

# Elementare Wahrscheinlichkeitstheorie und Statistik A

Dozent: Prof. Dr. R. Grübel

unkorrigierte Vorlesungsmitschrift  
aus dem WS 2004 / 05  
angefertigt von Florian Garbs

Bei etwaigen Fehlern, würde ich mich über eine Benachrichtigung per  
E-mail ([sos\\_1981@yahoo.de](mailto:sos_1981@yahoo.de)) freuen.

## 1. Vorlesung (14.10.2004)

### §1 Ein mathematisches Modell für Zufallsexperimente

Stochastik: Wahrscheinlichkeitstheorie und Statistik.

Gegenstand: Zufallsexperimente (d.h. Ergebnis nicht durch Randbedingungen festgelegt).

#### Stichproben oder

Ergebnisraum: Eine Menge, die die möglichen Versuchsergebnisse enthält,  $\Omega$ .

Ereignisse: werden durch Teilmengen von  $\Omega$  beschrieben.

#### Beispiel 1.1

a) Würfelwurf  $\Omega = \{1, \dots, 6\}$ .

Ereignis „gerade Zahl erscheint“ wird beschrieben durch  $A = \{2, 4, 6\}$ .

b) Eine Probe radioaktives Material emittiert in einem bestimmten Zeitraum eine zufällige Anzahl von Partikeln.  $\Omega = \mathbb{N}_0 = \{0, 1, 2, \dots\}$ ,  $A = \{n \in \mathbb{N}_0 : n \geq 10\}$  steht für „mindestens 10 Zerfälle“.

c) Eine Faser der Länge 1 reißt unter Zug an einer zufälligen Stelle. Ergebnisraum für die Position des Bruchpunktes  $\Omega = [0, 1]$ . Das Ereignis, dass die Bruchstelle näher am Mittelpunkt der Faser, als am Endpunkt liegt entspricht der Teilmenge  $\left(\frac{1}{4}, \frac{3}{4}\right)$ .

Ereignisse mit nur einem Element, also von der Form  $A = \{\omega\}$  mit einem  $\omega \in \Omega$ , nennt man Elementarereignisse.

Ereignisse lassen sich zu neuen Ereignissen kombinieren („Ereignisalgebra“). Auf der „Mengenseite“ entspricht dies Mengenoperationen.

Das Ereignis „das durch A repräsentierte Ereignis tritt nicht ein“ wird repräsentiert durch  $A^c (= \{\omega \in \Omega : \omega \notin A\})$ .

„es kommt keine gerade Zahl“:  $\{2, 4, 6\}^c = \{1, 3, 5\}$ .

$A \cap B$ : A und B treten beide ein

$A \cup B$ : A oder B (oder Beide) treten ein

#### Beispiel 1.2

In Bsp 1.1 a) ist  $A = \{2, 4, 6\}$  das Ereignis „eine gerade Zahl kommt“ und  $B = \{1, 2, 3\}$  das Ereignis „eine Zahl  $\leq 3$  kommt“.

$A \cap B = \{2\}$  (ein Elementarereignis) steht für „eine gerade Zahl  $\leq 3$  kommt“.

Wie wird das Ereignis „A, B und C treten ein“ dargestellt?  $A \cap B \cap C$ .

„genau eines“:  $A \cap B^c \cap C^c \cup A^c \cap B \cap C^c \cup A^c \cap B^c \cap C$  beachte: wir haben eine „disjunkte Vereinigung“. Hierfür schreiben wir gelegentlich „+“ statt „ $\cup$ “.

Was ist nun „Wahrscheinlichkeit“?

Eigentlich außermathematische Frage, wie z.B. „was ist Raum?“ .

Zwei nicht-identische, aber auch nicht-disjunkte Interpretationen:

- relative Häufigkeit, „frequentistisch“
- Grad der Gemischtheit, „subjektivistisch“ (insbesondere bei nicht wiederholbaren Experimenten sinnvoll)

Sei  $N_n(A)$  die Anzahl der Experimente bei n-maliger Wiederholung, die denen A eingetreten ist. Würfelwurf, A gerade Zahl:

3 3 2 1 2 4 6 6 3 1

$n=10$ ,  $N_n(A) = 5$  absolute Häufigkeit

relative Häufigkeit  $\frac{1}{n}N_n(A)$  (hier 0,5).

Rechenregeln für die relative Häufigkeit:

$$(1) 0 \leq \frac{1}{n}N_n(A) \leq 1, \quad \frac{1}{n}N_n(\Omega) = 1$$

$$(2) \frac{1}{n}N_n(A_1 + \dots + A_k) = \frac{1}{n}N_n(A_1) + \dots + \frac{1}{n}N_n(A_k)$$

für paarweise disjunkte Ereignisse  $A_1, \dots, A_k$

Jargon: „ $A \rightarrow \frac{1}{n}N_n(A)$  ist Additiv“. ( $n = \text{fest}$ )

### Definition 1.3 ( die Kolmogorov-Axiome)

Gegeben: Ergebnisraum  $\Omega$ , System  $\mathcal{A}$  von Ereignissen (für uns normalerweise die Menge aller Teilmengen von  $\Omega$ , die Potenzmenge  $\mathfrak{P}(\Omega)$ ).

Eine Wahrscheinlichkeit (oder besser ein Wahrscheinlichkeitsmaß) ist eine Abbildung  $P: \mathcal{A} \rightarrow [0,1]$  (dem Ereignis A wird die Wahrscheinlichkeit  $P(A)$  zugeordnet) mit der Eigenschaft

$$(A1) P(A) \geq 0, \quad P(\Omega) = 1$$

(A2) Für alle  $A_1, A_2, \dots \in \mathcal{A}$  mit  $A_i \cap A_j = \emptyset$  für  $i \neq j$  (eine Folge von paarweise disjunkten Ereignissen) gilt:

$$\boxed{P\left(\bigcup_{i=1}^{\infty} A_i\right) = \sum_{i=1}^{\infty} P(A_i)} \quad (\sigma\text{-Additivität})$$

Das Tripel  $(\Omega, \mathfrak{A}, P)$  nennt man Wahrscheinlichkeitsraum.

Erste Folgerung:

Satz 1.4

- (I)  $P(\emptyset) = 0$
- (II)  $P(A) \leq 1$
- (III)  $P(A^c) = 1 - P(A)$
- (IV)  $A \subset B \Rightarrow P(A) \leq P(B)$
- (V)  $P(A_1 + \dots + A_k) = P(A_1) + \dots + P(A_k)$  (endliche Additivität)

Beweis:

(I) Verwendet man die  $\sigma$ -Additivität (A'') mit  $A_j = \emptyset$  für alle  $j \in \mathbb{N}$ , so erhält man

$$P(\emptyset) = \sum_{j=1}^{\infty} P(\emptyset),$$

woraus wegen  $P(\emptyset) \in \mathbb{R}$  die gewünschte Aussage  $P(\emptyset) = 0$  folgt.

(V) Verwendet man (A'') mit  $A_j = \emptyset$  für  $j > k$ , so folgt wegen (I) die Behauptung.

