2} du = \frac{1}{(1+z)^2} \\ z < 0: 0 \end{cases}$$

man kann Verteilungen transformieren.

$$g(X, Y) = (X+Y, \frac{X}{Y}), \quad g^{-1}(s, q) = (s, s/q) \quad s = X+Y = Y(1+q)$$

$$Y = \frac{s}{1+q}$$

$$X = \frac{sq}{1+q}$$

$$\text{Funktionaldeterminante: } \begin{vmatrix} \frac{\partial s}{\partial x} & \frac{\partial s}{\partial y} \\ \frac{\partial q}{\partial x} & \frac{\partial q}{\partial y} \end{vmatrix} = \begin{vmatrix} 1 & 1 \\ \frac{s}{(1+q)^2} & -\frac{s}{(1+q)^2} \end{vmatrix} = -\frac{sq}{(1+q)^2} - \frac{s}{(1+q)^2} = -\frac{s}{(1+q)^2}$$

$$f_{S,Q}(s,q) = f_X\left(\frac{sq}{1+q}\right) f_Y\left(\frac{s}{1+q}\right) \left| -\frac{s}{(1+q)^2} \right| = \lambda e^{-\lambda \frac{sq}{1+q}} \cdot \lambda e^{-\lambda \frac{s}{1+q}} \cdot \frac{s}{(1+q)^2}$$

$$= s \lambda^2 e^{-\lambda s} \frac{1}{(1+q)^2} \quad s \geq 0 \quad q \geq 0 \quad \Rightarrow s, q \text{ unabhängig}$$

Multivariate Verteilung mit Namen: (Anwendung der Transformationsformel)

1, Multinomialverteilung (diskret, verallg. von Binomial): n Versuche mit Ausgängen $1, \dots, k$

$k=2$ Binomialverteilung

$(X_1 \dots X_k)$ Ergebnis X_i ... # Ausgänge i Wahrscheinlichkeiten $p_1 \dots p_k$

$$P_A(x) = P_{X_1 \dots X_k}(x_1 \dots x_k) = \begin{cases} \frac{n!}{x_1! x_2! \dots x_k!} p_1^{x_1} p_2^{x_2} \dots p_k^{x_k} & x_i \geq 0, x_1 + \dots + x_k = n \\ 0 & \text{sonst} \end{cases}$$

2, Normalverteilung (stetig) $N(0, 1)$

$Y_1 \dots Y_n$ unabhängig \rightarrow (aufschreiben als Zeilenvektoren)

$$f_Y(y) = f_{Y_1 \dots Y_n}(y_1 \dots y_n) = \prod \frac{1}{\sqrt{2\pi}} e^{-\frac{y_i^2}{2}} = \frac{1}{(\sqrt{2\pi})^n} e^{-\frac{\sum y_i^2}{2}} = \frac{1}{(\sqrt{2\pi})^n} e^{-\frac{y^T y}{2}}$$

$$X = AY + b \quad A \in \mathbb{R}^{n \times n}, b \in \mathbb{R}^n$$

A regulär: $g(x) = Ax + b$

$$\text{umkehrbar: } g^{-1}(y) = A^{-1}(y - b)$$

$N(b, \Sigma)$

Dichte einer multiv. Norm v.

$$f_Y(y) = \int_X (A^{-1}(y-b) | \det(A^{-1}) |) = \frac{1}{(\sqrt{2\pi})^n} e^{-\frac{(y-b)^T (A^T)^{-1} A^{-1} (y-b)}{2}} \frac{1}{|\det(A)|} = \frac{1}{(\sqrt{2\pi})^n} e^{-\frac{(y-b)^T (AA^T)^{-1} (y-b)}{2}} \frac{1}{|\det(A)|} = \frac{1}{(\sqrt{2\pi})^n \det(\Sigma)} e^{-\frac{(y-b)^T \Sigma^{-1} (y-b)}{2}}$$

$$\Sigma = AA^T \quad \det \Sigma = \det(AA^T) = \det(A) \det(A^T) = (\det(A))^2$$

b ... Mittelwert, Σ Kovarianzmatrix

gemeinsame Normalverteilung, unabhängig wenn Kovarianz = \emptyset !

statt y jetzt $x \rightarrow$ Spaltenvektoren

$$f_X(x) = f_{X_1 \dots X_n}(x_1 \dots x_n) = \prod \frac{1}{\sqrt{2\pi}} e^{-\frac{x_i^2}{2}} = \frac{1}{(\sqrt{2\pi})^n} e^{-\frac{\sum x_i^2}{2}} = \frac{1}{(\sqrt{2\pi})^n} e^{-\frac{x^T x}{2}}$$

$Y = AX + b \quad A \in \mathbb{R}^{n \times n}, b \in \mathbb{R}^n$
 A regulär $g(x) = Ax + b$
 umkehrbar $g^{-1}(y) = A^{-1}(y - b)$



Momente

- n-tes Moment von X $M_n = \mathbb{E}(X^n)$
- n-tes zentriertes Moment $m_n = (\mathbb{E}(X - \mathbb{E}(X))^n)$
- n-tes absolutes Moment $\mathbb{E}(|X|^n)$
- n-te absolute zentrale Moment

3. Moment: $m_3 = \frac{m_3}{1(V(x))^3} = \frac{\mathbb{E}((X - \mathbb{E}(X))^3)}{(\mathbb{E}((X - \mathbb{E}(X))^2))^3}$

4. Moment: $k = \frac{m_4}{V(x)^2} - 3$

Wahrscheinlichkeitserzeugende Funktion $\rightarrow X$ diskret (nicht negativ, ganzzahlig)

$$\mathbb{E}(z^X) = \sum_{x=0}^{\infty} z^x P(X=x) = \sum_{x=0}^{\infty} z^x p_X(x) \quad (\text{geht für } |z| \leq 1)$$

Sidonak: $(a_n)_{n \geq 0} \sum_{n=0}^{\infty} a_n z^n$ Erzeugende Funktion, $\hat{=}$ Transformierte $a_n = \frac{g^{(n)}(0)}{n!}$

$$g'(1) = \sum_{x=0}^{\infty} x z^{x-1} p_X(x) \Big|_{z=1} = \sum_{x=0}^{\infty} x p_X(x) = \mathbb{E}(X)$$

Faktorielles Moment $g''(1) = \mathbb{E}(X(X-1))$

n Faktorielles Moment: $g^{(n)}(1) = \mathbb{E}(X!)$?

$X \sim p_X$ $Y \sim p_Y$ unabhängig $\Rightarrow X+Y \sim p_X * p_Y$

$$g_X(z) = \sum_{n=0}^{\infty} p_X(n) z^n = \mathbb{E}(z^X)$$

$$g_Y(z) = \sum_{n=0}^{\infty} p_Y(n) z^n = \mathbb{E}(z^Y)$$

$$g_{X+Y}(z) = \mathbb{E}(z^{X+Y}) = \mathbb{E}(z^X \cdot z^Y) = \mathbb{E}(z^X) \cdot \mathbb{E}(z^Y) = g_X(z) \cdot g_Y(z)$$

exponentielles Moment: $M_X(t) = \mathbb{E}(e^{tx})$ geht für stetige und diskrete Zufallsvariablen (WENN es geht!) Cauchy Verteilung $\hat{=}$ für $X > 0, t < \theta$

$$L_X(t) = M_X(-t) = \mathbb{E}(e^{-tx}) = \int_0^{\infty} f_X(x) e^{-tx} dx \quad \text{wenn } x \text{ stetig}$$

Laplace-Transformierte

Momentenerzeugende Funktion:

$$M_X(t) = \mathbb{E}\left(\sum_{n=0}^{\infty} \frac{x^n t^n}{n!}\right) = \sum_{n=0}^{\infty} \frac{t^n \mathbb{E}(x^n)}{n!} = \sum_{n=0}^{\infty} \frac{M_n t^n}{n!}$$

$$e^{xt} = \sum_{n=0}^{\infty} \frac{x^n t^n}{n!}$$

erzeugende Funktion für Momente

$$M_n = \mathbb{E}(X^n) = M_X^{(n)}(0) \quad \text{"nulltes Moment" = 1}$$

Charakteristische Funktion (der Verteilung von x)

\hookrightarrow Lept. Verteilung eindeutig fest!

$$|e^{ixt}| = |\cos(Xt) + i \sin(Xt)| = 1$$

$$\varphi_X(t) = \mathbb{E}(e^{ixt}) = \mathbb{E}(\cos(Xt)) + i \mathbb{E}(\sin(Xt))$$

BSP Poissonverteilung $p_X(x) = \frac{\lambda^x}{x!} e^{-\lambda}$

$$g_X(t) = \sum \frac{\lambda^x}{x!} e^{-\lambda} = e^{-\lambda} \sum \frac{\lambda^x}{x!} = e^{-\lambda} e^{\lambda} = 1$$

$$M_X(e^t) = e^{\lambda(e^t - 1)} \quad \text{char. fun.:} \quad \varphi_X(t) = M_X(it) = e^{\lambda(e^{it} - 1)}$$

BSP $N(0,1)$

$$M_X(t) = \int_{-\infty}^{\infty} e^{xt} \cdot \frac{1}{\sqrt{2\pi}} e^{-\frac{x^2}{2}} dx = \int_{-\infty}^{\infty} \frac{1}{\sqrt{2\pi}} e^{-\frac{x^2 - 2xt}{2}} dx = \int_{-\infty}^{\infty} \frac{1}{\sqrt{2\pi}} e^{-\frac{(x-t)^2 - t^2}{2}} dx = e^{\frac{t^2}{2}} \int_{-\infty}^{\infty} \frac{1}{\sqrt{2\pi}} e^{-\frac{(x-t)^2}{2}} dx = e^{\frac{t^2}{2}} \quad \text{als Momentenerzeugende}$$

$$\varphi_X(t) = M_X(it) = e^{\frac{(it)^2}{2}} = e^{-\frac{t^2}{2}}$$

Inversenmethode:

Möglichkeit, Zufallszahlen mit beliebigen Verteilungen zu erzeugen.

X stetig, streng Monoton ($f'_X > 0$), F_X umkehrbar

$$U = F_X(X) \in [0,1]$$

$$0 < u < 1: \mathbb{P}(u \leq U) = \mathbb{P}(F_X(X) \leq u) = \mathbb{P}(X \leq F_X^{-1}(u)) = F_X(F_X^{-1}(u)) = u$$

$$U = F_X(X) \sim U(0,1) \quad \text{"u ist gleichverteilt auf } [0,1]\text{"}$$

$$X = F_X^{-1}(U)$$

Wenn F eine stetige, streng monotone Verteilungsfunktion ist dann

1, X nach F verteilt, dann X gleichverteilt auf $[0,1]$

$$F(X) \sim U(0,1)$$

geht noch allgemeiner: nur stetig ✓

2, wenn U auf $[0,1]$ gleichverteilt, dann

$$U \sim U(0,1) \Rightarrow F^{-1}(U) \sim F$$

$$\text{weil: } \mathbb{P}(X \leq x) = \mathbb{P}(F^{-1}(U) \leq x) = \mathbb{P}(U \leq F(x)) = F(x)$$

Normalverteilte Zufallsvariablen -
→ in inv. Norm. vert. einsetzen

Binomial geht auch (obwohl nicht integrierbar)
↳ verallgemeinerte Inverse

BSP Exponentialverteilung

$$F(x) = 1 - e^{-\lambda x}$$

$$F^{-1}(y) = -\frac{1}{\lambda} \log(1-y)$$

$$X = F^{-1}(U) = -\frac{1}{\lambda} \log(1-U) \sim E(\lambda)$$

$$\text{keine Verbesserung } X = -\frac{1}{\lambda} \log(U)$$

$$U = \frac{\text{randn}() + 0.5}{\text{RAND_MAX} + 1.01}$$

$$x_1, u_2 \quad x_1 = \sqrt{-2 \log u_1} \cos(2\pi u_2)$$


$$x_2 = \sqrt{-2 \log u_2} \cos(2\pi u_1)$$

Annahme - Verwerfungsmethode

$$a \leq X \leq b$$

Dichte $f_X = 0$ für $x < a$, $x > b$

$$F(x) = \int_a^x f(u) du$$



$U \sim U(a, b)$ $Y > f(x) \rightarrow$ war nix weg werfen neu versuchen

$X \sim U(0, H)$ $Y \leq f(x) \rightarrow X$ Zufallszahl \rightarrow passiert mit Wahrscheinlichkeit



$$\frac{\int_a^x f(u) du}{H(b-a)} = \frac{1}{H(b-a)}$$

Ziggorat Methode

\downarrow
Babylonische Tüme

Dichte auf $x \geq 0$ fallend

Wähle h so, dass möglichst jedes \square Fläche A hat; stelle δ so ein, dass sich oberes Rechteck genau ausfüllt und 2ⁿ Stufen entstehen
(auch für Normalverteilung)





Gesetz der großen Zahlen

(X_1, \dots, X_n) Folge von Zufallsvariablen, unabhängig, identisch verteilt

F_X Verteilungsfunktion

Erwartungswert: $E(X) = E(X_n) = \mu$

Varianz: $V(X) = \sigma^2$

Stichprobenmittel: $\bar{X}_n = \frac{X_1 + \dots + X_n}{n} \rightarrow \mu$ wenn $n \rightarrow \infty$, wie soll diese Konvergenz verstanden werden?

Möglichkeiten der Konvergenzdefinition: Y_n, Y sind Zufallsvariablen

1) $Y_n \rightarrow Y$ in Wahrscheinlichkeit, wenn $\forall \epsilon > 0 : \lim_{n \rightarrow \infty} P(|Y_n - Y| > \epsilon) = 0$

2) $Y_n \rightarrow Y$ mit Wahrscheinlichkeit 1 wenn $P(Y_n \neq Y) = P(|Y_n - Y| > \epsilon) = 0$ ∞ oft

$Z_k \sim D(1, 2^k)$ $k = 0, 1, \dots$

$\begin{cases} Y = 1 & \text{wenn } 2^k + 2^k \\ Y_n = 0 & \text{sonst} \end{cases}$

$2 < n \leq 2^{k+1} : P(Y_n = 1) = \frac{1}{2^k}$

nur für 1 Fall gleiches ???

Wenn $\sum P(|Y_n - Y| > \epsilon) < \infty$ für alle $\epsilon > 0$, dann konvergiert es mit WSK 1.

3) $Y_n \rightarrow Y$ konvergieren im Quadratmittel, wenn $E((Y_n - Y)^2) \rightarrow 0$

Schwaches Gesetz der Großen Zahlen

X_n unabhängig, identisch verteilt, $\bar{X}_n \rightarrow \mu$ in WSK, $E(X_n) = \mu$, $V(X_n) = \sigma^2$

1) Markov: $Y \geq 0$ $c > 0$

$P(Y \geq c) \leq \frac{E(Y)}{c}$

Bew: $Z = \begin{cases} c & Y \geq c \\ 0 & \text{sonst} \end{cases} \quad Z \leq Y : E(Z) \leq E(Y)$

2) Chebychev:

$P(|Y - E(Y)| \geq c) \leq \frac{V(Y)}{c^2}$

$P(\frac{(Y - E(Y))^2}{2} \geq c) \leq \frac{E(\frac{(Y - E(Y))^2}{2})}{c} = \frac{E((Y - E(Y))^2)}{2c} = \frac{V(Y)}{c^2}$

$E(\bar{X}_n) = E(\frac{1}{n}(X_1 + \dots + X_n)) = \frac{1}{n} E(X_1 + \dots + X_n) = \frac{1}{n} [E(X_1) + \dots + E(X_n)] = \frac{n \cdot \mu}{n} = \mu$ The mean of the mean is the mean (?)

$V(\bar{X}_n) = V(\frac{1}{n}(X_1 + \dots + X_n)) = \frac{1}{n^2} V(X_1 + \dots + X_n) = \frac{1}{n^2} [V(X_1) + \dots + V(X_n)] = \frac{1}{n^2} \cdot n \cdot \sigma^2 = \frac{\sigma^2}{n}$

Kann man Chebychev an

$P(\underbrace{|\bar{X}_n - \mu|}_{E(\bar{X}_n)} \geq \epsilon) \leq \frac{V(\bar{X}_n)}{\epsilon^2} = \frac{\sigma^2}{n \cdot \epsilon^2} \rightarrow 0$

Es wurde gezeigt: 1) $\bar{X}_n \rightarrow \mu$ im Quadratmittel (immer stärkere Versionen)

2) es genügt (X_n) unkorreliert (Voraussetzung aufzuweisen)



Starkes Gesetz der großen Zahlen

Selbe Voraussetzungen wie vorher, dann $\bar{x}_n \rightarrow \mu$ mit WSK 1

Simulation od. Stichprobenmittel:

möchte $E(X)$ berechnen, erzeugt n unabhängige Zufallszahlen $X_1 \dots X_n$ mit selber Verteilung wie X

\bar{X}_n als Näherungswert für $E(X)$

Etwas allgemeiner $\frac{g(X_1) + \dots + g(X_n)}{n} \rightarrow E(g(X))$

UE: wenn $X \sim f$ $E(g(X)) = \int_{-\infty}^{\infty} g(x) f(x) dx \approx \frac{1}{n} \sum_{i=1}^n g(x_i)$

$X \sim U[0,1]$: $\int_0^1 g(x) dx \approx \frac{1}{n} \sum_{i=1}^n g(x_i)$

Problem: Genauigkeit?

Wöchte $\frac{1}{n} \sum_{i=1}^n g(X_i)$

$|\frac{1}{n} \sum_{i=1}^n Y_i - E(Y)| < \delta$

$\delta = \frac{0.01}{0.005}$ für 2 Dezimalstellen

Fehlerstranke kann nur mit gewisser Wahrscheinlichkeit garantiert werden!

$P(|\frac{1}{n} \sum Y_i - E(Y)| \leq \delta) \geq 1 - \epsilon$

δ ... Fehlerstranke
 ϵ ... (kleine) Wahrscheinlichkeit für einen großen Fehler

$P(|\bar{Y}_n - E(Y)| \leq \delta) \leq \epsilon$ Wie kann das erreicht werden?