(III) Wir benutzen die erste Hälfte von (A1) sowie die endliche Additivität (V) mit  $A_1 = A$ ,  $A_2 = A^c$  und erhalten

$$1 = P(\Omega) = P(A + A^c) = P(A) + P(A^c),$$

also (III).

(IV) Mit dem zweiten Teil von (A1) und der endlichen Additivität folgt

$$P(B) = P(A + B \cap A^c) = P(A) + P(B \cap A^c) \geq P(A)$$

also die gewünschte Monotonieeigenschaft.

(II) Die folgt aus der Monotonieeigenschaft (IV) und der ersten Hälfte von (A1).

q.e.d.

Satz 1.5

(I) (Boolesche Ungleichung):

$P(A_1 \cup \dots \cup A_k) \leq P(A_1) + \dots + P(A_k)$  (Wichtig hierbei: es wird vorausgesetzt, dass  $A_1, \dots, A_k$  paarweise disjunkt sind)

(II) (Formel von Sylvester-Poincaré, Siebformel)

$$P\left(\bigcup_{i=1}^n A_i\right) = \sum_{k=1}^n (-1)^{k+1} \sum_{\substack{H \subset \{1, \dots, n\} \\ \#H=k}} P\left(\bigcap_{i \in H} A_i\right)$$

$$P(A_1 \cup A_2) = P(A_1) + P(A_2) - P(A_1 \cap A_2)$$

$$P(A_1 \cup A_2 \cup A_3) = P(A_1) + P(A_2) + P(A_3) - P(A_1 \cap A_2) - P(A_1 \cap A_3) - P(A_2 \cap A_3) + P(A_1 \cap A_2 \cap A_3)$$

## 2. Vorlesung (21.10.2004)

$\Omega$ : Ergebnisraum, enthält die möglichen Ergebnisse der Zufallsexperimente

$\mathfrak{A}$ : System der Ereignisse  $A \subset \Omega$

$P: \mathfrak{A} \rightarrow [0,1]$ : Abbildung, die jedem Ereignis  $A$  seine Wahrscheinlichkeit  $P(A)$  zuordnet

### §2 Laplace-Experiment, elementare Kombinatorik

Laplace-Experiment heißt:  $\#\Omega < \infty$  (endlicher Ergebnisraum),  $\mathfrak{A} = \mathfrak{P}(\Omega)$  (alle Teilmengen von  $\Omega$  kommen als Ergebnis in Frage),

$$P(A) = \frac{\#A}{\#\Omega} \quad (= \text{Anzahl der günstigen} / \text{Anzahl der Möglichkeiten insgesamt}).$$

#### Beispiel 2.1

Ein Würfel wird 2-mal geworfen. Mit welcher Wahrscheinlichkeit erhält man die Augensumme 7 (bzw. 6)?

Wir nehmen an, das ein Laplace-Experiment über

$$\begin{aligned}\Omega &= \{1, 2, 3, 4, 5, 6\} \times \{1, 2, 3, 4, 5, 6\} \\ &= \{(i, j) : i, j \in \{1, \dots, 6\}\} \\ &= \{(1,1), \dots, (6,6)\} \text{ vorliegt.}\end{aligned}$$

$$A_7 = \{(6,1), (5,2), (4,3), (3,4), (2,5), (1,6)\}$$

$$A_6 = \{(5,1), (4,2), (3,3), (2,4), (1,5)\}$$

$$P(A_7) = \frac{\#A_7}{\#\Omega} = \frac{6}{36}, \quad P(A_6) = \frac{5}{36}$$

Berechnung von Wahrscheinlichkeiten läuft bei Laplace-Experimenten auf die Kunst des Zählens (Kombinatorik) hinaus.

#### Regel 1:

Lässt sich  $A$  auf  $B$  bijektiv abbilden, so gilt  $\#A = \#B$ .

#### Regel 2:

$\#(A \cup B) = \#A + \#B$ , wenn  $A$  und  $B$  disjunkt sind.

Verallgemeinerung auf mehr als zwei:  $\#(A_1 + \dots + A_k) = \#A_1 + \dots + \#A_k$

Nützlicher Spezialfall: Hat  $C \subset A \times B$  die Eigenschaft  $\#\{y \in B : (x, y) \in C\} = n$  für alle  $x \in A$ , so gilt  $\#C = n \#A$ .

Spezialfall vom Spezialfall:  $\#(A \times B) = (\#A)(\#B)$

Wir schreiben abkürzend:  $A^k = A \times A \times \dots \times A$

$$= \{(x_1, \dots, x_k) : x_i \in A\} \text{ für alle } i = 1 - k$$

Klar:  $\#(A^k) = (\#A)^k$ .

Sei jetzt  $M_n = \{1, \dots, n\}$ . Dann nennen wir die Elemente von  $M_n^k$ , also die  $L$ -Tupel  $(i_1, \dots, i_k)$  mit  $i, j \in \{1, \dots, n\}$  für  $j = 1, \dots, k$   $\boxed{\#M_n^k = n^k}$ , K-Permutationen von  $M_n$  mit Wiederholung.

Interpretation:

- (I) Einer Menge von  $n$  Elementen kann man  $n^k$  verschiedene Stichproben vom Umfang  $k$  entnehmen, wenn man zurücklegt und die Reihenfolge beachtet wird.
- (II) Es gibt  $n^k$ -Möglichkeiten,  $k$  verschiedene Objekte auf  $n$  Plätze zu verteilen, wieder bei Berücksichtigung der Reihenfolge und möglicher Mehrfachbesetzung.

Zur Erinnerung:  $n! = n \cdot (n-1) \cdot \dots \cdot 3 \cdot 2 \cdot 1$  ( $n$ -Fakultät)

$$\binom{n}{m} = \frac{n!}{(n-m)! \cdot m!} \quad (n \text{ über } k, \text{ Binominalkoeffizienten})$$

Satz 2.2

Für  $1 \leq k \leq n$  gilt  $\#\left\{(i_1, \dots, i_k) \in M_n^k : \begin{matrix} i, j \neq i_l \\ j \neq L \end{matrix}\right\} = \frac{n!}{(n-k)!}$

Verwende Regel 2:

Es gibt  $n$  Möglichkeiten für  $i_1$ , bei gegebenem  $i_1$  gibt es  $n-1$  Möglichkeiten für  $i_2$ , bei gegebenen  $i_1$  und  $i_2$  gibt es  $n-2$  Möglichkeiten für  $i_3$ , ..., bei gegebenen  $i_1, \dots, i_{k-1}$  gibt es  $n-k+1$  Möglichkeiten für  $i_k$ .

$$\text{Also } \# \dots = n(n-k+1) = \frac{n!}{(n-k)!}.$$

Interpretation:

- (I) Einer Menge von  $n$  Elementen kann man  $\frac{n!}{(n-k)!}$  verschiedene Stichproben entnehmen, wenn die Reihenfolge beachtet wird, und nicht zurückgelegt wird.
- (II) Es gibt  $\frac{n!}{(n-k)!}$  Möglichkeiten,  $k$  Objekte unter Berücksichtigung der Reihenfolge auf  $n$  Plätze ohne Mehrfachbelegung zu verteilen.

Wichtiger Spezialfall: Es gibt  $n!$  Permutationen einer Menge von  $n$  Elementen (mit  $k = n$ ).

Satz 2.3

Für  $1 \leq k \leq n$  gilt:

$$\#\{(i_1, \dots, i_k) \in M_n^k : i_1 < i_2 < \dots < i_k\} = \binom{n}{k}$$

### Zum Beweis:

Jedem Element dieser Menge lassen sich  $k!$  Elemente der Menge aus dem letzten Satz zuordnen (alle die, die man durch eine der  $k!$  möglichen Permutationen erhält).

Also (unbekannte Anzahl):  $k! = \frac{n!}{(n-k)!}$ .

Die Elemente dieser Menge werden K-Kombinationen von  $M_n$  ohne Wiederholung genannt.

Wichtige Anwendung: Eine Menge mit  $n$  Elementen hat  $\binom{n}{k}$  Teilmengen mit  $k$  Elementen.

### Interpretation:

- (I) Es gibt  $\binom{n}{k}$  Möglichkeiten, aus  $n$  Objekten  $k$  herauszugreifen (Stichprobe ohne zurücklegen und ohne Berücksichtigung der Reihenfolge).
- (II) Es gibt  $\binom{n}{k}$  Möglichkeiten,  $k$  Objekte ohne Mehrfachbesetzung auf  $n$  Plätze zu verteilen, wenn die Verteilungsreihenfolge nicht berücksichtigt wird.

Typische Anwendung: „6 aus 49“,  $\binom{49}{6}$  Möglichkeiten.

### Beispiel 2.4

Eine (faire) Münze wird 10-mal geworfen. Mit welcher Wahrscheinlichkeit erscheint genau 7-mal Kopf? Wir gehen aus von einem Laplace-Experiment über  $\Omega = \{0,1\}^{10}$ , wobei 0 für Zahl und 1 für Kopf steht.

Beispielsweise bedeutet  $\omega = (0,0,0,1,1,0,1,1,1,0)$ , dass 3-mal Zahl, dann 2-mal Kopf usw. erscheint.

#A = Anzahl der Teilmenge vom Umfang 7 einer Menge von 10 Elementen.  
(betrachte die Wurfmenge, bei denen eine 1 erscheint)

$$P(A) = \frac{\#A}{\#\Omega} = \frac{\binom{10}{7}}{2^{10}} = \frac{120}{1024} = \frac{15}{128}.$$

### Satz 2.5

$$\#\{(i_1, \dots, i_k) \in M_n^k : i_1 < i_2 < \dots < i_k\} = \binom{n+k-1}{k}$$

Zum Beweis betrachten wir die folgende Abbildung  $M_n^k$  in  $M_{n+k-1}^k$ :

$$(i_1, \dots, i_k) \rightarrow (i_1, i_2 + 1, i_3 + 2, \dots, i_k + k - 1).$$

Dies liefert eine bijektive Abbildung zwischen

$$\{(i_1, \dots, i_k) \in M_n^k : i_1 \leq i_2 \leq \dots \leq i_k\} \quad \text{und} \\ \{(i_1, \dots, i_k) \in M_{n+k-1}^k : i_1 < i_2 < \dots < i_k\}$$

Nach Satz 2.4 hat die letztgenannte Menge  $\binom{n+k-1}{k}$  Elemente.

Die Elemente der Menge aus Satz 2.5 werden K-Kombinationen von  $M_n$  mit Wiederholung genannt.

Interpretation:

- (I) Einer Menge von  $n$  Elementen kann man  $\binom{n+k-1}{k}$  verschiedene Stichproben vom Umfang  $k$  entnehmen, wenn zurückgelegt wird und die Reihenfolge nicht beachtet wird.
- (II) Es gibt  $\binom{n+k-1}{k}$  Möglichkeiten  $k$  Objekte auf  $n$  Plätze zu verteilen, bei möglicher Mehrfachbesetzung, wenn die Verteilungsreihenfolge nicht berücksichtigt wird.

	mit Wiederholung	ohne Wiederholung
Permutation (Reihenfolge zählt)	$n^k$	$\frac{n!}{(n-k)!}$
Kombinationen (Reihenfolge egal)	$\binom{n+k-1}{k}$	$\binom{n}{k}$



### 3. Vorlesung (28.10.2004)

#### Drei klassische Beispiele für Laplace-Experimente

##### Beispiel 2.6 (Das Geburtstagsproblem)

In einem Raum befinden sich  $n$  Personen. Wie groß ist die Wahrscheinlichkeit, dass mindestens 2 Personen am gleichen Tag Geburtstag haben? ( $n \leq 365$ )

Vereinfachende Annahmen:

- 29. Februar streichen
- keine Zwillinge, etc.
- keine saisonalen Schwankungen

Dann ist ein Laplace-Experiment über  $\Omega := \{(i_1, \dots, i_n) : 1 \leq i_j \leq 365, j = (1, \dots, n)\}$  gerechtfertigt.  $i_j = k$  bedeutet hier, dass Person  $j$  am  $k$ -ten Tag des Jahres Geburtstag hat.

$$A = \{(i_1, \dots, i_n) \in \Omega : \exists l \neq j \text{ mit } i_l = i_j\}$$

$$P(A) = \frac{\#A}{\#\Omega} \quad \#\Omega = 365^n \quad \#A = ?$$

Trick:

Betrachte  $A^c = \{(i_1, \dots, i_n) \in \Omega : i_j \neq i_l \text{ für } j \neq l\}$

$$\begin{aligned} \#A^c &= 365 * 364 * \dots * (365 - n + 1) \quad (\text{beachte } (n \leq 365)) \\ &= \frac{365!}{(365 - n)!} \end{aligned}$$

$$\begin{aligned} P(A) &= 1 - P(A^c) = 1 - \frac{365!}{(365 - n)! * 365!} \\ &= 1 - \frac{365}{365} * \frac{364}{365} * \frac{363}{365} * \dots * \frac{(365 - n + 1)}{365} \end{aligned}$$



Offensichtlich monoton in  $n$

Bemerkenswert: Ab  $n = 23$  ist  $P(A) > 0,5$ . Bei  $n = 50$ :  $P(A) \approx 0,97$ .

### Beispiel 2.7 Der zerstreute Postbote

Ein Postbote verteilt  $n$  Briefe „zufällig“ auf  $n$  Briefkästen (einen pro Kasten).

Zu jeder der  $n$  Adressen gehört genau ein Brief. Wie viele Personen erhalten den für sie bestimmten Brief?

Wir nummerieren die Briefe und Briefkästen von 1 bis  $n$ , und zwar so, dass Brief  $i$  in Kasten  $i$  gehört.

Die möglichen Austeilungen entsprechen den Permutationen von  $\{1, \dots, n\}$ . Wir nehmen also

ein Laplace-Experiment über  $\Omega = \{(\omega_1, \dots, \omega_n) : \omega_i \in \{1, \dots, n\}, \omega_i \neq \omega_j \text{ für } i \neq j\}$  an.