1) Chebyshev: $P(|\bar{Y}_n - E(Y)| \geq \delta) = P(|\bar{Y}_n - E(\bar{Y}_n)| \geq \delta) = \frac{V(\bar{Y}_n)}{\delta^2} = \frac{V(Y)}{n \cdot \delta^2}$

$n = \frac{V(Y)}{\epsilon \delta^2}$

$\delta = \sqrt{\frac{V(Y)}{n \epsilon}} \begin{cases} O(\frac{1}{\sqrt{n}}) \\ O(\frac{1}{\sqrt{n}}) \end{cases}$

Wie groß ist Fehler wenn ich gewisse # von Versuchen mache?
nach δ umformen

$\int_0^1 \int_0^1 \dots \int_0^1 f(x_1, \dots, x_{20}) dx_1 \dots dx_{20} = E(f(U_1, \dots, U_{20})) \approx \frac{1}{n} \sum (f(U_{20i+1}, \dots, U_{20i+20}))$

ziemlich pessimistisch: Abhängig von Irrtumswahrscheinlichkeit ϵ

daher

Bessere Näherung

2) Zentraler Grenzwertsatz (ZGWS)

$(X_1 \dots X_n)$ unabhängig, identisch verteilt

$S_n = X_1 + \dots + X_n$
 $\bar{X}_n = \frac{X_1 + \dots + X_n}{n}$

ist näherungsweise

normal verteilt

$\begin{cases} N(\mu, \sigma^2) \\ N(\mu, \frac{\sigma^2}{n}) \end{cases}$

$P(\frac{S_n - n\mu}{\sqrt{n}\sigma} \leq x) \rightarrow \Phi(x) = \int_{-\infty}^x \frac{1}{\sqrt{2\pi}} e^{-\frac{u^2}{2}} du$

$E(X_n) = \mu$
 $V(X_n) = \sigma^2$

allgemein: standardisieren: $E(X) = \mu$ $V(X) = \sigma^2$

zentrieren: $E(X) = 0$ $i = X - E(X)$

normiert $E(X) = 1$ $V(X) = 1$

$z = \frac{X - \mu}{\sigma} = \frac{X - E(X)}{\sqrt{V(X)}}$

Grenzwertsatz - Spezial

De Moivre - Laplace: $X \sim B(n, p)$
 $P(X=x) \approx \frac{1}{\sqrt{2\pi np(1-p)}} e^{-\frac{(x-np)^2}{2np(1-p)}}$

wenn $|x-np| \leq C \cdot \sqrt{n}$

linke Seite $\rightarrow 1$
rechte Seite

Grenzwertsatz (X_n) unabh., identisch verteilt

$E(X_n) = \mu$
 $V(X_n) = \sigma^2$ ($> 0, < \infty$)

$S_n = (X_1 + \dots + X_n) \approx N(n\mu, n\sigma^2)$



BSP Simulation

$$\bar{I} = \int_0^1 g(x) dx \rightarrow \int_0^1 (1-x^2) dx \quad \text{Integral durch Näherung ersetzen: } I_n = \frac{1}{n} \sum_{i=1}^n g(u_i) = \frac{1}{n} \sum (1-u_i)$$

Genauigkeit gegeben! → gebe WSK α (die sehr klein ist) und eine Genauigkeit δ (auch klein) vor, sodass die WSK einen Fehler $> \delta$ zu erhalten, soll $\geq \alpha$ sein. Wie groß muss n sein? # der Versuche

Chebyshev: Sicher, aber zu pessimistisch: $n = \frac{V(g(u))}{\alpha \cdot \delta^2}$ $\alpha = 0.01$ $\delta = 0.01$ $V(g(u))$ ist aber nicht so leicht zu berechnen.
 2 GWS: $I_n = \frac{1}{n} \sum g(u_i) \approx N(I, \frac{1}{n} V(g(u))) = E(g(u)) = \int_0^1 g(x) dx$
 Abszisse \downarrow 2 GWS

$$P(|I_n - I| \leq \delta) = 1 - \alpha \rightarrow P(-\delta \leq I_n - I \leq \delta) = P\left(\frac{-\delta}{\sqrt{\frac{1}{n} V(g(u))}} \leq \frac{I_n - I}{\sqrt{\frac{1}{n} V(g(u))}} \leq \frac{\delta}{\sqrt{\frac{1}{n} V(g(u))}}\right) = \Phi\left(\frac{\delta}{\sqrt{\frac{1}{n} V(g(u))}}\right) - \Phi\left(-\frac{\delta}{\sqrt{\frac{1}{n} V(g(u))}}\right) = 2\Phi\left(\frac{\delta}{\sqrt{\frac{1}{n} V(g(u))}}\right) - 1$$

$$> n = \frac{z_{1-\frac{\alpha}{2}}^2 \cdot \sigma^2}{\delta^2}$$

$z_{1-\frac{\alpha}{2}} = z_{0.995} = 2.576$ $z_{1-\frac{\alpha}{2}}^2 \approx 6.64$

spezialfall: de Moivre-Laplace: $X \sim B(n, p)$

$$P(X=x) \approx \frac{1}{\sqrt{2\pi np(1-p)}} e^{-\frac{(x-np)^2}{2np(1-p)}} \cdot \binom{n}{x} p^x (1-p)^{n-x}$$

] Dichte einer Normalverteilung mit $\mu=np$ $\sigma^2=np(1-p)$
 ($x-np$ in Großbuchstaben μ)

S

Beweis: 1, Stirlingformel $n! \approx \sqrt{2\pi n} \left(\frac{n}{e}\right)^n$

$$2) \frac{P(X=x+1)}{P(X=x)} = \dots = \frac{\binom{n}{x+1} p^{x+1} (1-p)^{n-x-1}}{\binom{n}{x} p^x (1-p)^{n-x}} = \frac{n!}{(x+1)! (n-x-1)!} \cdot \frac{p^{x+1} (1-p)^{n-x-1}}{p^x (1-p)^{n-x}} = \frac{n!}{(x+1)! (n-x-1)!} \cdot \frac{p(1-p)^{-1}}{1} = \frac{n!}{(x+1)! (n-x-1)!} \cdot \frac{p}{1-p}$$

Beweis für zentralen Grenzwertsatz: Momentenerzeugende für $N(0,1)$

$$M(t) = E(e^{xt}) = e^{\frac{t^2}{2}}$$

Charakteristische Funktion $\varphi(t) = E(e^{ixt}) = M(it) = e^{-\frac{t^2}{2}}$

$$\frac{\sum_{i=1}^n x_i - n\mu}{\sqrt{n \cdot \sigma^2}} = \frac{\sum_{i=1}^n x_i - n\mu}{\sqrt{n \cdot \sigma^2}} = \frac{1}{\sqrt{n}} \sum_{i=1}^n \frac{x_i - \mu}{\frac{\sigma}{\sqrt{n}}}$$

$E(Y_i) = 0$ $V(Y_i) = 1$ $E\left(e^{\frac{it}{\sqrt{n}} (x_1 + \dots + x_n)}\right) = E\left(e^{\frac{it}{\sqrt{n}} x_1} \dots e^{\frac{it}{\sqrt{n}} x_n}\right) \rightarrow E\left(e^{\frac{it}{\sqrt{n}} x_1}\right)^n = \left(1 - \frac{t^2}{2n} + o\left(\frac{1}{n}\right)\right)^n \rightarrow E\left(e^{\frac{it}{\sqrt{n}} x_1}\right) = 1 + \frac{it}{\sqrt{n}} E(x_1) + \frac{1}{2} \frac{t^2}{n} E(x_1^2) + o\left(\frac{1}{n}\right) = 1 - \frac{t^2}{2n} + o\left(\frac{1}{n}\right)$

BSP Würfel wird 2000 x geworfen

$$P(X \leq 350) \approx \Phi\left(\frac{350 - \frac{2000}{6}}{\sqrt{2000 \cdot \frac{1}{6} \cdot \frac{5}{6}}}\right) = \Phi\left(\frac{2100 - 2000}{\sqrt{100000}}\right) = \Phi(1) = 0.841$$

$$P(X < 351) \approx \Phi(1.06) = 0.855$$

Stetigkeitskorrektur: X diskret durch Normalverteilung ^{ganzzahlige} approximiert.

verwende $P(X \leq x) = P(X \leq x + 0.5)$

$$P(X < x) = P(X < x - 0.5)$$

gute Schätzung für Varianz: Beginne mit n (moderat groß, zw. 100 und 1000)

$$I_n = \frac{1}{n} \sum g(u_i)$$

I_n Schätzwert für Integral/Erwartungswert

genau: In jedem Schritt prüfen

$$Q_n = \frac{1}{n} \sum g(u_i)^2$$

$Q_n - I_n^2$ Schätzwert für Varianz

WE DONE YET?



NO!



Statistik

Wir beschäftigen uns mit **mathematischer Statistik**

Gegensatz: Beschreibende Statistiken (fasst große Datenmengen übersichtlich zusammen)
Histogramme, Torten, ...

BSP Wahlumfrage — maove Partei: Wie groß ist Wähleranteil?

einen von N Wahlberechtigten auswählen (zufällig)

$$X = \begin{cases} 1 & \text{ja, es wählt diese Partei} \\ 0 & \text{nein} \end{cases}$$

$$P(X=1) = p$$

$$P(X=0) = 1-p$$

$$n \text{ Versuche} \quad \hat{p}_n = \bar{X}_n = \frac{\# \text{ ja-Antworten}}{n}$$

unabhängig (mit zurücklegen): mathematisch besser zu berechnen \rightarrow Binomialverteilung: $V = \frac{p(1-p)}{n} \rightarrow$ pessimistisch

bzw. ohne zurücklegen: praktisch besser (bei destruktiver Prüfung einziger Weg) \rightarrow Hypergeometrische Verteilung: $\sigma^2 = \frac{p(1-p)}{n} \cdot \frac{N-n}{N-1} < 1 \rightarrow$ besser!

Statistisches Modell: Menge \mathcal{P} von Verteilungen, welche das Problem beschreiben können

parametrisches Modell: Es gibt endlich viele reelle Zahlen, die die Verteilung festlegen (Parameter)

Aussagen einfacher, schärfer zu erreichen, aber **ACHTUNG**: komplett falsch, wenn Verteilung falsch

BSP: Alternativ (Wahl), Normal (Größe, Gewicht), oder keine Einschränkungen

nicht parametrisches Modell: unendlich viele Dimensionen, Chancen für falsches Modell gering, Aussagen unscharf

Stichprobe: Folge (X_1, \dots, X_n) von unabhängig identisch verteilten Zufallsvariablen mit einer unbekanntem Verteilung $p \in \mathcal{P}$
(ziehen mit zurücklegen)

↓
Stichprobenumfang: n

Aufgabe der schließenden Statistik: Aus der Stichprobe Aussagen über die unbekanntem Verteilung \mathcal{P} erhalten.

Parametrisches Modell: kann durch endlich viele reelle Parameter festgelegt werden.

$$(P_{\theta}, \theta \in \Theta) \quad \text{für} \quad \Theta \subseteq \mathbb{R}^k \quad \text{mit} \quad \Theta = (\theta_1, \dots, \theta_k) \quad \text{wobei} \quad k \dots \text{reeller Parameter}$$

Wahlumfrage / Alternativverteilung: $k=1 \quad \Theta = [0, 1]$

Normalverteilung: $k=2 \quad (\mu = \theta_1, \sigma^2 = \theta_2) \quad \Theta = \mathbb{R} \times \mathbb{R}^k$

Gleichverteilung: $U([0, \theta]) : \Theta = \mathbb{R}^+$

Gleichverteilung: $U(\theta_1, \theta_2)$

Statistik $T = T(x_1, \dots, x_n)$ Zufallsvariable, die Funktion (der Werte) in der Stichprobe ist.

GRUNDAUFGABEN der Statistik

- 1, Schätzproblem: einen Schätzwert für Parameter oder Funktion des Parameters aus der Stichprobe
- 2, Testproblem: gut/schlecht bzw ja/nein Entscheidungen aus Stichprobe Bier 500 cm³/Flasche 497 cm³ Mittel als Stichprobe
- 3, Prognoseproblem: untersuche Vergangenheit (Stichprobe) suche Parameter der Verteilung in der Zukunft

1, Schätzung

Schätzwert $\hat{\theta}$ für unbekanntem Parameter θ

Schätzer ist eine Folge $(\hat{\theta}_n)$ von Statistiken $\hat{\theta}_n = \hat{\theta}_n(x_1, \dots, x_n)$

mit Index versehen, weil von Stelle die Verteilung abhängt!

Eigenschaften von Schätzern:

konsistenz: $\hat{\theta}_n \rightarrow \theta$ ($n \rightarrow \infty$) $\hat{\theta}_n$ ist konsistent für θ

• Schwache Konsistenz: Ein Schätzer heißt schwach konsistent, wenn $\hat{\theta}_n \rightarrow \theta$ Wahrscheinlichkeit $P(|\hat{\theta}_n - \theta| > \varepsilon) \rightarrow 0$ für $n \rightarrow \infty$

• starke Konsistenz: Ein Schätzer heißt stark konsistent, wenn $\hat{\theta}_n \rightarrow \theta$ mit Wahrscheinlichkeit 1

Erwartungswert $E_{\theta}(\hat{\theta}_n) = \theta$ (muss $\forall \theta$ gelten!)

• unverzerrt: Ein Schätzer heißt erwartungstreu, wenn $E_{\theta}(\hat{\theta}_n) = \theta$

• asymptotisch unverzerrt: $\lim_{n \rightarrow \infty} E_{\theta}(\hat{\theta}_n) = \theta$

• Verzerrung von $\hat{\theta}_n$: $E_{\theta}(\hat{\theta}_n) - \theta$

nah Stein: Varianz θ Fehler + Quadrat der Verzerrung

Varianz $\hat{\theta}_n$ ist erwartungstreu, dann $V_{\theta}(\hat{\theta}_n) = E_{\theta}((\hat{\theta}_n - E_{\theta}(\hat{\theta}_n))^2) = E_{\theta}((\hat{\theta}_n - \theta)^2)$

MSE (mean square error), mittlerer quadratischer Fehler: $E_{\theta}((\hat{\theta}_n - \theta)^2)$

Ein Schätzer $\hat{\theta}_n$ heißt **effizient**, wenn er **erwartungstreu** ist und die **kleinste Varianz** von allen erwartungstreuen Schätzern hat.

$\hat{\theta}_n$ ist effizient wenn 1) $E_{\theta}(\hat{\theta}_n) = \theta \quad \forall \theta \in \Theta$

2) für jeden erwartungstreuen Schätzer $\tilde{\theta}_n$ gilt: $V_{\theta}(\hat{\theta}_n) \leq V_{\theta}(\tilde{\theta}_n) \quad \forall \theta$

Wenn $\hat{\theta}_n, \tilde{\theta}_n$ beide erwartungstreu sind und $V_{\theta}(\hat{\theta}_n) \leq V_{\theta}(\tilde{\theta}_n)$ dann heißt $\hat{\theta}_n$ effizienter als $\tilde{\theta}_n$

wenn man lineare Schätzer betrachtet $\hat{\theta}_n = \sum_{i=1}^n a_i x_i$

wenn man lineare Schätzer betrachtet: $\hat{\theta}_n = \sum a_i x_i + \beta$

BLUE: Best Linear Unbiased Estimator

Stichprobenvarianz $S_n = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x}_n)^2$ (aka $\hat{\sigma}_n^2 \dots$)

BSP \bar{X}_n ist erwartungstreu, stark konsistenter Schätzer für $E(X)$

(X_1, X_2, \dots, X_n) sind unabhängig, erwartungstreu

Frage nach der Effizienz nicht beantwortbar, da es immer vom Modell abhängig ist!

Norm, Bin, exp, γ , Poisson \rightarrow Stichprobenmittel ist effizient

\bar{X}_n ist effizientester Schätzer

BSP₂ Varianz

$V(X) = E(X^2) - (E(X))^2$ Schätzer für $V(X)$: $\hat{V}(X) = \frac{1}{n} \sum_{i=1}^n x_i^2 - (\bar{x}_n)^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x}_n)^2$

schätzen durch
 $\frac{1}{n} \sum_{i=1}^n x_i^2$ $\bar{x}_n = \frac{1}{n} \sum_{i=1}^n x_i$

stark konsistent: Ja, mit Wsk 1 \leq schwach konsistent

erwartungstreu? $E\left(\frac{1}{n} \sum x_i^2 - \bar{x}_n^2\right) = \frac{1}{n} \sum E(x_i^2) - E(\bar{x}_n^2) = \frac{1}{n} \sum (V(x_i) + (E(x_i))^2) - (V(\bar{x}_n) + (E(\bar{x}_n))^2) = V(x) + (E(x))^2 - \left(\frac{V(x)}{n} + (E(x))^2\right) = \frac{n-1}{n} V(x)$

nein, um Faktor $\frac{n-1}{n}$ zu klein!

aus Schätzer erwartungstreu Version machen: $\hat{V} = \frac{n}{n-1} \cdot \hat{V} = \frac{1}{n-1} \sum (x_i - \bar{x}_n)^2$ S_n oder $S_n^2 \rightarrow$ Stichprobenvarianz

\hookrightarrow geht nur wenn n mind 2!

Schätzer konstruieren

Momentenmethode: $E_{\theta}(X) = g(\theta)$ eine Funktion von θ , wir setzen $g(\hat{\theta}_n) = \bar{x}_n$

wenn g umkehrbar, gilt $\hat{\theta}_n = g^{-1}(\bar{x}_n)$

wenn g stetig ist, ist $\hat{\theta}_n$ konsistent

BSP Alternativverteilung $P(X=1) = p$ $P(X=0) = 1-p$ $\bar{x}_n \dots$ erwartungstreu Schätzer für $E_p(X) = 1 \cdot p + 0 \cdot (1-p) = p$
 $\hat{p}_n = \bar{x}_n \dots$ erwartungstreu, konsistent

BSP Exponentialverteilung $f(x) = \lambda e^{-\lambda x}$ [$x \geq 0$] $\lambda \dots$ Parameter
 $E_{\lambda}(X) = \frac{1}{\lambda}$ $\hat{\lambda} = \frac{1}{\bar{x}_n}$ ist nicht erwartungstreu, aber konsistent; für $n > 1$ kann man erwartungstreu machen

Gibt es mehr als einen Parameter, dann zusätzliche Gleichung aus $E(X^k) = \frac{1}{n} \sum x_i^k$ $k = 2, 3, \dots$

Bsp: $N(\mu, \sigma^2)$ $\bar{x}_n = E_{(\mu, \sigma^2)}(X) = \mu$ $\hat{\mu} = \bar{x}_n$

$\frac{1}{n} \sum x_i^2 = E_{(\mu, \sigma^2)}(X^2) = \mu^2 + \sigma^2$ $\hat{\sigma}^2 = \frac{1}{n} \sum x_i^2 - \bar{x}_n^2$
unkorrigiertes Stichprobenmittel

Wodurch soll man bei der Varianz dividieren? n oder $n-1$

Grundgesamtheit: $\frac{1}{n}$
 Stichprobe: $\frac{1}{n-1}$ } Wenn aus Grundgesamtheit mit Umfang N ohne Zurücklegen n mal ziehen: erwartungstreuer Schätzer für σ^2 : $\hat{\sigma}_z^2 = \frac{N-1}{N} \cdot \frac{1}{n-1} \cdot \sum_{i=1}^n (x_i - \bar{x}_n)^2$

Likelihoodfunktion

Stichprobe ist aus diskreter Verteilung mit Punktwahrscheinlichkeit

$P_{\theta}(x_1) \dots P_{\theta}(x_n)$ WSK, das genau diese Stichprobe $(x_1 \dots x_n)$ gezogen wird, wenn θ der Parameter

Beste Schätzwert ist der Wert von θ , welcher diese (also $p_{\theta}(x_i)$) WSKL approximiert

$$L(x_1 \dots x_n, \theta) = \begin{cases} P_{\theta}(x_1) \dots P_{\theta}(x_n) & \text{wenn } f \text{ diskret} \\ f_{\theta}(x_1) \dots f_{\theta}(x_n) & \text{wenn } f \text{ stetig} \end{cases} \quad \begin{matrix} \prod_{i=1}^n p(x_i, \theta) \\ \prod_{i=1}^n f(x_i, \theta) \end{matrix}$$

Wichtig: dass $p_{\theta}(x) = p(x, \theta)$
 stat $f_{\theta}(x) = f(x, \theta)$

ML (Maximum Likelihood Schätzer) Wert von θ , der $L(x_1 \dots x_n, \theta)$ maximiert. $\max L(x_1 \dots x_n, \theta)$
 (μ)²