A: # ist Null, d.h. **kein** Adressat erhält seinen Brief

$$A = \{(\omega_1, \dots, \omega_n) \in \Omega : \omega_i \neq i \text{ für } i = 1, \dots, n\}$$

Wieder:  $P(A) = \frac{\#A}{\#\Omega}$        $\#\Omega = n!$        $\#A = ?$

$$\begin{aligned} A^c &= \{(\omega_1, \dots, \omega_n) \in \Omega : \omega_i = i \text{ für ein } i \in \{1, \dots, n\}\} \\ &= \bigcup_{i=1}^n A_i \text{ mit } A_i = \{\omega \in \Omega : \omega_i = i\} \end{aligned}$$

### Siebformel

$$P\left(\bigcup_{i=1}^n A_i\right) = \sum_{k=1}^n (-1)^{k-1} \sum_{\substack{H \subset \{1, \dots, n\} \\ \#H=k}} P\left(\bigcap_{i \in H} A_i\right)$$

$$(P(A_1 \cup A_2) = P(A_1) + P(A_2) - P(A_1 \cap A_2))$$

$$\omega \in \bigcap_{i \in H} A_i \Leftrightarrow \omega_i = i \text{ für alle } i \in H.$$

Damit ist  $\#\bigcap_{i \in H} A_i = (n - \#H)!$

k-Positionen liegen fest
-----------------------------

Damit ist:

$$\begin{aligned} P(A) &= 1 - \frac{1}{n!} \sum_{k=1}^n (-1)^{k-1} \binom{n}{k} (n-k)! \\ &= 1 + \sum_{k=1}^n (-1)^k \frac{1}{k!} \\ &= \sum_{k=0}^n \frac{(-1)^k}{k!} \xrightarrow{n \rightarrow \infty} \frac{1}{e} \approx 0,3679... \end{aligned}$$

### Beispiel 2.8 (Skat)

Typisch: Mit welcher Wahrscheinlichkeit liegen zwei Buben im Skat?

Laplace-Experiment.

$$\Omega = \{(\omega_1, \dots, \omega_{32}) : \omega_i \in \{1, \dots, 32\}, \text{ paarweise verschieden}\} \quad (\text{also } \#\Omega = 32!)$$


Interpretation: Wir nummerieren die Karten mit den Zahlen 1 bis 32.

1 bis 4 seien die Buben. Die Austeilreihenfolge sei beispielsweise so, dass die 10. und die 11. Karte in den Skat kommen.

Ist A das Ereignis, dass zwei Buben im Skat landen,

$$\text{so führt dies auf } A = \{\omega \in \Omega : \omega_{10} \in \{1, 2, 3, 4\}, \omega_{11} \in \{1, 2, 3, 4\}\}.$$

$$\#A = 4 \quad * \quad 3 \quad * \quad 30 * 29 * 28 * \dots * 3 * 2 * 1$$



$$P(A) = \frac{\#A}{\#\Omega} = \frac{4 * 3 * 30!}{32!} = \frac{4 * 3}{32 * 31} = \frac{3}{248} \approx 0,012$$

In etwa einem Prozent der Spiele sind zwei Buben im Skat.

Es ist intuitiv klar, dass dieses Ergebnis von der Austeilreihenfolge unabhängig ist.

Fasst man alle  $\omega$ 's zusammen, die zu derselben Kartenverteilung führen, so erhält man als Ergebnisraum:

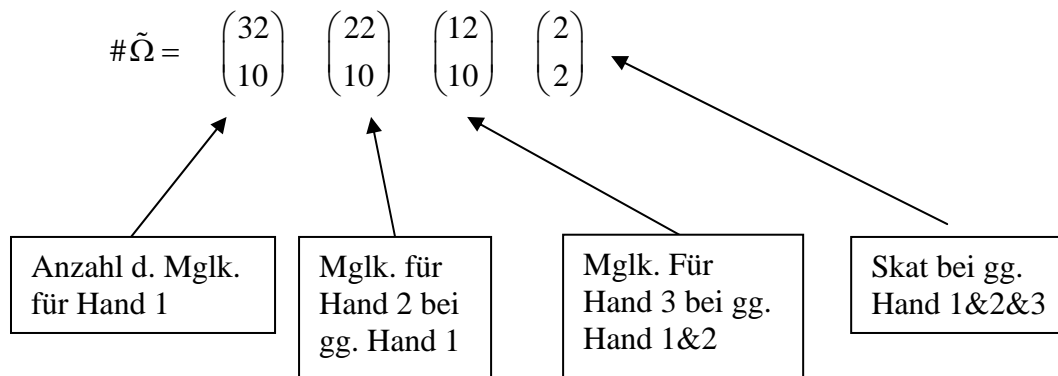
$$\tilde{\Omega} = \left\{ \begin{array}{l} H_1, H_2, H_3, S = \{1, \dots, 32\} \\ (H_1, H_2, H_3, S) : \#H_1 = \#H_2 = \#H_3 = 10, \#S = 2 \\ H_1, H_2, H_3, S \text{ paarweise disjunkt} \end{array} \right\}$$

$\omega = (H_1, H_2, H_3, S)$  wird wie folgt interpretiert:

Spieler  $i$  erhält die Karten mit Nummern aus  $H_i$ ,  $i = 1, 2, 3$ ;  $S = \text{Skat}$ .

Wie sieht das Ereignis A (2 Buben im Skat) in diesem mathematischen Modell (also als Teilmenge von  $\tilde{\Omega}$ ) aus?

$$A = \{(H_1, H_2, H_3, S) \in \tilde{\Omega} : S = \{1, 2, 3, 4\}\}$$



$$\#A = \begin{pmatrix} 4 \\ 2 \end{pmatrix} \begin{pmatrix} 30 \\ 10 \end{pmatrix} \begin{pmatrix} 20 \\ 10 \end{pmatrix} \begin{pmatrix} 10 \\ 10 \end{pmatrix}$$

$$P(A) = \frac{4! \cdot 30! \cdot 20! \cdot 10! \cdot 22! \cdot 10! \cdot 12! \cdot 10! \cdot 2!}{2! \cdot 2! \cdot 10! \cdot 20! \cdot 10! \cdot 10! \cdot 32! \cdot 22! \cdot 12!} = \frac{4! \cdot 30!}{2! \cdot 32!} = \frac{4 \cdot 3}{32 \cdot 31}$$

(passt zum anderen Ergebnis)

## Achtung!

Woher wissen wir eigentlich, dass ein Laplace-Experiment über  $\tilde{\Omega}$  vorliegt?

Dies geht nur, wenn beim Übergang von  $\Omega$  zu  $\tilde{\Omega}$  jeweils gleichviele  $\omega$ 's zu einem  $\tilde{\omega}$  zusammengefasst werden. (Dies ist hier der Fall:  $10! \cdot 10! \cdot 10! \cdot 2!$   $\omega$ 's werden zu einem  $\tilde{\omega}$  zusammengefasst.)