BSP Normalverteilung $f(x, \mu, \sigma) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{x-\mu}{2\sigma^2}}$

$$L(x_1, \dots, x_n, \mu, \sigma) = \prod \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{(x_i-\mu)^2}{2\sigma^2}} = \frac{1}{\sqrt{2\pi\sigma^2}^n} e^{-\sum \frac{(x_i-\mu)^2}{2\sigma^2}}$$

$\log L \rightarrow \max$

Maximum finden mittels Ableiten, null setzen \therefore

$$\log L(x_1 \dots x_n, \mu, \sigma) = -\frac{n}{2} \log(2\pi) - n \log(\sigma) - \sum \frac{(x_i-\mu)^2}{2\sigma^2}$$

$$\frac{\partial}{\partial \mu} := 0 \Leftrightarrow \sum \frac{2(x_i-\mu)}{2\sigma^2} = \sum (x_i-\mu) = 0 \quad \sum x_i - n\mu = 0 \quad \mu = \frac{\sum x_i}{n} = \bar{x}_n$$

$$\frac{\partial}{\partial \sigma} := 0 = -\frac{n}{\sigma} + \sum \frac{2x_i - \mu}{\sigma^2} \quad \sum (x_i - \mu)^2 - n\sigma^2 = 0$$

$$\hat{\sigma}^2 = \frac{1}{n} \sum (x_i - \mu)^2 = \frac{1}{n} \sum (x_i - \bar{x}_n)^2$$

BSP Alternativverteilung $A(\theta)$

$$p(1, \theta) = \theta$$

$$p(0, \theta) = 1 - \theta$$

$$p(x_i, \theta) = \left[\begin{matrix} \theta^{x_i} & x_i = 1 \\ 1 - \theta^{x_i} & x_i = 0 \end{matrix} \right] \rightarrow \theta^{x_i} (1 - \theta)^{1-x_i}$$

$$L(x_1 \dots x_n, \theta) = \prod_{i=1}^n \theta^{x_i} (1 - \theta)^{1-x_i} = \theta^{\sum x_i} (1 - \theta)^{n - \sum x_i}$$

$$\log L(x_1 \dots x_n, \theta) = (\sum x_i) \cdot \log \theta + (n - \sum x_i) \log(1 - \theta)$$

$$\text{Ableiten: } \frac{\partial}{\partial \theta} = 0 \quad 0 = \frac{\sum x_i}{\theta} - \frac{n - \sum x_i}{1 - \theta} = (\sum x_i) \left[\frac{1}{\theta} - \frac{1}{1 - \theta} \right] - \frac{n - \sum x_i}{1 - \theta} = 0$$

$$= \sum x_i \frac{1}{\theta(1 - \theta)} = \frac{n}{1 - \theta} \quad \hat{\theta} = \frac{\sum x_i}{n}$$

BSP $U(\theta, \theta)$ $f(x) = \begin{cases} \frac{1}{\theta} & \theta \leq x \leq 2\theta \\ 0 & \text{sonst} \end{cases}$

Momentenmethode: $E(x) = \frac{\theta}{2} \quad \theta = 2 \cdot E(x)$

Momentenschätzer: $2 \cdot \bar{x}_n = \hat{\theta}_n$

$$L(x_1, \dots, x_n) = f(x_1, \theta) \dots f(x_n, \theta) = \begin{cases} \frac{1}{\theta^n} & \text{wenn } x_i \leq \theta \quad \forall i = 1 \dots n \\ 0 & \text{sonst} \end{cases}$$

$$L(x_1 \dots x_n) = \begin{cases} \frac{1}{\theta^n} & \max(x_1 \dots x_n) \leq \theta \\ 0 & \text{sonst} \end{cases}$$

\Rightarrow maximum likelihood Schätzer $\hat{\theta}_n^{(ML)} = \max(x_1 \dots x_n)$ \rightarrow nicht erwehlen

UE: $E_{\theta}(\hat{\theta}_n) = \frac{n}{n+1} \theta$
 $\hat{\theta}_n = \frac{n+1}{n} \hat{\theta}_n^{(ML)}$
 $V(\hat{\theta}_n) \leq V(\hat{\theta}_n^{(ML)})$
 $\frac{1}{n(n+2)} \leq \frac{1}{n^2}$

Wie klein kann die Varianz eines erwartungstreuen Schätzers werden?

Cramér-Rao: Unter gegebenen Voraussetzungen ($p(x, \vartheta)$, $f(x, \vartheta)$ ist brav) ist $\hat{\vartheta}_n^1$ erwartungstreu für ϑ , wobei ϑ eindimensional ist, dann gilt:

$$\mathbb{E}\left(\frac{\partial}{\partial \vartheta} \log L(x_1 \dots x_n, \vartheta)\right)^2 = -\mathbb{E}\left(\frac{\partial^2}{\partial \vartheta^2} \log L(x_1 \dots x_n, \vartheta)\right) = \bar{I}_n(\vartheta) \quad \text{"Fisherinformation"}$$

Beweis: $\hat{\vartheta}_n^1 = T(x_1 \dots x_n)$

$$\vartheta = \mathbb{E}_{\vartheta}(\hat{\vartheta}_n^1) = \sum_{x_1 \dots x_n} T(x_1 \dots x_n) \cdot \mathbb{P}(X_1 = x_1 \dots X_n = x_n) = \sum_{x_1 \dots x_n} T(x_1 \dots x_n) \cdot L(x_1 \dots x_n, \vartheta) = \sum_{x_1 \dots x_n} L(x_1 \dots x_n, \vartheta) = 1$$

$$= \sum T(x_1 \dots x_n) \frac{\partial}{\partial \vartheta} L(x_1 \dots x_n, \vartheta) = 0$$

$$= \sum \frac{\partial}{\partial \vartheta} L(x_1 \dots x_n, \vartheta) = 0$$

$$1 = \sum [T(x_1 \dots x_n) - \vartheta] \frac{\partial}{\partial \vartheta} L(x_1 \dots x_n, \vartheta)$$

$$1 = \mathbb{E}_{\vartheta} (T(x_1 \dots x_n) - \vartheta) \frac{\partial}{\partial \vartheta} \log L(x_1 \dots x_n, \vartheta) = \sqrt{\mathbb{E}_{\vartheta}((\hat{\vartheta}_n^1 - \vartheta)^2)} \cdot \sqrt{\mathbb{E}_{\vartheta}\left(\left(\frac{\partial}{\partial \vartheta} \log L(x_1 \dots x_n, \vartheta)\right)^2\right)}$$

Cauchy Schwarz: $\mathbb{E}(X \cdot Y) \leq \sqrt{\mathbb{E}(X^2) \cdot \mathbb{E}(Y^2)}$

$\mathbb{E}(X^2) = \sigma^2 > 0$ $(\frac{X}{\sigma} - \frac{\mu}{\sigma})^2 \geq 0$
 $\mathbb{E}(Y^2) = \omega^2 > 0$
 $0 \leq \mathbb{E}\left(\left(\frac{X}{\sigma} - \frac{\mu}{\sigma}\right) \cdot \frac{Y}{\omega}\right) = \mathbb{E}\left(\frac{X}{\sigma} \cdot \frac{Y}{\omega}\right) - \frac{\mu}{\sigma} \cdot \frac{\omega}{\omega} = \frac{\mathbb{E}(X \cdot Y)}{\sigma \omega} - \frac{\mu}{\sigma}$

BSP Normalverteilung $N(\mu, \sigma^2)$ σ^2 bekannt \rightarrow nur 1 Parameter μ

$$\sigma^2 = 1 \Rightarrow L(x_1 \dots x_n, \mu) = \frac{1}{\sqrt{2\pi}^n} e^{-\frac{\sum (x_i - \mu)^2}{2}}$$

$$\log L(x_1 \dots x_n, \mu) = -\frac{n}{2} \log(2\pi) - \frac{\sum (x_i - \mu)^2}{2}$$

$$\frac{\partial}{\partial \mu} \log L = \sum x_i - n\mu = \sum x_i - n\mu$$

$$\frac{\partial^2}{\partial \mu^2} \log L = -n$$

$$\bar{I}_n(\mu) = -\mathbb{E}_{\mu}(-n) = n$$

Cramér Rao Schranke: $\hat{\mu}_n^1$ erwartungstreu $\rightarrow V_{\mu}(\hat{\mu}_n^1) \geq \frac{1}{n}$

$\hookrightarrow \hat{\mu}_n^1 = \bar{x}_n$ $V_{\mu}(\hat{\mu}_n^1) = \frac{1}{n} V_{\mu}(x) = \frac{1}{n}$ \rightarrow kleinste Varianz die es gibt
 \bar{x}_n ist effizient

BSP Alternativverteilung

$$\log L(x_1 \dots x_n, \vartheta) = \sum x_i \log \vartheta + (n - \sum x_i) \log(1 - \vartheta)$$

$$\frac{\partial}{\partial \vartheta} \log L(x_1 \dots x_n, \vartheta) = \frac{\sum x_i}{\vartheta} - \frac{n - \sum x_i}{1 - \vartheta}$$

$$\frac{\partial^2}{\partial \vartheta^2} \log L(\dots) = -\frac{\sum x_i}{\vartheta^2} - \frac{n - \sum x_i}{(1 - \vartheta)^2}$$

$$\mathbb{E}\left(\frac{\partial^2}{\partial \vartheta^2} \log L\right) = -\frac{n\vartheta}{\vartheta^2} - \frac{n(1-\vartheta)}{(1-\vartheta)^2} = -\frac{n(\vartheta+1-\vartheta)}{\vartheta(1-\vartheta)} = -\frac{n}{\vartheta(1-\vartheta)}$$

$$\hat{\mu}_n^1 \dots \text{erwartungstreu} \rightarrow V(\hat{\mu}_n^1) \geq \frac{\vartheta(1-\vartheta)}{n} = V(\bar{x}_n)$$



Konfidenzintervall



dua Seiten mit Genauigkeitsmaß

ein Paar $[a(x_1, \dots, x_n) \leq b(x_1, \dots, x_n)]$ von Statistiken mit $P_{\theta}(a(x_1, \dots, x_n) \leq b(x_1, \dots, x_n)) \geq \gamma$

Konfidenzintervall mit Überdeckungswahrscheinlichkeit γ $0 < \gamma < 1$

[BSP] $N(\mu, \sigma^2)$, $\sigma^2 = 1$

Konfidenzintervall Ausgangspunkt: Schätzer $\mu_n^* = \bar{x}_n$

Ausatz: Konfidenzintervall symmetrisch um $\bar{x}_n \Rightarrow a = \bar{x}_n - c$
 $b = \bar{x}_n + c$

$$2\Phi\left(\frac{c}{\sqrt{\frac{\sigma^2}{n}}}\right) = 1 + \gamma \rightarrow \frac{c}{\sqrt{\frac{\sigma^2}{n}}} = \Phi^{-1}\left(\frac{1+\gamma}{2}\right) = z_{\frac{1+\gamma}{2}}$$

$$\begin{aligned} P_{\mu}(\bar{x}_n - c \leq \mu \leq \bar{x}_n + c) &= \gamma = P_{\mu}(\mu \leq \bar{x}_n + c) = P_{\mu}(-c \leq \bar{x}_n - \mu \leq +c) = \\ &= P_{\mu}\left(-\frac{c}{\sqrt{\frac{\sigma^2}{n}}} \leq \frac{\bar{x}_n - \mu}{\sqrt{\frac{\sigma^2}{n}}} \leq \frac{c}{\sqrt{\frac{\sigma^2}{n}}}\right) = \Phi\left(\frac{c}{\sqrt{\frac{\sigma^2}{n}}}\right) - \Phi\left(-\frac{c}{\sqrt{\frac{\sigma^2}{n}}}\right) = \\ &= 2\Phi\left(\frac{c}{\sqrt{\frac{\sigma^2}{n}}}\right) - 1 \end{aligned}$$

$$c = z_{\frac{1+\gamma}{2}} \sqrt{\frac{\sigma^2}{n}} \rightarrow \text{Konfidenzintervall } \left[\bar{x}_n - z_{\frac{1+\gamma}{2}} \sqrt{\frac{\sigma^2}{n}}, \bar{x}_n + z_{\frac{1+\gamma}{2}} \sqrt{\frac{\sigma^2}{n}} \right]$$

Wenn σ^2 unbekannt \rightarrow Schätzen durch Stichproben $S_n^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x}_n)^2$

Köpfchen

1) billig: n hinreichend groß, dann $S_n^2 \approx \sigma^2 \rightarrow$ einfach einsetzen \Rightarrow

$$\hookrightarrow \text{näherungsweise Konfidenzintervall } \left[\bar{x}_n - z_{\frac{1+\gamma}{2}} \sqrt{\frac{S_n^2}{n}}, \bar{x}_n + z_{\frac{1+\gamma}{2}} \sqrt{\frac{S_n^2}{n}} \right]$$

2) exakter Weg Satz: x_1, \dots, x_n unabhängig und $\sim N(\mu, \sigma^2) \rightarrow \bar{x}_n$ und S_n^2 unabhängig

$$\bar{x}_n \sim N\left(\mu, \sqrt{\frac{\sigma^2}{n}}\right) \quad \frac{(n-1)S_n^2}{\sigma^2} \sim \chi_{n-1}^2 \left(= \Gamma\left(\frac{n-1}{2}, \frac{1}{2}\right) \right)$$

$$\frac{\bar{x}_n - \mu}{\sqrt{\frac{S_n^2}{n}}} \sim t_{n-1} \quad \text{Dichte } f(x) = C_n \cdot \frac{1}{\left(1 + \frac{x^2}{n-1}\right)^{\frac{n}{2}}}$$

Ausatz für Konfidenzintervall $\left[\bar{x}_n - c \sqrt{\frac{S_n^2}{n}}, \bar{x}_n + c \sqrt{\frac{S_n^2}{n}} \right]$ $c = t_{n-1, \frac{1+\gamma}{2}}$

[BSP] $n=20$ $\bar{x}_n = 1,32$ $S_n^2 = 0,36$ $\gamma = 0,95$

1) näherungsweise Konfidenzintervall

$$\left[1,32 - 1,96 \sqrt{\frac{0,36}{20}}, 1,32 + 1,96 \sqrt{\frac{0,36}{20}} \right]$$

$$[1,05, 1,59]$$

2) exakt: statt $z_{0,975} = 1,96$ $t_{n-1, \frac{1+\gamma}{2}}$

$t_{20-1, \frac{1+\gamma}{2}}$

$t_{19, 0,975} = 2,083$

$$\left[1,32 - 2,083 \sqrt{\frac{0,36}{20}}, 1,32 + 2,083 \sqrt{\frac{0,36}{20}} \right] = [1,04, 1,6]$$

$$\left[\frac{19 \cdot 0,36}{32,852}, \frac{6,84}{8,907} \right] = [0,2, \dots, 0,7]$$

Konfidenzintervall $\sigma^2 \rightarrow$ basiert auf S_n^2

im Raum nicht symmetrisch

definiert als $[a \cdot S_n^2, b \cdot S_n^2]$

$$P(\sigma^2 < a \cdot S_n^2) = P(\sigma^2 > b \cdot S_n^2) = \frac{1-\gamma}{2}$$

$$P\left(\frac{n-1}{a} < \frac{S_n^2}{\sigma^2} (n-1)\right) = \frac{1-\gamma}{2} \rightarrow P\left(\frac{n-1}{a} \geq \dots\right) = 1 - \frac{1-\gamma}{2}$$

$$\frac{n-1}{a} = \chi_{n-1}^2, \frac{1+\gamma}{2}$$

$$P\left(\frac{n-1}{b} \geq \dots\right) = \frac{1-\gamma}{2}$$

$$\frac{n-1}{b} = \chi_{n-1}^2, \frac{1-\gamma}{2}$$

$$\text{KI } \sigma^2 \left[\frac{(n-1)S_n^2}{\chi_{n-1}^2, \frac{1+\gamma}{2}}, \frac{(n-1)S_n^2}{\chi_{n-1}^2, \frac{1-\gamma}{2}} \right]$$

Anteilswert/allgemein: $\hat{\theta} = \bar{x}_n$ $n \cdot \bar{x}_n \sim B(n, \theta) \approx N(n\theta, n\theta(1-\theta))$

$$\bar{x}_n \approx N\left(\theta, \frac{\theta(1-\theta)}{n}\right)$$

$\hat{\theta} = \bar{x}_n$ für θ einsetzen

Kittelpunkt des Konfidenzintervalls

$$\text{näherungsweise Konfidenzintervall: } \left[\bar{x}_n - z_{\frac{1+\gamma}{2}} \sqrt{\frac{\hat{\theta}(1-\hat{\theta})}{n}}, \bar{x}_n + z_{\frac{1+\gamma}{2}} \sqrt{\frac{\hat{\theta}(1-\hat{\theta})}{n}} \right]$$

Statistische Tests (Signifikanz - Hypothesentests)

Entscheidung zwischen zwei Möglichkeiten (gut oder schlecht)

BSP Bier, 500ml Inhalt → haben wir genug? oder ist die Münze fair? ($p = \frac{1}{2}$) oder ist der Würfel fair? (alle WSK der Augenzahlen $\frac{1}{6}$)
 $\hookrightarrow \mu = 500$ Inhalt: $N(\mu, \sigma^2)$

Hypothese: Teilmenge des Parameterraums, mögliche Entscheidungen

- Nullhypothese H_0 (wie es sein soll)
- Alternative / Gegenhypothese (Abweichungen von der Norm, was bewiesen werden soll)
- einfache Hypothese $|H| = 1$ (nur 1 Element)
- zusammengesetzte Hypothese $|H| > 1$

BSP. $p = \frac{1}{2}$ ($\left\{ \frac{1}{2} \right\}$) einfach $p < \frac{1}{2}$, $p \leq \frac{1}{2}$, $p \neq \frac{1}{2}$ zusammengesetzt
↑ also Menge
 $\mu = 500$ ist zusammengesetzt, $H = \{(\mu, \sigma^2) : \mu = 500, \sigma^2 > 0\}$ wenn σ^2 unbekannt

Bei zusammengesetzten Hypothesen:

einseitig: $p < \frac{1}{2}$, $p \leq \frac{1}{2}$, $p > \frac{1}{2}$ $\mu > 500$, $\mu < 500$

zweiseitig: $p \neq \frac{1}{2}$ $\mu \neq 500$

Vorgehen: H_0, H_1 formulieren (Wann entscheiden wir uns für H_0 , wann für H_1 ?)

Annahmehbereich: alle möglichen Stichprobenergebnisse für die H_0 angenommen wird

Verwerfungsbereich: Stichproben, für die H_1 genommen wird.

$$\left. \begin{array}{l} H_0 = \frac{1}{2} \\ H_1 \neq \frac{1}{2} \end{array} \right\} n = 4 \quad A = \left\{ \begin{array}{cc} 0011 & 0101 \\ 0110 & 1010 \\ 1100 & 1001 \end{array} \right\} \quad V = \left\{ \begin{array}{ccc} 0000 & 1000 & 1110 \\ 1111 & \vdots & \vdots \\ & 0001 & 0111 \end{array} \right\}$$

Schöner:

a) Teststatistik (Statistik, die vom Parameter beeinflusst wird.)

BSP Münze: Anzahl / Erfolge / Köpfe

Vorselektionstest: Anzahl der Beobachtungen > 4

Normalverteilung: \bar{X}_n Stichprobenmittel (generell: Schätzer für Parameter)

b) Asymmetrische Sprechweise: H_0 wird angenommen oder verworfen → stärker

Teststatistik T , H_0 wird verworfen, wenn T größer / kleiner als "kritischer Wert" t_c

BSP Münze $T = \# \text{ Köpfe}$, verworfen von H_0 wenn $T \neq 2$ $|T - 2| > 0$

Fehler 1. Art: Nullhypothese H_0 trifft zu, wird aber verworfen.

Fehler 2. Art: Nullhypothese trifft nicht zu, wird aber angenommen.

↳ Dilemma: kann WSLK für Fehler 1. Art nicht verkleinern, ohne Wahrscheinlichkeit für Fehler 2. Art zu vergrößern (und umgekehrt)

Lösung: Eine Schwelle für die WSLK des Fehlers 1. Art an $\mathbb{P}(\text{Fehler 1. Art}) \leq \alpha$

Signifikanzniveau α , wobei $\alpha = 0.05$ (wenn nicht anders gesagt)

Ablauf: 1, Hypothesen formulieren

2) Wahl der Teststatistik (Kochrezept), α festlegen

3) Verteilung der Teststatistik T unter H_0 → kritischer Wert

4) Stichprobe, Teststatistik berechnen, mit kritischem Wert vergleichen → Entscheidung

Am Computer: nach Niveau wird nicht gefragt, es wird "p-Wert" gefragt, dh: WSLK, dass ein Ergebnis auftritt, welches mindestens so schlecht

(für die Nullhypothese H_0) ist wie das aus der Stichprobe

[BSP] $H_0 = \frac{1}{2} \quad H_1 > \frac{1}{2}$

Teststatistik: $T = \text{Anzahl "Kopf"}$, $\alpha = 0.05$, $n = 12$ Stichprobengröße

verwerfe H_0 , wenn $T > t_c$

praktisch: Approximation mittels Normalverteilung

H_0 wird verworfen, $T = \# \text{Kopf} = \sum_{i=1}^n X_i$

$$t_c = np + z_{1-\alpha} \sqrt{np(1-p)}$$

binomial \rightarrow (theoretisch gut)

$$\mathbb{P}(T > t_c) = \sum_{k=t_c+1}^n \binom{n}{k} \left(\frac{1}{2}\right)^n \leq \alpha$$

$$\sum \binom{n}{k} \leq z_{1-\alpha} \cdot 0.05 = 20.98$$

$$\left. \begin{aligned} \binom{12}{12} &= 1 \\ \binom{12}{11} &= 12 \\ \binom{12}{10} &= \binom{12}{2} = 66 \\ \binom{12}{9} &= 220 \end{aligned} \right\} = t_c$$

steigt von mit 125 und 318 ...!

Kochrezept für Anteilswerte $\alpha = 0.05$ wobei $T = \frac{\text{Anzahl Erfolge} - np_0}{\sqrt{n \cdot p_0(1-p_0)}}$

(1) $H_0: p = p_0 / H_0: p > p_0$ } H_0 verwerfen wenn $T > z_{1-\alpha}$
 ($H_0: p \leq p_0$)

(2) $H_0: p = p_0 / H_0: p < p_0$ } H_0 verwerfen wenn $T < z_{\alpha} = -z_{1-\alpha}$
 ($H_0: p \geq p_0$)

(3) $H_0: p = p_0 / H_0: p \neq p_0$ } H_0 verwerfen wenn $|T| > z_{1-\frac{\alpha}{2}}$

[BSP] $N(\mu, \sigma^2)$, $H_0: \mu = \mu_0 / H_1: \mu > \mu_0$, Annahme: σ^2 bekannt (ist einfacher also)

$T =$ Schätzer für $\mu = \bar{X}_n$, $\bar{X}_n \sim N(\mu, \frac{\sigma^2}{n})$ unter H_0

$$T = \frac{\bar{X}_n - \mu_0}{\sqrt{\frac{\sigma^2}{n}}} \sim N(0,1)$$

$H_0: \mu = \mu_0 / H_1: \mu > \mu_0$ } verwerfen, wenn $T > z_{1-\alpha}$
 $\mu \leq \mu_0$

$H_0: \mu \geq \mu_0 / H_1: \mu < \mu_0$ } verwerfen, wenn $T < z_{\alpha} = -z_{1-\alpha}$

$H_0: \mu = \mu_0 / H_1: \mu \neq \mu_0$ } verwerfen, wenn $|T| > z_{1-\frac{\alpha}{2}}$

Wenn σ^2 (Varianz) nicht bekannt ist, muss es mit S_n^2 geschätzt werden

$$T = \frac{\bar{x}_n - \mu_0}{\sqrt{\frac{S_n^2}{n}}}$$

Computer: H_0 wird verworfen, wenn p-Wert $< \alpha$

Verteilung von T mit t_{n-1} ($n-1$ Freiheitsgrade - exakt) oder $N(0,1)$ näherungsweise

$$H_0 \mu \leq \mu_0 / H_1 \mu > \mu_0 \quad \text{verworfen wenn } T > t_{n-1, 1-\alpha}$$

$$H_0 \mu \geq \mu_0 / H_1 \mu < \mu_0 \quad \text{verworfen wenn } T < t_{n-1, \alpha} = -t_{n-1, 1-\alpha}$$

$$H_0 \mu = \mu_0 / H_1 \mu \neq \mu_0 \quad \text{verworfen wenn } |T| > t_{n-1, 1-\frac{\alpha}{2}}$$

(BSP) Bier $\mu_0 = 500$ $n = 25$ $\bar{x}_n = 497$ $S_n^2 = 25$ $t_{n-1, \alpha} = -t_{n-1, 1-\alpha} = -t_{24, 0.05} = -1,711 < -2,797$

$$T = \frac{497 - 500}{\sqrt{\frac{25}{25}}} = -3 \rightarrow H_0 \text{ wird verworfen}$$


Stochastik

Stochastischer Prozess: Familie von Zufallsvariablen mit $X_t, t \in T$ $t \in \mathbb{R}$ (Parameterraum, Indexraum)


diskreter stochastischer Prozess: T ist endlich/abzählbar Ω_X - Wertebereich, (Zustands/Phasenraum)

stetiger stochastischer Prozess: T ist endliches/unendliches Intervall

BSP Temperatur - stetig per Definition



BSP Fahrzeuge an der Kreuzung




diskreter Zustandsraum

Sei $X_n, n \geq 1$ eine Folge von unabhängigen und identisch verteilten Zufallsvariablen

$$S_n = X_1 + \dots + X_n \quad (S_0 = 0)$$

unabhängig identisch verteilt aka independent and identically distributed iid



$$X_{t_1} \quad t_1 \geq 0$$

$$(X_{t_1}, X_{t_2}), \quad t_1, t_2 \geq 0 \\ t_2 > t_1$$

Charakterisierung

Die Zufallsvariablen $X_n (n \geq 1)$ können voneinander abhängig sein. Beschrieben wird das durch die gemeinsamen Verteilungen $(X_{t_1}, X_{t_2}, \dots, X_{t_n})$ wobei $t_1 < t_2 < \dots < t_n \quad n \geq 1$

Kolmogorow: Ein stochastischer Prozess wird durch gemeinsame Verteilungen $(X_{t_1}, X_{t_2}, \dots, X_{t_n})$ mit $t_1 < t_2 < \dots < t_n \quad (n \geq 1)$ beschrieben.


Wichtige Klassen der stochastischen Prozesse: stationäre Prozesse, Prozesse mit unabhängigen Zuwäusen, Markovprozesse, Zählprozesse, Erneuerungsprozess

räumliche stochastische Prozesse: gibts auch


stationärer stochastischer Prozess

stationär: $(X_t, t \in T)$ ist stationär, wenn die gemeinsamen Verteilungen $(X_{t_1}, \dots, X_{t_n})$ mit denen von $(X_{t_1+h}, \dots, X_{t_n+h})$ für alle $t_1 < \dots < t_n$ und $h > 0$ übereinstimmen. (Verteilungen sind so gleich, dass h beliebig sein kann)

Veranschaulichung



BSP



Folge von Zufallsvariablen, wobei X_n unabhängig und gleichverteilt sind.

Zirkular - Odds

Ergodensatz von Birkhoff

Wenn eine Folge von Zufallsvariablen $(X_n, n \geq 1)$ stationär ist und $E[X_1] < \infty$ dann gilt

1) die Zufallsvariable $X_{\infty} =: \lim_{n \rightarrow \infty} \bar{X}_n$ existiert mit Wahrscheinlichkeit 1


2) $E[X_{\infty}] = E[X_1]$ wobei $\bar{X}_n = \frac{\sum_{i=1}^n X_i}{n}$

$$i=1 \rightarrow X_1 \\ i=2 \rightarrow \frac{X_1 + X_2}{2} \\ i=3 \rightarrow \frac{X_1 + X_2 + X_3}{3}$$

Wenn $\lim_{n \rightarrow \infty} f(X_n, X_{n+1}, \dots)$ ein Wert für die beschränkte Funktion $f(\cdot)$ ist, dann heißt $(X_n, n \geq 1)$ ergodisch

Prozesse mit unabhängigen Zuwächsen

unabhängiger Zuwachs: $(X_t, t \in T)$ unabh. Zuw. wenn $X_{t_1}, X_{t_2} - X_{t_1}, \dots, X_{t_n} - X_{t_{n-1}}$ für $t_1 < \dots < t_n$ voneinander unabhängig




BSP Sei $(X_n, n \geq 1)$ unabh. identisch verteilt, dann ist $S_n = X_1 + \dots + X_n$ ein Prozess mit unabhängigen Zuwächsen

$$S_n, S_m - S_n, S_i - S_j, m \leq j < i$$

$$S_n = X_1 + \dots + X_n \quad S_m - S_n = X_{n+1} + X_{n+2} + \dots + X_m \quad S_i - S_j = X_{j+1} + \dots + X_i$$

Markovprozesse ~~Kalenderprozess~~


Folgende Eigenschaft muss gelten: $P(X_{t_n} = x_n | X_{t_1} = x_1, \dots, X_{t_{n-1}} = x_{n-1}) = P(X_{t_n} = x_n | X_{t_{n-1}} = x_{n-1}) \quad \forall t_1 < \dots < t_n, n \geq 1$



Markoveigenschaft:

Zählprozess


es gilt: $X_t = \#\{i : 0 < T_i \leq t\}$ mit $(T_i > 0, i \geq 1)$ ist Zufallsfolge von Zeitpunkten/Ereignissen



Erneuerungsprozess

es gilt: $(R_n, n \geq 1)$ ist Folge von unabhängig und identisch verteilten Zufallsvariablen und $S_0 = 0$ und $S_n = R_1 + \dots + R_n$

$(t_n, t \in T)$ ist Erneuerungsprozess $\Leftrightarrow X_t = n$ für $S_n \leq t < S_{n+1}$



$$X_t = \#\{n : 0 < S_n \leq t\}$$

Erneuerungsprozess ist Spezialfall von Zählprozess

Poissonprozess

Ein Poissonprozess wird mit Hilfe von Annäherung von diskreter Zeit auf stetige Zeit durch schrittweise Erhöhung der Auflösung erzeugt.

Wir teilen $[0, \infty]$ auf kleine Teile mit der Länge 2^{-N} auf. Einige von diesen kleinen Teilen werden markiert bzw. gewisse Ereignisse treten in einigen, zufällig ausgewählten kleinen Intervallen auf. Die Markierungen sind voneinander unabhängig. Die Wahrscheinlichkeit des Auftretens eines gewissen Ereignisses ist proportional mit der Länge des kleinen Intervalls, d.h. $P(\text{Markierung}) = \lambda 2^{-N}$. N ist groß genug gewählt, sodass $\lambda 2^{-N} < 1$ ist.

→ Sei $X(t)$ die Anzahl der Markierungen im Intervall $[0, t]$

1) $[X(t+s) - X(s)]$ und $X(s)$ sind unabhängig

2) $[X(t+s) - X(s)]$ hat Binomialverteilung mit $p = \lambda 2^{-N}$ und $n = 2^N t \sim B(\lambda 2^{-N}, 2^N t)$

$$\Rightarrow E[X(t+s) - X(s)] = np = \lambda 2^{-N} 2^N t = \lambda t \rightarrow \text{unabhängig von } N$$

Wir setzen den Grenzübergang $N \rightarrow \infty$ mit

1) $[X(t+s) - X(s)]$ und $X(s)$ sind unabhängig $X \sim B(p, n) \xrightarrow[np = \text{konstant}]{n \rightarrow \infty} P(\text{konstant})$

2) $[X(t+s) - X(s)]$ hat Poissonverteilung $\sim P(\lambda, t)$

$$\Rightarrow P([X(t+s) - X(s)] = k) = \frac{(\lambda t)^k}{k!} e^{-\lambda t} \quad p \geq 0$$

Man nennt den Zählprozess $(N(t), t \geq 0)$ Poissonprozess mit Parameter λ , wenn gilt:

1) Prozess mit unabhängigen Zuwächsen, d.h. $[N(s+t) - N(s)]$ und $N(s)$ für $0 \leq s \leq t$ sind unabhängig.

2) Prozess mit stationären Zuwächsen, d.h. $[N(s+t) - N(s)]$ ist $P(\lambda t)$ also $P(N(s+t) - N(s) = k) = \frac{(\lambda t)^k}{k!} e^{-\lambda t}$ also nur von t abhängig für alle $s \geq 0$

1. Alternative Form: Kurzzeitverhalten

$$P(N(t+h) - N(t) = 1) = \lambda h + o(h)$$

$$P(N(t+h) - N(t) = 0) = 1 - \lambda h + o(h)$$

$$P(N(t+h) - N(t) \geq 2) = o(h)$$

2. Alternative Form: Exponentiell verteiltes Zwischenzuwachsintervall

Sei $(T_i, i \geq 1)$ durch $N(t) = \#\{i: 0 < T_i \leq t\}$ definiert und $T_0 = 0$

Dann sind die Intervalle $T_{n+1} - T_n, n \geq 0$ mit $\exp(-\lambda)$ verteilt.

Kochrezept:

Zuerst a dann b dann c beweisen, von c auf a folgern

ex: Kleinordnung:

Fkt $f(h)$ ist $o(h)$ wenn $\lim_{h \rightarrow 0} \frac{f(h)}{h} = 0$
geht über bzw schneller als h

Alle Fkt die $> h^1$ sind, sind Kleinordnungen.

$$2h \notin o(h)$$

$$h^2 \in o(h)$$

Kochrezept: Zuerst **a** dann **b** dann **c** beweisen, von **c** auf **a** folgern

a → b (stationärer Prozess → Kurzzeitverhalten)

$$P(N(t+h) - N(t) = 0) = e^{-\lambda h} \stackrel{h \ll 1}{=} 1 - \lambda h + o(h)$$


$$P(N(t+h) - N(t) = 1) = \lambda h e^{-\lambda h} = \lambda h - \frac{\lambda^2 h^2}{2} + o(h) = \lambda h + o(h)$$

$$P(N(t+h) - N(t) \geq 2) = 1 - P(N(t+h) - N(t) = 0) - P(N(t+h) - N(t) = 1) = 1 - (1 - \lambda h + o(h)) - \lambda h + o(h) = o(h)$$

b → c (Kurzzeitverhalten → exp. vert. zw. Zuwachs)

$$P(t) = P(\text{kein Zuwachs findet statt in } [0, t])$$

$$P(t + \Delta t) \stackrel{\substack{\text{kein Zuwachs} \\ \text{1. Exponential}}}{=} P(t) \stackrel{\substack{\text{kein Zuwachs} \\ \text{2. Exponential}}}{=} P(\Delta t) = P(t)(1 - \lambda \Delta t + o(\Delta t)) = P(t) - \lambda P(t) \Delta t + P(t) o(\Delta t)$$

$$\lim_{\Delta t \rightarrow 0} \frac{P(t + \Delta t) - P(t)}{\Delta t} = -\lambda P(t) + \lim_{\Delta t \rightarrow 0} P(t) \frac{o(\Delta t)}{\Delta t}$$



$$P'(t) = -\lambda P(t) \quad P(0) = 1$$

$$P(t) = e^{-\lambda t} \quad P(t) = P(T_{n+1} - T_n > t) = e^{-\lambda t} \rightarrow P(T_{n+1} - T_n \leq t) = 1 - e^{-\lambda t} \quad n \geq 0$$


c → a (exp. ... → stationäre Zuwächse)

$$h = 0 \quad P(T_n > t) = e^{-\lambda t} = P(N(t) = 0)$$

$h \geq 1$ mit mathematischem Indikator




$$P(N(t) = k+1) = \int_{u=0}^t P(N(t) = k+1 | T_1 = u) \cdot f(u) du = \int_{u=0}^t P(N(t-u) = k) f(u) du = \int_{u=0}^t \frac{[\lambda(t-u)]^k}{k!} e^{-\lambda(t-u)} \lambda e^{-\lambda u} du = \frac{\lambda^{k+1}}{k!} e^{-\lambda t} \int_{u=0}^t (t-u)^k du = \frac{\lambda^{k+1}}{k!} e^{-\lambda t} \frac{(t-u)^{k+1}}{k+1} \Big|_{u=0}^t = \frac{\lambda^{k+1}}{k!} e^{-\lambda t} \frac{t^{k+1}}{k+1} = \frac{(\lambda t)^{k+1}}{(k+1)!} e^{-\lambda t}$$



ist je schön, aber wir können es noch anders beweisen, und zwar so:

$$P(T_n \leq t) = P(T_n \leq t, T_{n+1} \leq t) + P(T_n \leq t, T_{n+1} > t)$$

$$\Rightarrow P(T_n \leq t, T_{n+1} > t) = P(T_n \leq t) - P(T_{n+1} \leq t)$$

$$P(N(t) = n) = P(T_n \leq t, T_{n+1} > t) = P(T_n \leq t) - P(T_{n+1} \leq t) = \int_{x=0}^t \frac{\lambda^n x^{n-1}}{(n-1)!} e^{-\lambda x} - \frac{\lambda^{n+1} x^n}{n!} e^{-\lambda x} dx = \frac{1}{\lambda} \frac{\lambda^{n+1} t^n}{n!} e^{-\lambda t} = \frac{(\lambda t)^n}{n!} e^{-\lambda t}$$


Gamma(n, λ) = Γ(n, λ)

$\frac{1}{\lambda} f'_{\text{Gamma}(n+1, \lambda)}(x)$

$$\Gamma(n, \lambda) = \frac{\lambda^n x^{n-1}}{(n-1)!} e^{-\lambda x}$$

Verbundene Eigenschaften der Exp(λ) Verteilung

1) Erlang (n, λ) Verteilung: Sei (x_n, n ≥ 1) eine Folge von unabhängig verteilten Exp(λ) Zufallsvariablen, dann ist y_n = x₁ + ... + x_n Erlang(n, λ) verteilt.