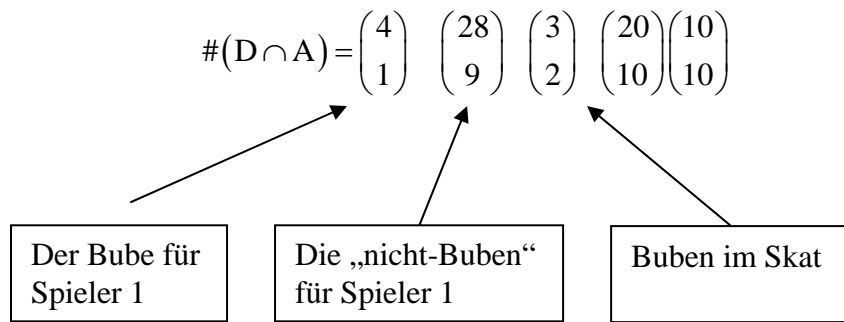
Weiteres Beispiel (zeigt, dass man mit etwas Übung recht schnell mit  $\tilde{\Omega}$  arbeiten kann):

D sei das Ereignis, dass Spieler 1 genau einen Buben erhält.

$$\#D = \begin{pmatrix} 4 \\ 1 \end{pmatrix} \begin{pmatrix} 28 \\ 9 \end{pmatrix} \begin{pmatrix} 22 \\ 10 \end{pmatrix} \begin{pmatrix} 12 \\ 10 \end{pmatrix} \begin{pmatrix} 2 \\ 2 \end{pmatrix}$$

$$\text{Damit ist } P(D) = \dots = \frac{4 \cdot 10 \cdot 22 \cdot 21 \cdot 20}{32 \cdot 31 \cdot 30 \cdot 29} = \frac{385}{899} \approx 0,4283$$

$P(D \cap A) = ?$  Spieler 1 erhält einen Buben und zwei liegen im Skat.



$$P(D \cap A) = \frac{\#(D \cap A)}{\#\tilde{\Omega}} \dots = \frac{5}{899} = 0,0056$$

#### 4. Vorlesung (04.11.2004)

#### §3 Bedingte Wahrscheinlichkeit und Unabhängigkeit

Es seien A und B Ereignisse in einem Zufallsexperiment. Welche Wahrscheinlichkeit hat B, wenn bekannt ist, dass A eintritt?

Bei n Wiederholungen tritt A  $N_n(A)$ -mal ein (absolute Häufigkeit). Unter dieser tritt auch B  $N_n(A \cap B)$ -mal ein. Damit ergibt sich als relative Häufigkeit des Eintretens von B,

unter denen die A liefern 
$$\frac{N_n(A \cap B)}{N_n(A)} = \frac{\frac{1}{n} N_n(A \cap B)}{\frac{1}{n} N_n(A)} .$$

Der Zusammenhang relative Häufigkeit – Wahrscheinlichkeit motiviert nun:

#### Definition 3.1

Es sei A ein Ereignis mit  $P(A) > 0$ . Die bedingte Wahrscheinlichkeit von B unter A wird

definiert durch 
$$P(B|A) := \frac{P(A \cap B)}{P(A)} .$$

#### Beispiel 3.2

In der im Beispiel 2.8 betrachteten Situation (Skat) sei A das Ereignis, dass sich 2 Buben im Skat befinden, D das Ereignis, dass Spieler 1 genau einen Buben erhält.

$$P(A|D) = \frac{P(A \cap D)}{P(D)} = \frac{5/899}{385/899} = \frac{5}{385} \approx 0,013$$

Dies ist etwas größer, als  $P(A) (= 3/248 \approx 0,012)$ .

#### Satz 3.3

##### (I) (Multiplikationsregeln)

Sind  $A_1, \dots, A_n$  Ereignisse mit  $P(A_1, \dots, A_n) > 0$ , so gilt:

$$P(A_1 \cap \dots \cap A_n) = P(A_1) * P(A_2 | A_1) * P(A_3 | A_1 \cap A_2) * \dots * P(A_n | A_1 \cap \dots \cap A_{n-1})$$

##### (II) (Gesetz von der totalen Wahrscheinlichkeit)

Ist  $A_1, \dots, A_n$  eine Ereignispartition von  $\Omega$ , d.h.

$A_1 \cup \dots \cup A_n = \Omega$ ,  $A_i \cap A_j = \emptyset$  für  $i \neq j$ , so gilt für alle Ereignisse B

$$P(B) = \sum_{i=1}^n P(B | A_i) P(A_i) .$$
 (Hierbei ist  $P(A_i) = 0$  zugelassen, der Summand wird dann als 0 interpretiert)

##### (III) (Formel von Bayes)

Es seien  $A_1, \dots, A_n$  und B wie in (II) und  $P(B) > 0$ . Dann gilt:

$$P(A_i | B) = \frac{P(A_i) P(B | A_i)}{\sum_{k=1}^n P(A_k) P(B | A_k)} .$$


Beweis:

(I) Die rechte Seite wird zu

$$P(A_1) * \frac{P(A_2 \cap A_1)}{P(A_1)} * \frac{P(A_3 \cap A_1 \cap A_2)}{P(A_1 \cap A_2)} * \dots * \frac{P(A_n \cap A_1 \cap \dots \cap A_{n-1})}{P(A_1 \cap \dots \cap A_{n-1})}$$
$$= P(A_1 \cap A_2 \cap \dots \cap A_n)$$

(II)

$$P(B) = P(B \cap \Omega)$$
$$= P(B \cap (A_1 \cup \dots \cup A_n)) = P(B \cap A_1 \cup \dots \cup B \cap A_n)$$



$$= P(B \cap A_1) + \dots + P(B \cap A_n)$$
$$= P(B | A_1) P(A_1) + \dots + P(B | A_n) P(A_n)$$

(III)

Teil (II) liefert für den Nenner  $P(B)$ , also wird die rechte Seite zu

$$\frac{P(A_1) P(B | A_1)}{P(B)} = \frac{P(A_1) \frac{P(B | A_1)}{P(A_1)}}{P(B)} = P(A_1 | B).$$

q.e.d

Beispiel 3.4

Ein bestimmter medizinischer Test ist zu 95% effektiv beim erkennen einer bestimmten Krankheit, liefert allerdings bei 1% der gesunden Personen „falschen Alarm“.

Angenommen, 0,5% der Bevölkerung leiden unter dieser Krankheit. Mit welcher Wahrscheinlichkeit hat dann jemand diese Krankheit, wenn der Test dies behauptet? Es sei A „die getestete Person hat die Krankheit“, B „der Test ist „positiv“ (zeigt das Vorliegend der Krankheit)“.

$$P(A) = 0,005 \quad P(B | A) = 0,95 \quad P(B | A^c) = 0,01 \quad P(A | B) = ?$$

Die Bayes-Formel liefert:

$$P(A | B) = \frac{P(B | A) P(A)}{P(B | A) P(A) + P(B | A^c) P(A^c)}$$
$$= \frac{0,95 * 0,005}{0,95 * 0,005 + 0,01 * (1 - 0,005)}$$
$$\approx 0,323$$

Einer der zentralen Begriffe der Stochastik ist der der (stochastischen) Unabhängigkeit.  
Grob: B ist von A unabhängig, wenn die Information „A ist eingetreten“ die Wahrscheinlichkeit für B nicht ändert.

### Definition 3.5

Zwei Ereignisse A und B heißen (stochastisch) unabhängig, wenn  $P(A \cap B) = P(A) * P(B)$  gilt.

Eine Familie  $\{A_i : i \in I\}$  im Ereignisraum heißt unabhängig, wenn

$$P\left(\bigcap_{i \in J} A_i\right) = \prod_{i \in J} P(A_i) \quad (\text{für alle endlichen Teilmengen } J \text{ und } I).$$

Bei  $I = \{1, 2, 3\}$ :

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

$$P(A_1 \cap A_2) = P(A_1) * P(A_2)$$

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

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

Der Grund für die „schwierig aussehende“ Definition bei allgemeinen Ereignisfunktionen ist die Tatsache, dass aus der paarweisen Unabhängigkeit

$P(A_i \cap A_j) = P(A_i) * P(A_j)$ , für alle  $i, j \in I$  mit  $i \neq j$  nicht die volle Unabhängigkeit folgt.

### Beispiel 3.6

Der zweimalige Wurf einer fairen Münze führt auf ein Laplace-Experiment über  $\Omega = \{(0,0), (0,1), (1,0), (1,1)\}$ , wobei wir 0 für Kopf und 1 für Wappen schreiben.

Wir betrachten:

$$A_1 = \{(0,0), (0,1)\} \quad \text{„Kopf im 1. Wurf“}$$

$$A_2 = \{(0,0), (1,0)\} \quad \text{„Kopf im 2. Wurf“}$$

$$A_3 = \{(0,1), (1,0)\} \quad \text{„Ergebnisse verschieden“}$$

$$P(A_1 \cap A_2) = P(\{0,0\}) = \frac{1}{4} = \frac{1}{2} * \frac{1}{2} = P(A_1) * P(A_2)$$

$$P(A_1 \cap A_3) = P(\{0,1\}) = P(A_1) * P(A_3)$$

$$P(A_2 \cap A_3) = P(\{1,0\}) = P(A_2) * P(A_3)$$

Das Ereignissystem  $\{A_1, A_2, A_3\}$  ist also paarweise unabhängig, **aber:**

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




### Beispiel 3.7

Eine typische Fragestellung der angewandten Wahrscheinlichkeitsrechnung beschäftigt sich mit dem Funktionieren von Innovationen.

Wir betrachten einen einfachen Fall:

Ein System bestehe aus 5 wie folgt angeordneten Komponenten:



Wir nehmen an, dass die Komponenten unabhängig voneinander und zwar jeweils mit der Wahrscheinlichkeit  $p$  funktionieren. Das Gesamtsystem funktioniert, wenn es einen Pfad funktionierender Komponenten von L nach R gibt.

Mit welcher Wahrscheinlichkeit funktioniert das Gesamtsystem?

Es sei  $A_i$  das Ereignis, dass Komponente  $i$  funktioniert.  $B$  Das Ereignis, dass das Gesamtsystem funktioniert.

Dann gilt  $B = B_1 \cup B_2$  mit

$$B_1 = A_4 \cap A_5 \quad (\text{der untere Pfad ist passierbar})$$

$$B_2 = A_1 \cap (A_2 \cup A_3) \quad (\text{der obere Pfad ist passierbar})$$

$$P(B_1) = P(A_4 \cap A_5) = P(A_4) \cdot P(A_5) = p^2 \quad (\text{Unabhängigkeit!})$$

$$\begin{aligned} P(B_2) &= P(A_1 \cap A_2 \cup A_1 \cap A_3) \\ &= P(A_1 \cap A_2) + P(A_1 \cap A_3) - P(A_1 \cap A_2 \cap A_3) \\ &= p^2 + p^2 - p^3 \end{aligned}$$

Paarweise Unabhängigkeit würde nicht reichen

$$P(B) = P(B_1) + P(B_2) - P(B_1 \cap B_2)$$

$$\begin{aligned} P(B_1 \cap B_2) &= P(A_4 \cap A_5 \cap A_1 \cap A_2) + P(A_4 \cap A_5 \cap A_1 \cap A_3) - P(A_4 \cap A_5 \cap A_1 \cap A_2 \cap A_3) \\ &= 2p^4 - p^5 \end{aligned}$$

Insgesamt:

$$P(B) = p^2 + 2p^2 - p^3 - 2p^4 + p^5 = p^2(3 - p - 2p^2 + p^3)$$

## 5. Vorlesung (11.11.2004)

### §4 Diskrete Zufallsgrößen

#### 4.1 Allgemeines

Oft interessiert man sich nicht für das Ergebnis  $\omega$  eines Zufallsexperimentes, sondern nur für einen hiervon unabhängigen Wert  $X(\omega)$ .

##### Beispiel 4.1.1

Eine faire Münze wird 5-mal geworfen. Wie oft erscheint „Kopf“?

Schreibt man „1“ für Kopf und „0“ für Wappen, so erhält man ein Laplace-Experiment über

$$\Omega = \{(\omega_1, \dots, \omega_5) : \omega_i \in [0,1]\} \quad (= \{0,1\}^5).$$

Mit dieser „Kodierung“ ist die Anzahl  $X(\omega)$  der Kopfwürfe bei einem Ergebnis (Wurffolge)

$$\omega \text{ gegeben durch } X(\omega) = \omega_1 + \dots + \omega_5 = \sum_{k=1}^5 \omega_k. \quad (X : \Omega \rightarrow \mathbb{R})$$

Die möglichen Werte sind  $0, 1, \dots, 5$ .

Mit welcher Wahrscheinlichkeit treten diese Werte auf?  $P(X=0) = P(\{(0,0,0,0,0)\}) = 1/32$

Bei beliebigem Paar aus dem Wertebereich gibt es  $\binom{5}{k}$  Möglichkeiten, die  $k$  Kopfwürfe auf


die 5 möglichen Positionen zu verteilen, also  $P(X=k) = \binom{5}{k} \cdot 2^{-5}$  für  $k = 0, 1, \dots, 5$ .

K	0	1	2	3	4	5
$P(X=k)$	$1/32$	$5/32$	$10/32$	$10/32$	$5/32$	$1/32$

##### Definition 4.1.2

- (I) Eine diskrete Zufallsvariable (ZV) ist eine Abbildung  $X(\omega) \rightarrow \mathbb{R}$  mit endlich vielen oder abzählbar unendlich vielen Werten (z.B.  $\mathbb{N}, \mathbb{Z}, \mathbb{Q}$ )
- (II) Die Verteilung einer diskreten Zufallsvariablen ist die Abbildung  $A \rightarrow P(X \in A)$  ( $= P(\{\omega \in \Omega : X(\omega) \in A\})$ ). Diese ist ein Wahrscheinlichkeitsmaß (s. Def. 1.3).
- (III) Die Wahrscheinlichkeitsmassenfunktion (WMF)  $p_x$  einer diskreten Zufallsvariablen  $X$  wird definiert durch  $p_x : \mathbb{R} \rightarrow [0,1]$ ,  $p_x(x) = P(X=x)$ .
- (IV) Die Verteilungsfunktion  $F_x$  einer diskreten Zufallsvariablen wird definiert durch  $F_x : \mathbb{R} \rightarrow [0,1]$ ,  $F_x(x) = P(X \leq x)$ .