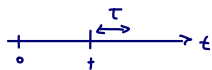
$$\text{Erlang}(n, \lambda) = \Gamma(n, \lambda)$$

$$n=1: f_{\text{erlang}(1, \lambda)}(x) = \lambda e^{-\lambda x} = f_{\Gamma(1, \lambda)}$$

$$\begin{aligned} n > 1: f_{\text{erlang}(n, \lambda)}(x) &= \int_{x=0}^x f_{\text{erlang}(n-1, \lambda)}(x) f_{\text{Exp}(\lambda)}(x-x) dx = \int_{x=0}^x \frac{\lambda^{n-1} x^{n-2}}{(n-2)!} \lambda e^{-\lambda(x-x)} dx = \frac{\lambda^{n-1}}{(n-2)!} e^{-\lambda x} \int_{x=0}^x x^{n-2} dx = \\ &= \frac{\lambda^{n-1}}{(n-2)!} e^{-\lambda x} \frac{x^{n-1}}{n-1} = \frac{\lambda^{n-1}}{(n-1)!} e^{-\lambda x} x^{n-1} = f_{\Gamma(n, \lambda)} \end{aligned}$$

2) Gedächtnislosigkeit der Exponentialverteilung

$$P(X \leq t + \tau | X > t) = 1 - \frac{P(X > t + \tau, X > t)}{P(X > t)} = 1 - \frac{P(X > t + \tau)}{P(X > t)} = 1 - \frac{e^{-\lambda(t+\tau)}}{e^{-\lambda t}} = 1 - e^{-\lambda \tau} \sim \text{Exp}(\lambda)$$



$$X \sim \text{Exp}(\lambda)$$

$$\exp(\lambda) \cdot \frac{\lambda e^{-\lambda t}}{e^{-\lambda t}} = \lambda$$

Hazard Rate (Verteilung der verbleibenden Zeit)

$$G_t(x) = P(X - t \leq x | X > t) = \frac{P(X \leq t+x, X > t)}{P(X > t)} = \frac{F(t+x) - F(t)}{1 - F(t)}$$

3 Möglichkeiten für f(t) = $\lim_{\Delta x \rightarrow 0} \frac{F(t+\Delta x) - F(t)}{\Delta x}$

aging (wird älter): λ(t) steigt

deaging (wird jünger): λ(t) fällt

apeless (zeitlos): λ(t) = c

$$\text{Rate: } \lambda(t) = \lim_{\Delta x \rightarrow 0} \frac{G_t(\Delta x)}{\Delta x} = \lim_{\Delta x \rightarrow 0} \frac{F(t+\Delta x) - F(t)}{\Delta x} \cdot \frac{1}{1 - F(t)} = \frac{f(t)}{1 - F(t)}$$

Intuitives Denken mit Poissonprozess

1) Kurzzeitverhalten

$$P(N(t+\Delta t) - N(t) = 0) = 1 - \lambda \Delta t + o(\Delta t)$$

$$P(N(t+\Delta t) - N(t) = 1) = \lambda \Delta t + o(\Delta t)$$

$$P(N(t+\Delta t) - N(t) \geq 2) = o(\Delta t)$$

2) Hazardrate ist λ

inhomogener Prozess: \rightarrow nicht stationär, unabhängige Zuwächse

$$\lambda t \rightarrow \int_0^t \lambda(x) dx$$

$$P(N(t) = k) = \left(\int_0^t \lambda(x) dx \right)^k \frac{1}{k!} e^{-\int_0^t \lambda(x) dx}$$

Anwendung unter anderem bei Modellierung von Telefonanrufen (Warteschlangenthema), bei Zerfall des Teildens, genetische Änderung durch radioaktive Einstrahlung

BSP $X \sim \text{Poi}(\lambda)$ $Y \sim \Gamma(n, \lambda) \Rightarrow P(Y \leq \lambda) = P(X \geq n)$, $n \geq 1$

1. Lösung: (mittels Induktion)

$$\int_0^\lambda \frac{\lambda^n x^{n-1}}{(n-1)!} e^{-nx} = \sum_{k=n}^{\infty} \frac{\lambda^k}{k!} e^{-\lambda}$$

bei $n=1$ $\int_0^\lambda e^{-x} dx = -e^{-x} \Big|_0^\lambda = 1 - e^{-\lambda}$

bei $k \rightarrow n+1$ $\int_0^\lambda \frac{x^n}{n!} e^{-x} dx = \frac{1}{n!} \int_0^\lambda x^n e^{-x} dx = \frac{1}{n!} (-x^n e^{-x}) \Big|_0^\lambda + \int_0^\lambda nx^{n-1} e^{-x} dx = \int_0^\lambda \frac{x^{n-1}}{(n-1)!} e^{-x} dx - \frac{\lambda^n e^{-\lambda}}{n!} =$
 $= \sum_{k=n}^{\infty} \frac{\lambda^k}{k!} e^{-\lambda} - \frac{\lambda^n e^{-\lambda}}{n!} = \sum_{k=n+1}^{\infty} \frac{\lambda^k}{k!} e^{-\lambda}$

2. Lösung (eleganter) ... $\frac{d}{d\lambda}$

$$\frac{\lambda^{n-1}}{(n-1)!} e^{-\lambda} = \sum_{k=n}^{\infty} \frac{k \lambda^{k-1}}{k!} e^{-\lambda} - \frac{\lambda^k}{k!} e^{-\lambda} = \sum_{k=n}^{\infty} \frac{\lambda^{k-1}}{(k-1)!} - \sum_{k=n}^{\infty} \frac{\lambda^k}{k!} e^{-\lambda} = \frac{\lambda^{n-1}}{(n-1)!} e^{-\lambda}, \quad n \geq 1$$

Wenn $\lambda \rightarrow 0$, sodass $\int_0^\lambda \frac{\lambda^{n-1}}{(n-1)!} e^{-x} dx$ und auch $\sum_{k=n}^{\infty} \frac{\lambda^k}{k!} e^{-\lambda}$ also man 'sieht' das konstante beim Integral 0 wird

3. Lösung: Interpretation

$X \sim$ Anzahl der Zuwächse im Intervall $[0, \lambda]$

$Y \sim$ Zeitpunkt des ersten Zuwachs

$$P(Y \leq \lambda) = P(n\text{-ter Zuwachs, der vor } \lambda \text{ stattfindet}) = P(\# \text{Zuwächse} \geq n) = P(X \geq n)$$

Markovprozesse

Ein stochastischer Prozess heißt Markov, wenn $P(X_t \leq x_n | X_{t+1})$ wobei $T = \text{Indexraum}$, $S = \text{Zustandsraum}$

Wir kategorisieren nach Intervallen

nach Zustandsraum

mit diskreter Zeit (Indexmenge $\in \mathbb{Z}, \mathbb{N}$ or \mathbb{N}^+)

diskret oder stetig

mit stetiger Zeit (Indexmenge \mathbb{R} or \mathbb{R}^+)

Zustandsraum kann sowohl diskret als auch stetig sein.

DTMC Markovkette in diskreter Zeit

Ein stochastischer Prozess heißt DTMC genau dann, wenn gilt: $P(X_n = x_n | X_0 = x_0, X_1 = x_1, \dots, X_{n-1} = x_{n-1}) = P(X_n = x_n | X_{n-1} = x_{n-1})$ für $n \geq 1$

Übergangswahrscheinlichkeit: $P(X_n = i | X_{n-1} = j)$ für $n \geq 1$ und $i, j \in S$

homogen: DTMC ist homogen, wenn Übergangswahrscheinlichkeit $P(X_n = j | X_{n-1} = i) \forall n \geq 1$ verschiebungsinvariant ist (gleiches bleibt?)

also: $P(X_n = j | X_{n-1} = i) = P(X_{n+1} = j | X_n = i) \dots \Rightarrow P_{ij} = P(X_n = j | X_{n-1} = i)$

Ab jetzt werden homogene DTMCs mit Indexwerten $\in \mathbb{N}$ ausgedrückt!

Begriffe:

1-stufige Übergangswahrscheinlichkeit: $P_{ij} = P(X_1 = j | X_0 = i)$

CTMC Markovkette in stetiger Zeit

1-stufige Übergangsmatrix: $\underline{P} = [P_{ij}]$

n-stufige Übergangswahrscheinlichkeit: $P_{ij}^{(n)} = P(X_{n+1} = j | X_n = i)$

Markovkette - Markovprozess mit diskreten S/T

n-stufige Übergangsmatrix: $\underline{P}^{(n)} = [P_{ij}^{(n)}]$

Anfängliche Zustandswahrscheinlichkeit: $\underline{P}_i = P(X_0 = i)$

Mehrdimensionale Markovprozess: S = mehrdimensional

Anfänglicher Zustandsvektormatrix: $\underline{P} = [P_i]$


n-stufige Zustandswahrscheinlichkeit: $P_i^{(n)} = P(X_n = i)$

n-stufige Zustandsvektormatrix: $\underline{P}^{(n)} = [P_i^{(n)}]$

Beschreibung mehrstufiger Übergänge

Chapman Kolmogorov Gleichung:

$$\underline{P}^{(n+m)} = \underline{P}^{(m)} \cdot \underline{P}^{(n)} \quad n, m \geq 1$$



Beweis: Alle (disjunkten) Wege von einem Zustand zum anderen addieren (entspricht Matrixmultiplikation)

Grundlegende Zusammenhänge

$\underline{P}^{(n)} = \underline{P}^n \quad \underline{P}^{(n)} = \underline{P}^{(n-1)} \cdot \underline{P} \Rightarrow \underline{P} \text{ (n mal machbar)}$

$\underline{P}^{(n)}$ ist stochastisch

ex: stochastische Matrix:

alle Elemente von $\underline{P}^{(n)}$ sind WSK $\rightarrow 0 \leq a_{ij} \leq 1$

1) $0 \leq a_{ij} \leq 1$

Zeile i von $\underline{P}^{(n)}$ beschreibt WSK für Zustandswechsel $\Rightarrow \sum = 1$


2) Zeilen Summen = 1 $\Leftrightarrow \sum_{j \in S} a_{ij} = 1 \quad \forall i \in S$

$\underline{P}^{(n)} = \underline{P}^{(0)} \cdot \underline{P}^{(n)} \quad (\underline{P}^{(0)} \text{ ist Anfangszustandsvektor!})$

Festlegungsmöglichkeiten einer DTMC

a) Übergangsmatrix

b) Zustandsdiagramm



$$\Leftrightarrow \begin{bmatrix} 0 & 0.4 & 0.6 \\ 0.2 & 0.1 & 0 \\ 0 & 1 & 0 \end{bmatrix} = P$$

Summe aller Pfeile weg von X muss 1 ergeben!

Charakterisierung des Verhaltens einer DTMC mittels $P(\text{Aufenthaltsdauer in Zustand } i = n) = P_{ii}^{(n)}(1 - P_{ii}) \sim \text{Geometrisch}(1 - P_{ii})$

immer noch eine Zeit von \sim Geometrisch wird Zustand gewechselt

Simulation einer DTMC

mit der Übergangsmatrix oder mit der (geometrisch verteilten) Aufenthaltsdauer

"Erzeugen" der Aufenthaltsdauer \Rightarrow Bestimmen des nächsten Zustands (sofern es Übergang gibt) mit $\frac{P_{ij}}{1 - P_{ii}}$

BSP $P = \begin{bmatrix} 1-a & a \\ b & 1-b \end{bmatrix}$

$$|\lambda I - P| = [\lambda - (1-a)][\lambda - (1-b)] - ab = \lambda^2 - \lambda(1-a+1-b) + (1-a)(1-b) - ab \stackrel{!}{=} 0$$

$$\lambda_{1,2} = \dots \stackrel{\text{binom. Formel}}{=} \frac{2 - (a+b) \pm (a+b)}{2} = 1$$

$$\downarrow \frac{2 - (a+b) - (a+b)}{2} = 1 - a - b$$

$$(P - \lambda I) \underline{u} = \underline{0}$$

$$\lambda = 1 \rightarrow (P - I) \underline{u} = \underline{0} \quad \begin{bmatrix} -a & a \\ b & -b \end{bmatrix} \begin{pmatrix} u_1 \\ u_2 \end{pmatrix} = \underline{0} \quad \begin{cases} -au_1 + au_2 = 0 \\ bu_1 - bu_2 = 0 \end{cases} \quad \begin{matrix} u_1 = u_2 \\ u_1 = u_2 \end{matrix} \Rightarrow u_1 = u_2 \Rightarrow \underline{u} = \begin{pmatrix} 1 \\ 1 \end{pmatrix}$$

$$\lambda = 1 - a - b \rightarrow (P - \lambda I) \underline{u} = \underline{0} \quad \begin{bmatrix} b & a \\ b & a \end{bmatrix} \begin{pmatrix} u_1 \\ u_2 \end{pmatrix} = \underline{0} \rightarrow u_2 = -\frac{a}{b} u_1 \rightarrow \underline{u} = \begin{pmatrix} 1 \\ -\frac{a}{b} \end{pmatrix}$$

$$P^n = \underline{u} \underline{u}^n \underline{u}^{-1} = \begin{bmatrix} 1 & a \\ 1-b & -a \end{bmatrix} \begin{bmatrix} 1 & 0 \\ 0 & (1-b-a)^n \end{bmatrix} \begin{bmatrix} \frac{b}{a+b} & \frac{a}{a+b} \\ \frac{1}{a+b} & \frac{-1}{a+b} \end{bmatrix} = \frac{1}{a+b} \begin{pmatrix} b & a \\ 1-b & -a \end{pmatrix} + (1-a-b)^n \frac{1}{a+b} \begin{pmatrix} a & -a \\ -b & b \end{pmatrix}$$

Spaltenzerlegung

Wiederholung:

Ein stochastischer Prozess heißt Markovprozess in diskreter Zeit \Leftrightarrow Markoveigenschaft $P(X_n = x_n | X_{n-1} = x_{n-1}, \dots, X_0 = x_0) = P(X_n = x_n | X_{n-1} = x_{n-1})$

homogener Markovkette in diskreter Zeit: homogen $\Leftrightarrow P(X_n = j | X_{n-1} = i) \forall i \in S \wedge n \geq 0$ in n Verschiebungsmoment ist.

\hookrightarrow alle $P(X_{n+m} = j | X_{n+m-1} = i) = P(X_n = j | X_{n-1} = i) = P(X_1 = j | X_0 = i) \Rightarrow P_{ij}$ Übergangswsk., P Übergangsmatrix

Chapman-Kolmogorov Gleichung: $P^{n+m} = P^n \cdot P^m \quad \forall n, m \geq 1$

$P_{ij}^{(m)}$ m stufige Übergangswsk $\Rightarrow P^n$ n stufige Übergangswsk

$P_i^{(0)}$ anfängliche Zustandswsk $\Rightarrow P$ anfängliche Wsk

$P_i^{(n)}$ n stufige Zustandswsk $\Rightarrow u$ stufige Wsk

Vorkenntnisse aus LinAlg:

1) Bilden der Potenz der \underline{P}

$$\underline{P} = \underline{U} \underline{\Lambda} \underline{U}^{-1}$$

$\underline{\Lambda}$ ist diagonale Matrix $\begin{bmatrix} \lambda & 0 & 0 \\ 0 & \lambda & 0 \\ 0 & 0 & \lambda \end{bmatrix}$

$$\underline{P}^n = (\underbrace{\underline{U} \underline{\Lambda} \underline{U}^{-1}}_{n \text{ mal}}) \cdot \dots \cdot (\underline{U} \underline{\Lambda} \underline{U}^{-1}) = \underline{U} \underline{\Lambda}^n \underline{U}^{-1}$$

In Spalten zerlegen

2) Spektralzerlegung (von quadr. Matrix)

$$\underline{A} \underline{u} = \lambda \cdot \underline{u} \rightarrow \begin{array}{l} \underline{u} \text{ ist Eigenvektor} \\ \lambda \text{ ist Eigenwert} \end{array} \quad \underline{A} \cdot \underline{e} = \underline{e} \rightarrow \text{bei stochastischem } \underline{A} \text{ muss ein } \lambda = 1 \text{ sein!}$$

$$(\lambda \underline{I} - \underline{A}) \underline{u} = \underline{0} \rightarrow |\lambda \underline{I} - \underline{A}| = 0 \quad \dots \text{ charakteristische Gleichung (n-dimensional, Ordnung)}$$

$$\lambda = \begin{bmatrix} \lambda & & 0 \\ & \lambda & \\ 0 & & \lambda \end{bmatrix} \quad \underline{u} = [u_1, u_2, \dots] \rightarrow \underline{A} = \underline{U} \underline{\Lambda} \underline{U}^{-1} \quad (\underline{A} \text{ ist diagonalisierbar}) \Leftrightarrow \text{Matrix } \underline{A} \text{ genau } n \text{ unabhängige Eigenvektoren hat}$$

3) Inverses einer Matrix 2. Ordnung

$$\underline{A} = \begin{bmatrix} a_{11} & a_{12} \\ a_{21} & a_{22} \end{bmatrix} \quad \underline{A}^{-1} = \frac{\begin{bmatrix} a_{22} & -a_{12} \\ -a_{21} & a_{11} \end{bmatrix}}{\det \underline{A}}$$

4)

Berechnung von $\underline{U} \underline{A} \underline{U}^{-1}$ mit Hilfe der Diaden

$$\underline{u} = [v_1, v_2, \dots] \quad \begin{bmatrix} v_1 \\ v_2 \end{bmatrix} \begin{matrix} (v) \\ \end{matrix}$$

$$\underline{u}^{-1} = \begin{bmatrix} w_1 \\ \vdots \end{bmatrix} \quad \begin{bmatrix} u_1 \\ u_2 \end{bmatrix} \begin{matrix} [v_1, v_2] \\ \end{matrix} = \begin{bmatrix} u_1 v_1 & u_1 v_2 \\ u_2 v_1 & u_2 v_2 \end{bmatrix}$$

$$1) p_{ij}^{(n)} \geq 0$$

$$2) \sum p_{ij}^{(n)} = 1 \quad \forall i \in S$$

$$\left[\sum_k u_{k,i} \lambda_i w_{k,j} \right] = \sum_j \lambda_j [v_{i,k}] [w_{k,j}]$$

$$\underline{u} = [u_1, u_2, \dots]$$

$$\rightarrow \underline{U} \underline{\Lambda} \underline{U}^{-1} = \sum \lambda_k \overset{\text{Spalte}}{V_k} \overset{\text{Zeile}}{W_k}$$

Simulationsmöglichkeiten:

Laut Übergangsmatrix

Mit Kenntnis der Eigenschaft von Aufenthaltswahrscheinlichkeit $\sim \text{Geo}(1-p_{ii})$

1) Erzeuge eine Zufallsvariable

2) Sprung in Zustand j $\frac{p_{ij}}{1-p_{ii}}$

Aufenthaltswahrscheinlichkeit im Zustand $i \sim \text{Geometrische Verteilung } (1-p_{ii})$

$$\underline{P}^{(n)} = \underline{P}^{(0)} \cdot \underline{P}^{(n)} = \underline{P}^{(0)} \cdot \underline{P}^n$$

$\mathbb{P}(S) = \sum_{k \in \mathbb{Z}} p_k z^k \quad |z| < 1$
 ↳ eindeutige Umkehr für $p_k = \frac{d^k P(z)}{dz^k} \Big|_{z=0}$
 ↳ Bestimmung von Faktoriellen
 $\frac{d^k P(z)}{dz^k} = \sum_{i=1}^k p_i i! = E[D^k]$
 $\frac{d^k P(z)}{dz^k} = E[X(X-1)\dots(X-k+1)]$
 $P(z) = \sum_{k=0}^{\infty} p_k z^k$

Eigenschaften der Zustände

Nachfolger: Ein Zustand ist ein Nachfolger von einem Zustand, wenn es ein n gibt, sodass $P_{ij}^{(n)} > 0$ (Berechnung $i \rightarrow j$)

Kommunizierende Zustände: Die Zustände i und j sind kommunizierend, wenn i Nachfolger von j und j Nachfolger von i
 d.h. $i \rightarrow j$ und $j \rightarrow i$ (\Rightarrow ist Äquivalenzrelation (RST))

Periode eines Zustandes: Die Periode eines Zustandes ist durch $d(i) = \text{ggT}\{n > 0, P_{ii}^{(n)} > 0\}$ gegeben

Aperiodischer Zustand: Zustand i ist aperiodisch, wenn $\exists n_0$ sodass $P_{ii}^{(n)} > 0 \quad \forall n \geq n_0$

Periodischer Zustand: Zustand i ist periodisch mit Periode $d(i)$, wenn $d(i) \geq 2$ (sonst aperiod.)