Massenfunktionen können beispielsweise durch ein Stabdiagramm illustriert werden. In der Situation des Beispiels erhält man:



Stabdiagramm für die WMF

Allgemein:  $p_x(x) \geq 0$

$$\sum_x p_x(x) = 1$$



Verteilungsfunktion  $F_x$

(isoton, schwach monoton wachsend)

Stetig von rechts, bei diskreter ZV von reinem Sprungtyp.

$$F_x(0) = P(X \leq 0)$$

Sprunghöhe in  $x$  ist

$$P(X = x) = p_x(x)$$

### Bemerkung 4.1.3

- (I) Zu jeder Zufallsvariablen gehört eine Verteilung, aber verschiedene ZV können durchaus dieselbe Verteilung haben (!). Beim 5-maligen Münzwurf erhält man beispielsweise auch für die Anzahl  $Y$  der Wappenwürfe die obige WMF (insbesondere haben  $X$  und  $Y$  dieselbe Verteilung), aber natürlich sind  $X$  und  $Y$  nicht gleich (hier gilt sogar  $P(X = Y) = 0$ ).
- (II) Da durch die Abbildung  $X$  in der Regel unterschiedlich viele Argumente  $\omega$  zu einem Bildwert  $X(\omega)$  zusammengefasst werden, sind in der Regel selbst bei einem Laplace-Experiment die Werte  $P(X = x)$  nicht gleich groß.

## 4.2 Einige wichtige diskrete Verteilungen

### 4.2.1 (Binominalverteilung)

$X$  heißt binominal verteilt mit Parametern  $n$  und  $p$ . Kurz:  $X \sim \text{Bin}(n, p)$ , wenn gilt:

$$P(X = k) = \binom{n}{k} p^k (1-p)^{n-k} \quad \text{für } k = 0, 1, \dots, n.$$

Die ZV  $X$  aus Beispiel 4.1.1 ist  $\text{Bin}\left(5, \frac{1}{2}\right)$ -verteilt. Ganz allgemein erhält man  $\text{Bin}(n, p)$  als Verteilung der Anzahl  $X$  der Folge bei  $n$  unabhängigen Versuchsfolgen mit Erfolgswahrscheinlichkeit  $p$ :

Bezeichnet  $A_i$  das Ereignis: „Erfolg im  $i$ -ten Versuch“, so hat jede Sequenz  $A_1 \cap A_2 \cap A_3^c \cap \dots \cap A_{n-1}^c \cap A_n^c$  in der  $k$ -mal  $A_i$  und  $(n-k)$ -mal  $A_i^c$  steht, die Wahrscheinlichkeit  $p^k (1-p)^{n-k}$ .

Schließlich gibt es  $\binom{n}{k}$  Möglichkeiten, die  $k$  Erfolge auf die  $n$  Positionen zu verteilen.

Wirft man beispielsweise einen Würfel 100x, so ist die Anzahl der Sechser  $\text{Bin}\left(100, \frac{1}{6}\right)$ .

#### 4.2.2 (Hypergeometrische Verteilung)

Eine ZV heißt hypergeometrisch verteilt mit Parametern  $M, m, n$  ( $M, m, n \in \mathbb{N}$ ), wenn gilt:

$$P(X = k) = \frac{\binom{m}{k} \binom{M-m}{n-k}}{\binom{M}{n}}, \quad k = 0, \dots, n.$$

Typische Fragestellung: Wahrscheinlichkeit für 2 Richtige beim Zahlenlotto „6 aus 49“.

$$\frac{\binom{6}{2} \binom{49-6}{6-2}}{\binom{49}{6}}$$

Anzahl der möglichen Ziehungen

Die Hypergeometrische Verteilung taucht bei Stichproben ohne Zurücklegen auf: Enthält eine Urne  $M$  Kugeln, von denen  $m$  weiß und  $M-m$  schwarz sind, und werden  $n$  Kugeln zufällig und ohne (!) Zurücklegen entnommen, so ist  $X$  die Anzahl der weißen Kugeln in der Stichprobe:

Möglichkeiten für weiß

→

$P(X = k) =$

←

Möglichkeiten für schwarz

$$\frac{\binom{m}{k} \binom{M-m}{n-k}}{\binom{M}{n}}$$


Anzahl der Stichproben

↑

#### 4.2.3 (Geometrische Verteilung)

Angenommen, ein Würfel wird solange geworfen, bis eine 6 erscheint; X sei die hierfür nötige Wurfzahl.

$$P(X = n) = \left(\frac{5}{6}\right)^{n-1} \frac{1}{6} \quad (n \in \mathbb{N} \setminus \{0\}).$$



Allgemein: X heißt geometrisch verteilt mit Parameter p, wenn gilt:

$$P(X = n) = (1 - p)^{n-1} p$$

Die geometrische Verteilung taucht immer dann auf, wenn man ein Zufallsexperiment solange wiederholt, bis erstmalig ein bestimmtes Ereignis A erscheint.

Der Parameter p ist die Wahrscheinlichkeit von A (Erfolgswahrscheinlichkeit).

## Achtung!

Wenn man die Anzahl der Misserfolge zählt, erhält man eine andere Version der geometrischen Verteilung:  $(1 - p)^n p$ ,  $n \in \mathbb{N}_0$

#### 4.2.4 (Poisson Verteilung)

Die ZV X heißt Poisson-verteilt mit Parameter  $\lambda (> 0)$ , wenn gilt

$$P(X = k) = e^{-\lambda} \frac{\lambda^k}{k!}, \quad k \in \mathbb{N}_0.$$

#### Satz 4.3 („Das Gesetz der seltenen Ereignisse“)

Ist  $(p_n)_{n \in \mathbb{N}} \subset [0, 1]$  eine Nullfolge mit  $\lim_{n \rightarrow \infty} n p_n = \lambda$ , so gilt für alle  $k \in \mathbb{N}_0$ :

$$\lim_{n \rightarrow \infty} \binom{n}{k} p_n^k (1 - p_n)^{n-k} = e^{-\lambda} \frac{\lambda^k}{k!}$$

Wahrscheinlichkeit für k Erfolge bei n Wiederholungen bei Erfolgswahrscheinlichkeit p.

Beweis:


$$\begin{aligned} \binom{n}{k} p_n^k (1 - p_n)^{n-k} &= \frac{n(n-1) \cdot \dots \cdot (n-k+1)}{n^k} \cdot \frac{(n p_n)^k}{k!} \cdot \left(1 - \frac{n p_n}{n}\right)^{n-k} \\ &\stackrel{\uparrow}{=} \frac{n}{n} \cdot \frac{n-1}{n} \cdot \dots \cdot \frac{(n-k+1)}{n} = 1 \quad \uparrow = \frac{\lambda^k}{k!} \quad \uparrow \left(1 - \frac{n p_n}{n}\right)^n = \left(1 - \frac{\lambda}{n}\right)^n = e^{-\lambda} \\ &= \frac{\lambda^k}{k!} \cdot \frac{e^{-\lambda}}{\left(1 - \frac{n p_n}{n}\right)^k} = 1 \end{aligned}$$

Bekannt:  $\lim_{n \rightarrow \infty} \left(1 + \frac{x}{n}\right)^n = e^x$

6. Vorlesung (18.11.2004)

4.4 Erwartungswerte und Momente

In diesem Abschnitt werden einige Verteilungsparameter eingeführt. Dies sind Zahlen, die bestimmte Aspekte einer Verteilung, wie beispielsweise die Lage oder die Streuung, beschreiben.