Rekurrenter und Transienter Zustand

$\tau_i^* = \inf\{n > 1, X_n = i \mid X_0 = i\}$ - Rückkehrzeit

$\tau_i = \inf\{n > 1, X_n = i\}$ - Rückkehr oder Übergangszeit

Der Zustand i einer DTMC ist rekurrent wenn $P(\tau_i^* < \infty) = 1$, sonst (bei $P(\tau_i^* < \infty) < 1$) ist es transient

ODER Ein Zustand ist rekurrent wenn $\sum_{n=0}^{\infty} P_{ii}^{(n)} = \infty$, sonst (bei $\sum_{n=0}^{\infty} P_{ii}^{(n)} < \infty$) ist es transient.

↗ äquivalente Definition

Beweis für 1&2

$f_{ii}^{(n)} = P(\tau_i^* \leq n) = P(\text{erste Rückkehr in den ersten } n \text{ Übergängen})$

$f_{ii} = \sum_{n=1}^{\infty} f_{ii}^{(n)} = P(\tau_i^* < \infty)$

$P_{ii}^{(n)} = \sum_{j=1}^k f_{ij}^{(k)} \cdot P_{ij}^{(n-k)} \quad | \sum_{n=1}^{\infty} z^n$

$\sum_{n=1}^{\infty} P_{ii}^{(n)} z^n = \sum_{n=1}^{\infty} \sum_{j=1}^k f_{ij}^{(n)} P_{ij}^{(n)} z^n = \sum_{j=1}^k \sum_{n=1}^{\infty} f_{ij}^{(n)} z^n \cdot \sum_{m=1}^{\infty} P_{ij}^{(m)} z^m = \sum_{j=1}^k \underbrace{\sum_{n=1}^{\infty} f_{ij}^{(n)} z^n}_{f_{ij}(z)} \cdot \underbrace{\sum_{m=1}^{\infty} P_{ij}^{(m)} z^m}_{P_{ij}(z)}$

$P_{ii}(z) = 1$

$P_{ii}(z) - 1 = F_{ii}(z) P_{ii}(z)$

$F_{ii}(z) [1 - P_{ii}(z)] = 0$

$P_{ii}(z) = \frac{1}{1 - F_{ii}(z)}$

$z < 1 \quad F_{ii}(z) = \sum_{n=1}^{\infty} P_{ii}^{(n)} z^n$

$F_{ii}(z) = \sum_{n=1}^{\infty} f_{ii}^{(n)} z^n = P(\tau_i^* < \infty)$

$P(\tau_i^* < \infty) = 1 \Rightarrow \sum_{n=0}^{\infty} P_{ii}^{(n)} = \infty$

$P(\tau_i^* < \infty) < 1 \Rightarrow \sum_{n=0}^{\infty} P_{ii}^{(n)} < \infty$

Alle vier Definitionen sind äquivalent!

ODER Ein Zustand ist rekurrent wenn $P(r_i^* = \infty) = 1$ sonst ($P(r_i^* = \infty) < 1$) ist es transient

$\{N_i\}$

$r_i^* = \# \{n > 0, X_n = i \mid X_0 = i\}$ Anzahl der Rückkehrer

$v_i^* = \# \{n > 0, X_n = i\}$ Anzahl der Rückkehrer oder Übergang

ODER Ein Zustand ist rekurrent wenn $E[r_i^*] = \infty$ sonst (bei $E[r_i^*] < \infty$) ist es transient

Beweis für 3

$Q_{ii}^{(n)} = P(r_i^* = n)$

$Q_{ii} = \lim_{n \rightarrow \infty} Q_{ii}^{(n)} = P(r_i^* = \infty)$

$Q_{ii}^{(n)} = \sum_{k=1}^n f_{ii}^{(k)} \cdot Q_{ii}^{(n-k)} = f_{ii}^{(n)} + Q_{ii}^{(n)}$

$Q_{ii}^{(n)} = P(\tau_i^* < \infty) = f_{ii}^{(n)} + Q_{ii}^{(n)}$

Wenn $f_{ii} = P(\tau_i^* < \infty) = 1 \Rightarrow \lim_{n \rightarrow \infty} Q_{ii} = P(r_i^* = \infty) = 1$
 $f_{ii} + P(\tau_i^* < \infty) < 1 \Rightarrow \lim_{n \rightarrow \infty} Q_{ii} = P(r_i^* = \infty) < 1$

Beweis für 4 (und alle)

Ereignis $A_n = \text{DTMC befindet sich nach } n \text{ten Übergang im Zustand } i; X_n = i \quad (X_0 = i, X_{-1} = i)$

$v_i^* = \sum_{n=0}^{\infty} 1_{A_n}$

$E[v_i^*] = E[\sum_{n=0}^{\infty} 1_{A_n}] = \sum_{n=0}^{\infty} E[1_{A_n}] = \sum_{n=0}^{\infty} P(A_n)$

Positiv rekurrent Ein rekurrenter Zustand ist positiv rekurrent, wenn $E[\tau_i^*] < \infty$

nullrekurrenter Zustand Ein rekurrenter Zustand ist positiv rekurrent, wenn ($E[\tau_i^*] < \infty$) ist es nullrekurrent

Absorbierender Zustand: Ein Zustand i ist absorbierend, wenn er keine Übergänge in einen anderen Zustand hat.

Folgerungen: aperiodisch, rekurrent $\sum_{n=0}^{\infty} P_{ii}^{(n)} = \sum_{n=0}^{\infty} 1 = \infty$

Klassen: Die von kommunizierend als Äquivalenzrelation partitionierte Menge einer DTMC heißen Klassen.

irreduzible Markovkette in Diskreter Zeit: Eine DTMC ist irreduzibel, wenn sie aus genau einer Klasse besteht.

Klasseneigenschaft: Eine Eigenschaft heißt klasseneigenschaft, wenn sie entweder für alle Zustände der Klasse oder für keine gilt.

Eigenschaften der Klassen: Periode, Rekurrenz / Transienz, Positive Rekurrenz / Nullrekurrenz

1) Periode: Zustände k_j sind kommunizierend

$$P_{jk}^{(n)} > 0$$

$$P_{kj}^{(s)} > 0$$

$$P_{jj}^{(n+s)} \geq P_{jk}^{(n)} \cdot P_{kj}^{(s)} > 0 \Rightarrow d(i) | n+s$$

Existiert ein n sodass $P_{kk}^{(n)} > 0$

$$P_{jj}^{(r+m+s)} \geq P_{jk}^{(s)} \cdot P_{kk}^{(m)} \cdot P_{ki}^{(r)} > 0 \Rightarrow d(j) | r+m+s$$

$$\left. \begin{array}{l} d(i) | n \Rightarrow d(j) | d(i) \\ \text{für alle } n \text{ auf } P_{kk}^{(n)} > 0 \\ \text{umgekehrt gilt's auch: } d(k) | d(j) \end{array} \right\} \Rightarrow d(j) = d(k)$$

2) Rekurrenz, Transienz: Zustände j, k sind kommunizierend

$$a = P_{jk}^{(n)} > 0 \quad b = P_{kj}^{(s)} > 0$$


! | Kann man nicht lesen

$$P^{(r+m+s)} \geq P_{jk}^{(s)} \cdot P_{kk}^{(m)} \cdot P_{kj}^{(r)}$$

$$\sum_{r=1}^{\infty} P^{(r+m+s)} \geq \sum_{r=1}^{\infty} P_{jk}^{(s)} \cdot P_{kk}^{(m)} \cdot P_{kj}^{(r)} = ab \sum_{r=1}^{\infty} P_{rr}^{(m)}$$

Wenn r rekurrent, $\sum_{r=1}^{\infty} P_{rr}^{(m)} = \infty \Rightarrow \sum_{r=1}^{\infty} P_{ii}^{(r+j+k)} = \infty \rightarrow$ Zustand i ist auch rekurrent

Wenn j transient, $\sum_{r=1}^{\infty} P_{rr}^{(m)} < \infty \Rightarrow \sum_{r=1}^{\infty} P_{rr}^{(m)} < \infty$ Zustand P ist auch transient



- klasse 1 absorbiert
- klasse 2, 3, 4 transient
- klasse 5, 6 rekurrent
- Knoten = Zustände
- Kanten = Wahrscheinlichkeit

Zustand 8 $\sum_{r=1}^{\infty} P_{ii}^{(rn)} = \sum_{r=1}^{\infty} 1 = \infty \rightarrow$ rekurrent

Zustand 1 $f_{11}^{(1)} = \frac{1}{2}$

$$f_{11}^{(2)} = \frac{1}{3} + \frac{1}{6} = \frac{1}{2}$$

$$f_{11}^{(n)} = 0 \quad n \geq 3$$

$$\left. \begin{array}{l} \Rightarrow P(\tau_1^* < \infty) < f_{11} = \sum_{r=1}^{\infty} f_{11}^{(r)} = f_{11}^{(1)} + f_{11}^{(2)} = \frac{1}{2} + \frac{1}{2} = 1 \\ E[\tau_1^*] = \sum_{n=1}^{\infty} n f_{11}^{(n)} = 1 \cdot \frac{1}{2} + 2 \cdot \frac{1}{2} = 1,5 < \infty \end{array} \right\} \Rightarrow \text{Zustand 1 ist positiv rekurrent}$$

klasse 5 Periode 3

klasse 4 Periode 2

Zustand 0:

$$T_{\{1,2,3\}} = \begin{bmatrix} \frac{1}{2} & \frac{1}{6} \\ 1 & 0 \end{bmatrix} \rightarrow \text{Substochastisch}$$

$$\sum_{i=0}^{\infty} f_{00} = P_{01} [T_{\{1,2,3\}}] P_{10} = 1 \cdot 3 \cdot \frac{1}{3} = 1 \rightarrow \text{Zustand 0 ist rekurrent}$$

\underline{T} ist substochastisch & $\sum_i T_{i,j} < \infty$ wenn alle $| \lambda_i | < 1 = \sum_{n=0}^{\infty} T_{\{1,2,3\}}^n < \infty$

$$\sum_{n=0}^{\infty} T_{\{1,2,3\}}^n = [\underline{T} - \underline{I}]^{-1} = \begin{bmatrix} \frac{1}{2} & -\frac{1}{2} \\ -1 & 1 \end{bmatrix}^{-1} = \frac{1}{\frac{1}{2} - \frac{1}{6}} \begin{bmatrix} 1 & 1/6 \\ 1 & 1/2 \end{bmatrix} = 3 \begin{bmatrix} 1 & 1/6 \\ 1 & 1/2 \end{bmatrix}$$

stationäre Verteilung einer DTMC und Grenzverteilung einer DTMC

Def: Die stationäre Verteilung einer DTMC ist durch die Lösung des folgenden linearen Gleichungssystems gegeben:

$$\underline{p} = \underline{p} \underline{P} \quad \underline{p} \cdot \underline{P} = \underline{1} \quad (\text{wobei } \underline{p} \text{ ist Spaltenvektor bestehend aus } 1 \text{em})$$

Folgerungen:

$$\underline{p}^{(0)} = \underline{p} \Rightarrow \underline{p}^{(1)} = \underline{p}^{(0)} \underline{P} = \underline{p} \underline{P} = \underline{p} \Rightarrow \text{rekursiv } \underline{p}^{(n)} = \underline{p} \quad \forall n \geq 0 \quad (\text{1D Randverteilung von Kette ist } \underline{p})$$

also stationäre Version

ndimensionale Randverteilung $\underline{p}^{(0)} = \underline{p}$

$$\begin{aligned} P(x_n = i_0, \dots, x_{n+1} = i_m) &\rightarrow P(x_n = i_0) P(x_{n+1} = i_1 | x_n = i_0) P(x_{n+2} = i_2 | x_n = i_0, x_{n+1} = i_1) \dots P(x_{n+n} = i_n | x_n = i_0, \dots, x_{n+n-1} = i_m) = \\ &\stackrel{\text{'kürzen' durch Markov-Eigenschaft}}{=} P(x_n = i_0) P(x_{n+1} = i_1 | x_n = i_0) P(x_{n+2} = i_2 | x_{n+1} = i_1) \dots P(x_{n+n} = i_n | x_{n+n-1} = i_m) = \\ &= p_{i_0}^{(n)} p_{i_0, i_1} \dots p_{i_{m+1}, i_n} \quad \leftarrow \text{gleich!} \\ &\downarrow \\ &= P(x_{n+1} = i_0, x_{n+2} = i_1, \dots) = p_{i_0}^{(n)} p_{i_0, i_1} \dots p_{i_{m+1}, i_n} \end{aligned}$$

Die Markovkette in diskreter Zeit $\underline{p}^k = \underline{p}$ ist ein stationärer Prozess (und somit eine stationäre Version der DTMC)

Diese Version der DTMC (also wenn 1D + nD) ist stationär

Fundamentale Grenzverhalte der Markovkette in diskreter Zeit

Wenn DTMC irreduzibel, aperiodisch und rekurrent ist, dann sind die Grenzwerte

$$1) \lim_{n \rightarrow \infty} p_{ij}^{(n)} = \frac{1}{M_j} = \frac{1}{\sum_i n_{ij}^{(n)}} = \begin{cases} < \infty & \text{wenn Zustand } j \text{ positiv rekurrent ist.} \\ 0 & \text{wenn Zustand } j \text{ der Nullwert ist.} \end{cases}$$

Erwartungswert

2) vom Anfangszustand unabhängig

$$\lim_{n \rightarrow \infty} p_{ij}^{(n)} = \lim_{n \rightarrow \infty} p_{ij}^{(n)} \quad \forall i \in S \quad \leftarrow \text{Zustandraum}$$

Folgerungen:

$$a) \underline{p}_{ij}^{(\infty)} = \lim_{n \rightarrow \infty} p_{ij}^{(n)} = \lim_{n \rightarrow \infty} \sum_{i \in S} p_i^{(0)} \cdot p_{ij}^{(n)} = \sum_{i \in S} p_i^{(0)} \lim_{n \rightarrow \infty} p_{ij}^{(n)} = \lim_{n \rightarrow \infty} p_{ij}^{(n)} = p_{ij}^{(\infty)}$$

unabh. von i

Zeilen der Matrix sind gleich!

(Zeilen von $\underline{p}^{(0)}$ sind gleich)

also Zeilen $\rightarrow \begin{bmatrix} x \\ x \\ x \end{bmatrix}$

nach so vielen Schritten ist Verteilung genau gleich mit so einer Matrix (?)

$$b) \underline{p}^{(\infty)} = \underline{p}^{(0)} \cdot \underline{p}^{(\infty)}$$

$$\underline{p}^{(\infty)} = \begin{pmatrix} p_0^{(\infty)} \\ \vdots \\ p_n^{(\infty)} \end{pmatrix} = \begin{pmatrix} p_0^{(0)} & p_1^{(0)} & \dots & p_j^{(0)} \\ p_0^{(0)} & p_1^{(0)} & \dots & p_j^{(0)} \\ \vdots & \vdots & \ddots & \vdots \\ p_0^{(0)} & p_1^{(0)} & \dots & p_j^{(0)} \end{pmatrix}$$

$$(a_0 \ a_1 \ \dots \ a_j \ \dots) \begin{pmatrix} p_0^{(0)} & p_1^{(0)} & \dots & p_j^{(0)} \\ p_0^{(0)} & p_1^{(0)} & \dots & p_j^{(0)} \\ \vdots & \vdots & \ddots & \vdots \\ p_0^{(0)} & p_1^{(0)} & \dots & p_j^{(0)} \end{pmatrix} = \begin{pmatrix} \sum_i a_i p_0^{(0)} \\ \vdots \\ \sum_i a_i p_j^{(0)} \end{pmatrix}^T$$

Wenn eine DTMC irreduzibel, aperiodisch und positiv rekurrent ist, dann sind die Grenzwerte $\lim_{n \rightarrow \infty} p_{ij} = \lim_{n \rightarrow \infty} p_j$ eine

Wahrscheinlichkeitsverteilung $\underline{p}^{(\infty)} \cdot \underline{e} = \underline{1}$ und diese eindeutig mit dem folgenden GLS bestimmt werden können:

$$\underline{p}^{(\infty)} = \underline{p}^{(\infty)} \underline{P} \quad \underline{p}^{(\infty)} \cdot \underline{e} = \underline{1}$$

Folgerung: $\underline{p}^{(\infty)} = \underline{p}$

Grenzwertkette \rightarrow stationäre Verteilung

Beweis: Aus zweiter Aussage folgt 1. Aussage \rightarrow zur 2. Aussage muss bewiesen werden.

x_k = Lösung des Gleichungssystems


$$x_k = \sum_{i \in S} x_i P_{ij} \quad | \sum_{i \in S} x_i = 1$$

$$\sum_{i \in S} x_i P_{ik} = \sum_{i \in S} \sum_{j \in S} x_i P_{ij} P_{jk} = \sum_{i \in S} x_i P_{ik} \Rightarrow x_k = \sum_{i \in S} x_i P_{ik} \dots \text{Rekursiv weiter machen} \Rightarrow$$


$$\begin{aligned} x_k &= \sum_{i \in S} x_i P_{ik} \geq 1 \\ \lim_{n \rightarrow \infty} x_k &= \lim_{n \rightarrow \infty} \sum_{i \in S} x_i P_{ik}^{(n)} = \sum_{i \in S} x_i \lim_{n \rightarrow \infty} P_{ik}^{(n)} \\ &= \lim_{n \rightarrow \infty} p_{ij}^{(n)} = \lim_{n \rightarrow \infty} p_j^{(n)} = \underline{p}^{(\infty)} \end{aligned}$$

Eine DTMC ist irreduzibel, periodisch und rekurrent, dann

- Existieren die Grenzwerte $\lim_{n \rightarrow \infty} P_{ij}^{(n)}$ nicht.
- Existieren die Grenzwerte $\lim_{n \rightarrow \infty} \frac{1}{n} \sum_{k=1}^n P_{ij}^{(k)}$ schon.



$$\begin{aligned}
 P_{11}^{(m)} &= 1 & P_{11}^{(2m)} &= 1 \\
 P_{11}^{(m+1)} &= 0 & P_{11}^{(2m+1)} &= 0 \\
 P_{11}^{(m+2)} &= 0 & P_{11}^{(2m+2)} &= 1 \\
 P_{11}^{(m+5)} &= 1 & &
 \end{aligned}$$



Relationen in den verschiedenen Verteilungen für irreduzible, positiv rekurrente DTMC

| Zustand i | stationäre Verteilung P_i | $\lim_{n \rightarrow \infty} \frac{1}{n} \sum_{k=1}^n P_i^{(k)}$ | Grenzwertverteilung $P_i^{(oo)} = \lim_{n \rightarrow \infty} P_i^{(n)}$ |
|-------------|-----------------------------|--|--|
| aperiodisch | alle 3 Grenzwerte | existieren und | sind gleich! |
| periodisch | Grenzwerte existieren | und sind gleich | \neq → existiert nicht! |

Absorption

Eine DTMC hat eine Menge von rekurrenten Zuständen (C) und eine transiente Klasse (T)

Absorptionswahrscheinlichkeit: $a_i = P(\text{Absorption in } C \text{ findet in endlicher Zeit statt} \mid X_0 = i)$ ($i \in T$)

↳ berechnen: Wenn eine DTMC eine Menge von rekurrenten Zuständen und eine transiente Klasse hat, dann sind die Absorptionswsk die kleinsten nicht negativen Lösungen folgendes LGS:

$$\begin{aligned}
 a_i &= 1 \quad i \in C \\
 a_i &= \sum_j P_{ij} \cdot a_j \quad i \in T
 \end{aligned}$$

Beweis: $a_i^{(n)} = P(\text{Die Kette befindet sich nach } n \text{ Übergängen in } C \mid X_0 = i)$, $i \in T$ (Übergang C kann nach k Schritten passieren $0 \leq k \leq n$)

$$1) a_i^{(m+1)} = \sum_{j \in T} P_{ij} a_j^{(m)} + \sum_{j \in C} P_{ij} \cdot 1$$

$$2) \gamma_i \geq a_i^{(0)} = 0 \quad (\text{mit mathematische Induktion})$$

$$2) a_i^{(m+1)} \geq a_i^{(m)} \quad (\text{mit Induktion})$$

$$a_i^{(m)} = 0$$

$$\gamma_i \geq a_i^{(m)} \Rightarrow \gamma_i \geq a_i^{(m+1)}$$

$$a_i^{(m+1)} = \sum_j P_{ij} a_j^{(m+1)} + \sum_{j \in C} P_{ij} \cdot 1$$

$$a_i^{(m+1)} = \sum_{j \in T} P_{ij} a_j^{(m)} + \sum_{j \in C} P_{ij} \cdot 1 \geq \gamma_i = \sum_{j \in T} P_{ij} \gamma_j + \sum_{j \in C} P_{ij} \cdot 1$$

$$a_i^{(n+1)} = \sum_j P_{ij} a_j^{(n)} + \sum_{j \in C} P_{ij} \cdot 1$$

$$\Rightarrow \gamma_i \geq a_i^{(m)} \quad \forall m \geq 1$$

$$\gamma_i \geq a_i \quad (a_i^{(0)}) \text{ monoton steigend und } a_i = \lim_{n \rightarrow \infty} a_i^{(n)}$$

$$3) \lim_{n \rightarrow \infty} a_i^{(n+1)} = \lim_{n \rightarrow \infty} \sum_j P_{ij} a_j^{(n)} + \sum_{j \in C} P_{ij} \cdot 1$$

$$\underbrace{\lim_{n \rightarrow \infty} a_i^{(n+1)}}_{a_i}$$

$$a_i = \sum_{j \in T} P_{ij} a_j + \sum_{j \in C} P_{ij} \cdot 1 = \sum_{j \in C} P_{ij} a_j$$

Relation für Absorptionswahrscheinlichkeit in Matrix/Vektorform

$$\underline{a} = [a_i] \quad i \in T \quad \underline{a} \text{ ist Spaltenvektor}$$

$$\underline{I} = [P_{ij}] \quad j \in T$$

$$\underline{e} = [P_{ij}] \quad i \in T, j \in C$$

$$\underline{a} = [\underline{I} - \underline{T}]^{-1} \underline{e}$$

Relation für Absorptionswahrscheinlichkeit in Matrix/Vektorform

$\underline{a} = [a_i] \quad i \in T \quad \underline{a}$ ist Spaltenvektor

$\underline{T} = [P_{ij}] \quad j \in T$

$\underline{c} = [c_j] \quad i \in T, j \in C$

$\underline{q} = [\underline{I} - \underline{T}]^{-1} \underline{c} \underline{e}$

Beweis: $a_i = \sum_{j \in C} P_{ij} a_j \quad i \in T$

$a_i = \sum_{j \in T} P_{ij} a_j + \sum_{j \in C} P_{ij} \cdot 1 \quad i \in T$

$\underline{a} = \underline{T} \underline{a} + \underline{c} \underline{e}$

$(\underline{I} - \underline{T}) \underline{a} = \underline{c} \underline{e}$


$\underline{a} = (\underline{I} - \underline{T})^{-1} \underline{c} \underline{e}$

$\sum_{n=0}^{\infty} \underline{T}^n \rightarrow \text{Kil} < 1 \Rightarrow T \text{ ist substochastisch}$

Alternativer Beweis

$\sum P(\text{Absorption der Menge } C \text{ (oder Zustand } j \text{ erreicht)}) = \sum_{j \in C} \sum_{n=0}^{\infty} (\text{Absorption nach } n \text{ Übergängen der Klasse } T \text{ im Zustand } j \in C \text{ stattfindet}) =$
 $= \sum \sum \underline{T}^n [\underline{c}] = \sum \underline{T}^n \underline{c} \underline{e} = (\underline{I} - \underline{T})^{-1} \underline{c} \underline{e}$

BSP



absorbierendes Zustand
transient

$P = \begin{bmatrix} 1 & 0 & 0 & 0 \\ \alpha & 1-(\alpha+\beta) & \beta & 0 \\ 0 & \delta & 1-(\gamma+\delta) & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} \Rightarrow$

$\underline{T} = \begin{bmatrix} \alpha & 0 \\ 0 & \delta \end{bmatrix}$

$\underline{c} \cdot \underline{e} = \begin{bmatrix} \alpha \\ \delta \end{bmatrix}$

$[\underline{I} - \underline{T}]^{-1} = \begin{bmatrix} \alpha+\beta & -\beta \\ -\delta & \gamma+\delta \end{bmatrix}^{-1} = \frac{1}{(\alpha+\beta)(\gamma+\delta) - \beta\delta} \begin{bmatrix} \gamma+\delta & \beta \\ \delta & \alpha+\beta \end{bmatrix}$

$\underline{q} = [\underline{I} - \underline{T}]^{-1} \underline{c} \underline{e} = \begin{bmatrix} \alpha(\gamma+\delta) + \beta\delta \\ \delta\alpha + (\alpha+\beta)\delta \end{bmatrix} \frac{1}{\alpha\gamma + \alpha\delta + \beta\delta} = \begin{bmatrix} 1 \\ 1 \end{bmatrix}$ WSK absorbiert zu werden, wenn bei ① aufgefangen wird
WSK bei ② aufzufangen

wenn man nur Zustand 0 oder 3 betrachtet:

$\underline{c}_0 = \begin{pmatrix} \alpha \\ 0 \end{pmatrix} \Rightarrow \underline{c}_0 \cdot \underline{e} = \begin{pmatrix} \alpha \\ 0 \end{pmatrix} \Rightarrow \underline{q}_0 = \frac{1}{\alpha\gamma + \alpha\delta + \beta\delta} \begin{bmatrix} \gamma+\delta & \beta \\ \delta & \alpha+\beta \end{bmatrix} \begin{pmatrix} \alpha \\ 0 \end{pmatrix} = \begin{bmatrix} \alpha(\gamma+\delta) \\ \delta\alpha \end{bmatrix} \frac{1}{\alpha\gamma + \alpha\delta + \beta\delta}$

$\underline{c}_3 = \begin{pmatrix} 0 \\ \delta \end{pmatrix} \Rightarrow \underline{c}_3 \cdot \underline{e} = \begin{pmatrix} 0 \\ \delta \end{pmatrix} \Rightarrow \underline{q}_3 = \frac{1}{\alpha\gamma + \alpha\delta + \beta\delta} \begin{bmatrix} \gamma+\delta & \beta \\ \delta & \alpha+\beta \end{bmatrix} \begin{pmatrix} 0 \\ \delta \end{pmatrix} = \begin{bmatrix} \beta\delta \\ (\alpha+\beta)\delta \end{bmatrix} \frac{1}{\alpha\gamma + \alpha\delta + \beta\delta}$

Mittlere Zeit bis zur Absorption: Wenn eine DTHC wieder aus den Mengen T und C besteht, können die mittleren Absorptionszeiten mit folgendem GLS bestimmt werden:

$t_i = 0 \quad i \in C$

$t_i = 1 + \sum_{j \in T} P_{ij} \cdot t_j \quad i \in T$

Relation für mittlere Absorptionszeiten in Matrix/Vektorform:

$\underline{t} = [t_i] \quad i \in T \quad \text{Spaltenvektor}$

$\underline{t} = [\underline{I} - \underline{T}]^{-1} \underline{e}$

Rechnung $1 = 1 + \sum_{j \in T} P_{ij} t_j \quad i \in T$

$\underline{t} = \underline{e} + \underline{T} \underline{t} \Rightarrow (\underline{I} - \underline{T}) \underline{t} = \underline{e}$

$\underline{t} = [\underline{I} - \underline{T}]^{-1} \underline{e}$

Varianz der Absorptionszeit:

$v_i = 0 \quad i \in C$

$v_i = \sum_{j \in C} P_{ij} (1 + t_j - t_i)^2 + \sum_{j \in T} P_{ij} v_j \quad i \in T$

Voraussetzungen für Zustände und Klasseeigenschaften

Irreduzibilität - hinreichende Kriterien

Übergangsmatrix Die WSK in den Nebendiagonalen der \underline{P} über und unter der Hauptdiagonale sind positiv.
 Zustandsdiagramm: Es gibt einen Übergang von allen Zuständen, ein Zustand hinauf und hinunter.



aperiodischer Zustand (hinreichende Kriterien)

Übergangsmatrix Die WSK in Hauptdiagonale sind positiv.

Zustandsdiagramm Es gibt ein "loop" in jedem Zustand zu sich selbst mit positiven Nebendiagonalen
 ↳ Selbstlufe

rekurrenter Zustand

sind der Zustand ϕ

Für ein irreduzible DTMC, und durch die Irreduzibilität alle Zustände genau dann rekurrent, wenn die kleinste nichtnegative Lösung (für $a_i = 1$ für $i \geq 1$) durch folgende Gleichung gegeben ist:

$$a_0 = 1$$

$$a_i = \sum_j P_{ij} a_j \quad \text{für } i \geq 1$$

$$\left\{ n > 0 \quad x_n = i \left\{ \begin{array}{l} x_0 = j \\ \uparrow \\ x_0 = j \quad i \geq 1 \end{array} \right. \right\} \rightarrow P(\tau_i^+ < \infty) \leq 1$$

positiv rekurrenter Zustand (hinreichende Bedingung)

Foster Kriterium: Sei eine DTMC irreduzibel. Wenn die Zahlen $I \geq 1, c > 0, d > 0$ existieren und der Erwartungswert ist

$$E[x_{n+1} | x_n = k] = \begin{cases} \leq c & \text{für } k \leq I \\ \leq k - d & \text{für } k > I \end{cases} \quad \text{dann ist die DTMC positiv rekurrent.}$$

Ergänzungen

- Allgemeine Struktur einer DTMC

$$P = \begin{pmatrix} \boxed{K_1} & & & \\ & \boxed{K_2} & & \\ & & \dots & \\ & & & \boxed{T} \end{pmatrix}$$

T... Menge der Transienten Zustände
 (Bestehend aus einer oder mehreren Klassen)

- Endliche DTMC: Hat endliche Anzahl von Zuständen

Eine endliche DTMC muss mindestens einen rekurrenten Zustand haben.

Beweis:

$$\lim_{n \rightarrow \infty} \sum_{j=0}^{m-1} P_{ij}^{(n)} = 1 \Rightarrow \sum_j \lim_{n \rightarrow \infty} P_{ij}^{(n)} = \left(\lim_{n \rightarrow \infty} P_i^{(n)} = P_j^{(n)} \right) = 1$$

Existiert ein $j \in \{0, \dots, M_j\}$ wo für $\lim_{n \rightarrow \infty} P_{ij}^{(n)} > 0$ so ist es positiv rekurrent.

Folgerung: Eine irreduzible DTMC ist immer auch positiv rekurrent.


Markkette in stetiger Zeit CTMC

Ein paar Begriffe ...

... Ein stochastischer Prozess $(X(t), t \geq 0)$ heißt Markovprozess in stetiger Zeit, wenn er die Markoveigenschaften erfüllt.

$$P(X(t_n) = x_n | X(t_{n-1}) = x_{n-1}, \dots, X(t_1) = x_1, X(t_0) = x_0) = P(X(t_n) = x_n | X(t_{n-1}) = x_{n-1}) \quad \forall t_0 < t_1 < \dots < t_n \text{ und } x_i \in S \text{ für } i=0,1,2,\dots$$

... homogene CTMC: Ist homogen, wenn $P(X(s+t) = j | X(s) = i) = P(X(t) = j | X(0) = i) \quad \forall t, s \geq 0 \text{ und } i, j \in S$



... Chapman Kolmogorov: $\underline{P}(s+t) = \underline{P}(s) \cdot \underline{P}(t)$

$$P_i(0) \Rightarrow P(0) \\ P_i(t) \Rightarrow P(t)$$

Infinitesimale Parameter

$$\lim_{t \rightarrow 0} P_{ij}(t) = \delta_{ij} = \begin{cases} 1 & \text{wenn } i=j \\ 0 & \text{wenn } i \neq j \end{cases}$$

$\Rightarrow P_{ij}(t)$ ist stetig zum Zeitpunkt $t=0$

↳ notwendige Bedingung dass Ableitung existiert

$$q_{ij} = \lim_{t \rightarrow 0^+} \frac{P_{ij}(t) - \delta_{ij}(t)}{t} = \lim_{t \rightarrow 0^+} \frac{P_{ij}(t) - \delta_{ij}(t)}{t} = \frac{dP_{ij}(t)}{dt} \Big|_{t=0} = \frac{d}{dt} P(X(t) = j | X(0) = i) = \frac{d}{dt} P(X(t+T) = j | X(T) = i) \Big|_{t=0}$$

Folge immer Positiv weil es kommt von 0 Homogenität "zum Zeitpunkt $t=0$ "

$$q_{ij} \geq 0 \text{ für } i \neq j$$

$$q_{ii} < 0 \text{ für } i=j \quad (q_{ii} = -\infty \text{ kann auch vorkommen!})$$

• Erzeuger / Generatormatrix

$$\underline{Q} = [q_{ij}] = \lim_{t \rightarrow 0^+} \frac{\underline{P}(t) - \underline{I}}{t} = \lim_{t \rightarrow 0^+} \frac{\underline{P}(t) - \underline{I}}{t}$$

Kriterien für Infinitesimalparameter

1) CTMC ist konservativ wenn $q_{ii} > -\infty \quad \forall i \in S$, $\sum_{j \in S} q_{ij} = 0 \quad \forall i \in S$

$$2) \inf q_{ii} > -\infty \quad \forall i \in S \Rightarrow \sum_{j \in S} q_{ij} = \sum_{j \in S} \lim_{t \rightarrow 0} \frac{P_{ij}(t) - \delta_{ij}(t)}{t} = \lim_{t \rightarrow 0} \sum_{j \in S} \frac{[P_{ij}(t) - \delta_{ij}(t)]}{t} = \lim_{t \rightarrow 0} 0 = 0$$

Kolmogorov Gleichungen

Rückwärtsgleichung: Wenn eine CTMC 1) erfüllt, dann gilt

$$\underline{P}'(t) = \underline{Q} \underline{P}(t) = \lim_{\Delta t \rightarrow 0^+} \frac{\underline{P}(t+\Delta t) - \underline{P}(t)}{\Delta t} = \lim_{\Delta t \rightarrow 0^+} \frac{\underline{P}(t) \underline{P}(\Delta t) - \underline{P}(t)}{\Delta t} = \lim_{\Delta t \rightarrow 0^+} \frac{\underline{P}(t) [\underline{P}(\Delta t) - \underline{I}] + \underline{P}(t)}{\Delta t} = \lim_{\Delta t \rightarrow 0^+} \frac{\underline{P}(t) [\underline{P}(\Delta t) - \underline{I}]}{\Delta t} \cdot \underline{P}(t)$$

Korwärtsgleichung: Wenn eine CTMC 2) erfüllt, dann gilt

$$\underline{P}'(t) = \underline{P}(t) \underline{Q} = \lim_{\Delta t \rightarrow 0^+} \frac{\underline{P}(t+\Delta t) - \underline{P}(t)}{\Delta t} = \lim_{\Delta t \rightarrow 0^+} \frac{\underline{P}(t) \underline{P}(\Delta t) - \underline{P}(t)}{\Delta t} = \lim_{\Delta t \rightarrow 0^+} \underline{P}(t) \frac{\underline{P}(\Delta t) - \underline{I}}{\Delta t} = \underline{P}(t) \lim_{\Delta t \rightarrow 0^+} \frac{\underline{P}(\Delta t) - \underline{I}}{\Delta t}$$

Lösung: $\underline{P}(t) = e^{\underline{Q}t}$

Interpretation des Verhaltens einer CTMC

• Interpretation der Infinitesimalen Parameter

q_{ij} Die Parameter der exponential verteilten Aufenthaltsdauer im Zustand i vor einem Übergang in den Zustand j

$$X_i = \min X_{ij}, \quad X_{ij} \sim \text{Exp}(q_{ij})$$

$$P(X_i < j) = 1 - P(X_i > t) = 1 - \prod_{j \neq i} P(X_{ij} > t) = 1 - \prod_{j \neq i} e^{-q_{ij}t} = 1 - e^{-\sum_{j \neq i} q_{ij}t} = 1 - e^{q_{ii}t} = 1 - e^{-(\sum_{j \neq i} q_{ij})t}$$

$$\sum_j q_{ij} = 0 \Leftrightarrow q_{ii} + \sum_{j \neq i} q_{ij} = 0 \Rightarrow q_{ii} = -\sum_{j \neq i} q_{ij}$$

q_{ii} (-1) mal mal die Parameter der exp. verteilten Aufenthaltsdauer im Zustand i

Kurzzeitverhalten

- $P(x(t+\Delta t) = j | x(t) = i) = P_{ij}(\Delta t) = q_{ij} \Delta t + o(\Delta t)$
- $P(x(t+\Delta t) = i | x(t) = i) = P_{ii}(\Delta t) = 1 + q_{ii} \Delta t + o(\Delta t) \quad \| 1 - \sum_{j \neq i} q_{ij} \Delta t = 1 + q_{ii} \Delta t$
- $P(x(t+\Delta t) = j, x(t + \frac{\Delta t}{2}) = k | x(t) = i) = o(\Delta t)$
- $P(x(t+\Delta t) \neq i | x(t) = i) = \sum_{j \neq i} q_{ij} \Delta t + o(\Delta t) = -q_{ii} \Delta t + o(\Delta t)$

Poisson?
von i irgendwo hin

Simulation einer CTMC (2 Arten)

- 1) laut Interpretation von Q
Parallel verlaufende, exponential verteilte Zufallsvariablen simuliert $\sim \text{Exp}(q_{ij})$
Übergang in Zustand, welcher von $k_i \sim \min X_{ij}$ bestimmt wird.
- 2) Mit Hilfe von eingebetteter DTMC
Aufenthaltsdauer in Zustand $i \sim \text{Exp}(-q_{ii})$
Übergang nach $j \neq i$ mit WSK $\frac{q_{ij}}{-q_{ii}}$

Eingebettete DTMC (in Übergangszeitpunkten)

$$P_{ii} = 0$$


$$P_{ij} = \frac{q_{ij}}{\sum_{j \neq i} q_{ij}} = \frac{q_{ij}}{-q_{ii}} \quad j \neq i$$

Zustands und Klasseigenschaften

$$y^{(n)} = x(a_n) \quad a > 0 \quad t = a_n$$

\uparrow DTMC \uparrow CTMC

Irreduzibilität: DTMC - CTMC mapping (mit Zustandsdiagramm darstellen)



Periode: alle Zustände sind aperiodisch ($p_{ij}(t) > 0 \forall t > 0$)
Für ein Zustandspaar i, j $\begin{cases} \text{entweder } p_{ij}(t) > 0 \forall t > 0 \\ \text{oder } p_{ij}(t) = 0 \forall t > 0 \end{cases}$

$$P(t) = e^{Qt} = \sum_{n=0}^{\infty} \frac{Q^n t^n}{n!} \quad q_{ij} > 0$$

Rekurrenz / Transienz mittels DTMC - CTMC, mapping - für alle $a > 0$ muss b gezeigt werden (mit Zustandsdiagramm darstellen)

Absorbierender Zustand mittels DTMC - CTMC, mapping - für alle $a > 0$ muss b gezeigt werden (mit Zustandsdiagramm darstellen)
 $q_{ii} = 0$ in Matrix hat man volle Nullzeile

Absorption:

gegeben: CTMC mit einer Klasse von rekurrenten Zuständen C und einer transienten Klasse T

AbsorptionsWSLK: $a_i = P(\text{Absorption in } C | x_0 = i)$

Berechnung: Wenn eine CTMC eine Klasse von rekurrenten Zuständen C und eine Transiente Klasse T hat, dann sind die Absorptionswerte Lösungen von dem folgenden LGS:

$$a_i = 1 \quad i \in C$$

$$0 = \sum_j q_{ij} a_j \quad i \in T$$

$$a_i = (1 + q_{ii} dt) a_i + \sum_{j \neq i} q_{ij} dt a_j \quad \text{hdt, } \lim_{dt \rightarrow 0}$$

$$0 = a_{ii} a_i + \sum_j a_{ij} a_j \Rightarrow 0 = \sum_j q_{ij} a_j$$

Alternative Form der Berechnung der AbsorptionsWSLK in Matrix-Vektor-Form

$$\underline{Q} = [q_{ij}] \quad i, j \in T$$

$$\underline{R} = [q_{ij}] \quad i \in T, j \in C$$

$$\underline{a} = [a_i] \quad i \in T$$

$$\underline{a} = -\underline{Q}^{-1} \underline{R} \underline{e}$$

mittlere Zeit bis zur Absorption \rightarrow

Alternative Matrix/Vektor Form

$$t_{ii} = 0 \quad i \in C$$

$$0 = 1 + \sum_j q_{ij} t_j$$

$$\underline{t} = -\underline{Q}^{-1} \underline{e}$$

Ergänzungen

- stationäre Verteilung $P \underline{Q} = \underline{0}$ und $P \underline{e} = 1$
- Eine irreduzible und positiv rekurrente CTMC hat immer eine Grenzverteilung (P^∞), welche genau gleich wie P ist.
- Eine irreduzible und endliche CTMC hat immer eine Grenzverteilung (P^∞), bei der $P^\infty = P$ gilt.

\leftrightarrow Bei der Prüfung ist es nicht nötig Beweise zu können

Informationstheorie



Wie kann man Information messen?

Nachricht: Kette von "Buchstaben" die zufällig erzeugt wird

Je kleiner die WSK, desto größer der Informationsgehalt.

Wahrscheinlichkeit p

Informationsgehalt $\log_2 \frac{1}{p}$

Napier (nepbits) $\ln \frac{1}{p}$

(Basiswechsel indem man \log_p \log mit Basis multipliziert)

BSP: "Draußen schneit es"

Nordpol \rightarrow wenig Information

Surinam \rightarrow viel Information

Informationsgehalt abh. von WSK

BSP Frage - Antwort "Bar-Kochlos" (Ich - Sek - ka - sek - was - da - nicht - stekt)

m Objekte in Menge M zusammenfassen $M = \{1, \dots, m\} / \{0, \dots, m-1\}$

darf ja/nein Fragen stellen, mit möglichst wenig Fragen ein Objekt identifizieren.

\Rightarrow Optimale Anzahl von Fragen: $\lceil \log_2 m \rceil$

L Fragen: $\begin{cases} \text{ja/da} & ja = 1 \\ \text{nein/was} & = 0 \end{cases}$

höchstens 2^L versch. Folgen von


Antworten. Eindeutigkeit $2^L \geq m$

BSP Element von M wird zufällig bestimmt.

$M = \{1, 2, 3, 4, 5\}$

Fragen sind Teilmengen von M

Fragebaum 1



Fragebaum 2



"je nachdem" ist nicht notwendig

2 in Fragestrategie verwenden

1: 111 4: 100
2: 110 5: 0
3: 101

Fragestrategie mit Bäumen identifizieren \rightarrow Code: für $\begin{cases} ja = 1 \\ nein = 0 \end{cases}$ Zahlen aneinanderhängen

Blattlänge: Anzahl der Fragen für ein Element = Codewortlänge

Mittlere Anzahl an Fragen: $\bar{L} = \sum p_i \cdot L_i$ (Für Element i gibt es L_i Fragen)


BSP $m=4$, $P = (0.1, 0.2, 0.3, 0.4)$

Element m wird zufällig gewählt mit Verteilung $P = (p_1, \dots, p_m)$
Optimaler Wert für \bar{L} ?



$$\bar{L} = 0.4 \cdot 1 + 0.3 \cdot 2 + 3(0.2 + 0.1) = 1.9$$

\Rightarrow nicht soooo toll



Wt Baum: gerichteter Graph ohne Zyklen

Def: jeder Knoten höchstens 2 Kinder

Wortel: keine zufällige Werte

Vollständig: aus jedem Knoten im Inneren 2 Kinder

Blatt: keine mehr Kinder

Blattlänge: $\sum L_i$



Das geht besser: Baum mit Blattlänge $L_1 \dots L_m \rightarrow$ WSK darauf aufteilen



alter Baum

$P_1 \dots P_m$

$L_1 \dots L_m$

neuer Baum:

$P_1^* \dots P_{m-1}^*$

$L_1^* \dots L_{m-1}^*$

$P_{m-1}^* = P_{m-1} + P_m$

$L_{m-1}^* = L_m$

$P_1^* = P_1 \dots P_{m-2}^* = P_{m-2}$

$L_{m-1}^* = L_{m-1} - 1 = L_m - 1$

mittlere Blattlänge $\bar{L} = P_1 L_1 + \dots + P_{m-1} L_{m-1} + P_m L_m = P_1 L_1^* + \dots + P_{m-2} L_{m-2}^* + P_{m-1} (L_{m-1}^* + 1) + P_m (L_{m-1}^* + 1) = L^* + P_m + P_{m-1}$

Huffman - Algorithmus: Optimaler Code/Fragestrategie für $(P = P_1 \dots P_m)$

(0) Wenn $m=1$: \square break

rekursiv: (1) ordne die Wahrscheinlichkeiten absteigend $p_1 \geq \dots \geq p_m$


(2) Fasse die beiden kleinsten WSK esm $P^* = (P_1^* \dots P_{m-1}^*) = (P_1 \dots P_{m-2}, P_{m-1} + P_m)$

(3) konstruiere den optimalen Baum (optimaler Fragestrategie für P^*)

(4) Ersetze in weiteren optimalen Baum aus 3 $m-1 \rightarrow$



BSP (0.1, 0.2, 0.3, 0.4)
1 2 3 4



$$H^*(P) = (0.1, 0.2, 0.3, 0.4) = 1.9$$

mittlere Unbestimmtheit: $H^*(P)$ Optimaler Wert für die mittlere Anzahl von Fragen

Ableitung: Minimierung von $\bar{L} = \sum_{i=1}^n p_i \cdot l_i$ unter der Nebenbedingung "∃ Baum mit Blattlängen $l_1 \dots l_n$ "

Umkehrung von Kraft:

∃ Binärbaum mit Blattlängen $l_1 \dots l_n$ genau dann, wenn $\sum_{i=1}^n 2^{-l_i} \leq 1$

Gleichheit gilt, wenn der Baum vollständig ist.

minimiere $\sum p_i \cdot l_i$ unter NB $\sum 2^{-l_i} = 1 \Rightarrow \sum p_i \cdot l_i - \lambda \sum 2^{-l_i}$

$$\frac{\partial}{\partial l_i} = 0 \Rightarrow p_i - \lambda \cdot 2^{-l_i} \cdot (\log 2) = 0$$

$$C = \frac{1}{(-\lambda \cdot \log 2)}$$

$$2^{-l_i} = C \cdot p_i$$

$$\sum 2^{-l_i} = C \sum p_i$$

$$p_i = 2^{-l_i} \quad l_i = \log_2\left(\frac{1}{p_i}\right)$$

Entropie in P^* : $H(p_1 \dots p_n) = \sum_{i=1}^n p_i \cdot \log_2\left(\frac{1}{p_i}\right) \leq H^*(p_1 \dots p_n)$

weilers: $H^*(p_1 \dots p_n) \leq H(p_1 \dots p_n) + 1$

weilers: $l_i = \log_2\left\lceil \frac{1}{p_i} \right\rceil \geq \log_2\left(\frac{1}{p_i}\right) \Rightarrow \sum 2^{-l_i} \leq \sum 2^{-\log_2\left(\frac{1}{p_i}\right)} = \sum p_i = 1$

↳ $H^*(p_1 \dots p_n) \leq \sum p_i \left\lceil \log_2\left(\frac{1}{p_i}\right) \right\rceil \leq \sum p_i \left(\log_2\left(\frac{1}{p_i}\right) + 1\right) = H(p_1 \dots p_n) + 1$

Beweis $n=1$



$l_1=0 \quad l_n=1 \quad l_2=2$

Höhe h des Baumes $\max\{l_i\}$

$$h+1 \leq \sum_{i=1}^n \frac{1}{2^i} \text{ max } n \quad \square$$

$l_1 \leq l_2 \leq \dots \leq l_n$

entweder ist $\sum 2^{-l_i} \leq \frac{1}{2}$ $l_i^* = l_i - 1 \Rightarrow \sum 2^{-l_i^*} \leq 1$

oder es gibt $k < m$ mit $l_i^* = l_i - 1$: $\sum_{i=1}^k 2^{-l_i} = \frac{1}{2}$
 $2^{-l_1} + \dots + 2^{-l_{k-1}} + 1$ mit weiteren l_i
 $2^{-l_1} + \dots + 2^{-l_{k-1}} + 1 \geq 2^{-l_k}$



$H(x_1 \dots x_n) = n \cdot H(x) \Leftrightarrow x_1 \dots x_n$ sind unabhängig

$$n \cdot H(x) \leq H^*(x_1 \dots x_n) \leq n H(x) + 1$$

pro Element: $H(x) \leq \frac{H^*(x)}{n} \leq H(x) + \frac{1}{n}$

Vorstellung (nicht ganz korrekt aber funktioniert) $H(P)$ ist die optimale Anzahl von Fragen die optimale Strategie hat $l_i = \log_2\left(\frac{1}{p_i}\right)$

"Dumme Geschichte"

$x \sim P$ in Wirklichkeit aber wir glauben $x \sim Q = (q_1 \dots q_n)$
↓
peinlicher Würfel
Fairer Würfel

optimal: $\sum p_i \log_2\left(\frac{1}{p_i}\right) \Rightarrow H(P)$

wirklich: $\sum p_i \log_2\left(\frac{1}{q_i}\right) \Rightarrow$ nicht optimal $> H(P)$

Strafe des Irrtums / Relative Entropie / Diskrepanz / Kullback-Leibler Distanz / I-Divergenz $D(P, Q) = \sum p_i \log_2\left(\frac{p_i}{q_i}\right)$

$D(P, Q) \geq 0$ mit Gleichheit für $P=Q$

Beweis \log konkav: $\log_2(\lambda x + (1-\lambda)y) \geq \lambda \log_2(x) + (1-\lambda) \log_2(y)$

$\log_2\left(\sum \lambda_i x_i\right) \geq \sum \lambda_i \log_2(x_i) \quad \sum \lambda_i = 1, \lambda_i \geq 0$

$-D(P, Q) = \sum p_i \log_2\left(\frac{q_i}{p_i}\right) \leq \log_2\left(\sum x_i \frac{q_i}{p_i}\right) = 0$

Eigenschaften von $H(p)$

$$\theta \leq H(p) \leq \log_2(m)$$

$p \cdot \log_2\left(\frac{1}{p}\right)$ für $p = \theta$ soll θ sein

$H(x) = 0$ wenn X deterministisch ist

$$H(p) \leq \log_2(m) \quad Q\left(\frac{1}{m}, \dots, \frac{1}{m}\right)$$

$$H(p) = \sum_{i=1}^m p_i \log_2\left(\frac{1}{p_i}\right) = \sum_{i=1}^m p_i \log_2(m)$$

BSP 2x Würfeln, X kleinere Augenzahl, Y größere Augenzahl

| $X \setminus Y$ | 1 | 2 | 3 | 4 | 5 | 6 |
|-----------------|----------------|----------------|----------------|----------------|----------------|----------------|
| 1 | $\frac{1}{36}$ | $\frac{1}{36}$ | $\frac{1}{36}$ | $\frac{1}{36}$ | $\frac{1}{36}$ | $\frac{1}{36}$ |
| 2 | 0 | $\frac{1}{36}$ | $\frac{1}{36}$ | $\frac{1}{36}$ | $\frac{1}{36}$ | $\frac{1}{36}$ |
| 3 | 0 | 0 | $\frac{1}{36}$ | $\frac{1}{36}$ | $\frac{1}{36}$ | $\frac{1}{36}$ |
| 4 | 0 | 0 | 0 | $\frac{1}{36}$ | $\frac{1}{36}$ | $\frac{1}{36}$ |
| 5 | 0 | 0 | 0 | 0 | $\frac{1}{36}$ | $\frac{1}{36}$ |
| 6 | 0 | 0 | 0 | 0 | 0 | $\frac{1}{36}$ |

Frage nach X ($H(x)$) und Y ($H(y)$) getrennt

insgesamt $H(x) + H(y)$

$$\frac{1}{36} \cdot \log_2(36) + \frac{3}{36} \cdot \log_2\left(\frac{36}{3}\right) + \dots = 2.31135$$

$$\text{Zusammen: } H(x, y) = \frac{5}{6} \log_2(18) + \frac{1}{6} \log_2(36) = 4.33659$$

Information zwischen X und Y : $I(x, y) = H(x) + H(y) = H(x, y)$

$$H(x, y) = - \sum_{i=1}^m \sum_{j=1}^m P(X=x_i, Y=y_j) \cdot \log(P(X=x_i, Y=y_j)) = - \sum_{i,j} P(X=x_i, Y=y_j) \log[P(X=x_i) P(Y=y_j | X=x_i)] =$$

$$= - \underbrace{\sum_i P(X=x_i) \log P(X=x_i)}_{H(x)} + \underbrace{\left(\sum_i P(X=x_i) \sum_j P(Y=y_j | X=x_i) \log P(Y=y_j | X=x_i) \right)}_{H(y | X=x_i) \text{ Entropie der bedingten}}$$

$$= H(x) + \sum P(X=x_i) H(y | X=x_i) = H(x) + H(y | x) = H(x) + H(x | y)$$

Prüfung: Entropien berechnen

sei $P(Y=f(x_i)) = 1 \Rightarrow$ mit WSK = 1 für $y=f(x)$

$I(x, y)$ im Beispiel $4.6 \dots - 4.3 \dots = 0.30331$

$$H(x | y) = H(x, y) - H(y) = 2.01664$$

$$\theta \leq I(x, y) \leq \min H(x, y)$$

$\theta = I(x, y)$ wenn x, y unabhängig sind

$I(x, y) = \min H(x, y)$ wenn $I(x, y) = H(x) \iff H(y | x) = 0 \iff H(y | x = x_i) = 0 \quad \forall i$

Vert. von Y unter $X = x_i$ ist deterministisch

Codes

Begriffe:

Quellalphabet $M = \{1 \dots m\}$ oder $\{0 \dots m-1\}$ oder $\{x_1 \dots x_m\}$

Codealphabet $C = \{0 \dots r-1\}$

Binärcode: $r=2$

Alphabet A

Nachrichten der Länge n : $A^n = \{a_1 \dots a_n, a_i \in A, i=1 \dots n\}$

$$A^* = \bigcup_{n \geq 0} A^n \quad A^0 = \{\epsilon\}$$

$$A^{**} = A^* \cup A^N$$

(a_1, a_2, \dots, a_n) wird zu $a_1 a_2 \dots a_n$

Code: Abbildung $c: M^{**} \rightarrow C^{**}$ Einschränkung: für jeden Quellbuchstaben gibt es ein Codewort

Nachricht wird durch aneinanderhängen codiert

$$c(x_1 x_2 \dots) = c(x_1) c(x_2) \dots$$

bsp $m=3$
 $r=2$

$$M = \{1, 2, 3\}$$

$$3121 \mapsto 110100 \xrightarrow{-1} 3121$$

$$c: \begin{aligned} c(1) &= 0 \\ c(2) &= 10 \\ c(3) &= 11 \end{aligned}$$

Präfixfreier Code $\Leftrightarrow c$ ist fortlaufend entzifferbar

(beim sequenziellen Lesen ist klar, wo ein Code endet)

(kein Codewort darf Anfang eines anderen Codeworts sein)

c ... eindeutig entzifferbar

c ... endlich eindeutig entzifferbar

o) $m=r=2$ $c(1)=0, c(2)=01$

kann eindeutig entziffert werden, wenn man den nächsten Buchstaben auch kennt.

(gilt mit entzifferten und unentzifferten Angaben)

o) $m=3, r=2$

$$\begin{aligned} 1 &\rightarrow 0 \\ 2 &\rightarrow 01 \\ 3 &\rightarrow 11 \end{aligned}$$

110010 rückwärts lesen
3121

a) 1333 \rightarrow 01111
b) 2333 \rightarrow 01111

Oh shit, same!

Optimaler Code \rightarrow Huffman Code aus Huffman Baum erzeugen

Kanonischer Huffman Code

1) bestimme Codewortlängen aus Huffman Baum: $l_1 \dots l_n$ mit $l_1 \leq \dots \leq l_n$

2) erstes Codewort: nur über Binärzahl mit l_i stellen $C_{i+1} = (C_i + 1) 2^{e_{i+m} - e_i} = (C_i + 1) \leftarrow^{shiften} (l_{i+1} - l_i)$

Aus Beweis der Entropie geht Ungleichung $l_i = \lceil \log_2 \frac{1}{p_i} \rceil$ hervor

Shannon Code

$P = (0.1, 0.2, 0.3, 0.4)$ ordne WSUK absteigend

| x_i | A_i | $f_{i-1} = p_1 + \dots + p_{i-1}$ | $l_i = \lceil \log_2 \frac{1}{p_i} \rceil$ | $C_i = f_{i-1}$ |
|-------|-------|-----------------------------------|--|-----------------|
| 4 | 0.4 | 0 | 2 | 00 |
| 3 | 0.3 | 0.4 | 2 | 01 |
| 2 | 0.2 | 0.7 | 3 | 101 |
| 1 | 0.1 | 0.9 | 4 | 1110 |

$\hookrightarrow (0.1110 \dots)_2$

Fano Code mit $l_i = \lceil \log_2 \frac{1}{p_i} \rceil + 1$

| f_i | $\frac{f_i + f_{i-1}}{2}$ | C_i |
|-------|---------------------------|-------|
| 0.1 | 0.1 | 00001 |
| 0.2 | 0.3 | 0011 |
| 0.3 | 0.6 | 011 |
| 0.4 | 1.0 | 110 |