Beispiel 4.5

Sei X das Resultat beim Wurf eines fairen Würfels.


Der Mittelwert nach n Würfeln ist

$$\frac{1}{n} (1 \cdot \#(1) + 2 \cdot \#(2) + 3 \cdot \#(3) + \dots + 6 \cdot \#(6)),$$

wobei #(i) für die Anzahl der Würfe und Resultat i steht.

Für große n gilt  $\frac{1}{n} \#(i) \approx P(X=i)$ . Damit liegt der Mittelwert bei großem n in der Nähe von

$$1 \cdot P(X=1) + 2 \cdot P(X=2) + \dots + 6 \cdot P(X=6) \\ = \frac{1}{6} (1 + 2 + \dots + 6) = \frac{21}{6} = 3,5$$



Definition 4.6

Sei X eine diskrete Zufallsvariable mit WMF  $p_x$ . Dann wird der Erwartungswert  $E(X)$  von

$$X \text{ definiert durch } E(X) = \sum_{x \in \mathbb{R}} x \cdot P(X=x) \left( = \sum_{\substack{x \in \mathbb{R} \\ P(X=x) > 0}} x \cdot P(X=x) \right) \\ = \sum_{x \in \mathbb{R}} x \cdot p_x(x)$$

Hierbei wird vorausgesetzt, dass die Reihe absolut konvergiert, d.h.  $\sum |x| p_x(x) < \infty$ .

Ist das nicht der Fall, so sagt man, dass der Erwartungswert von X nicht existiert.

Es bietet sich die folgende Analogie zu Mechanik an:

Platziert man die Massen  $p_1, p_2, \dots$  auf die Plätze  $x_1, x_2, \dots$ , so ist  $\sum x_i p_i$  die Lage des Schwerpunktes des Gesamtbildes.

Beispiel 4.7

$X \sim P(\lambda)$ ,  $P(X=k) = e^{-\lambda} \frac{\lambda^k}{k!}$ ,  $k \in \mathbb{N}$ . Gesucht EX.

$$EX = \sum_{k=0}^{\infty} k \cdot P(X=k) = e^{-\lambda} \sum_{k=1}^{\infty} \frac{\lambda^k}{(k-1)!} \\ = e^{-\lambda} \cdot \lambda \sum_{k=1}^{\infty} \frac{\lambda^{k-1}}{(k-1)!} = e^{-\lambda} \cdot \lambda \cdot e^{\lambda} = \lambda$$

Oft kann man die interessierende Zufallsvariable  $Y$  als Funktion  $g$  einer anderen ZV  $X$  schreiben:  $\Omega \xrightarrow{x} \mathbb{R} \xrightarrow{g} \mathbb{R} \quad y := g(x)$ .

**Satz 4.8**

Es gilt  $Eg(x) = \sum_{x \in \mathbb{R}} g(x) \cdot p_X(x) = \sum_{x \in \mathbb{R}} g(x) \cdot P(X = x)$ , vorausgesetzt, die Summen konvergieren absolut.

**Beweis:**

$$\begin{aligned} Eg(x) &= \sum_{y \in \mathbb{R}} y \cdot P(g(x) = y) = \sum_{y \in \mathbb{R}} y \cdot P(x \in g^{-1}(y)) = \sum_{y \in \mathbb{R}} y \sum_{x \in g^{-1}(y)} P(X = x) \\ &= \sum_{y \in \mathbb{R}} \sum_{x \in g^{-1}(y)} y \cdot P(X = x) = \sum_{x \in \mathbb{R}} g(x) \cdot P(X = x). \end{aligned}$$

**Beispiel 4.9**

$X \sim P(\lambda)$ . Gesucht ist  $E(X(X-1))$ , verwende Satz 4.8 mit  $g(x) = x(x-1)$ .

$$\begin{aligned} EX(X-1) &= \sum_{k=0}^{\infty} k \cdot (k-1) \cdot P(X = k) = \sum_{k=0}^{\infty} k \cdot (k-1) \cdot e^{-\lambda} \frac{\lambda^k}{k!} \\ &= e^{-\lambda} \sum_{k=2}^{\infty} \frac{\lambda^k}{(k-2)!} = e^{-\lambda} \cdot \lambda^2 \sum_{k=2}^{\infty} \frac{\lambda^{k-2}}{(k-2)!} = e^{-\lambda} \cdot \lambda^2 \cdot e^{\lambda} = \lambda^2 \end{aligned}$$

**Satz 4.10 (Rechenregeln)**

Sei  $X$  und  $Y$  diskrete ZV und  $c \in \mathbb{R}$ . Vorausgesetzt, dass die beteiligten Summen absolut konvergieren, gilt dann:

$$E(X + Y) = E(X) + E(Y), \quad E(cX) = cE(X), \quad X \leq Y \Rightarrow E(X) \leq E(Y)$$

(ohne Beweis)

Auch klar:  $E(X_1 + X_2 + \dots + X_n) = EX_1 + EX_2 + \dots + EX_n$  (Folgt mit Induktion)

**Beispiel 4.11**

$X \sim \text{Bin}(n, p)$ , gesucht:  $EX$

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

$$\begin{aligned} EX &= \sum_{k=0}^n k \binom{n}{k} p^k (1-p)^{n-k} = \sum_{k=0}^n k \cdot \frac{n!}{k!(n-k)!} p^k (1-p)^{n-k} \\ &= n \cdot \sum_{k=1}^n \frac{(n-1)!}{(k-1)!(n-k)!} p^k (1-p)^{n-k} = n \cdot \sum_{k=1}^n \binom{n-1}{k-1} p^k (1-p)^{n-k} \\ &= n \cdot \sum_{k=0}^{n-1} \binom{n-1}{k} p^{k+1} (1-p)^{n-1-k} = n \cdot p \sum_{k=0}^{n-1} \binom{n-1}{k} p^k (1-p)^{n-1-k} \end{aligned}$$

$$EX = n \cdot p, \text{ da } \sum_{k=0}^{n-1} \binom{n-1}{k} p^k (1-p)^{n-1-k} = 1$$

Die Summe über alle Werte der WMF zu  $\text{Bin}(n-1, p)$

Alternativ unter Anwendung der Rechenregeln (Satz 4.10):

Es gilt  $X = X_1 + \dots + X_n$ , wobei  $X_i$  die Anzahl der Erfolge in der i-ten Versuchswiederholung ist.

$$X_i \sim \text{Bin}(1, p)$$

Damit  $EX_i = 0P(X_i = 0) + 1P(X_i = 1) = P(X_i = 1) = p$  und deshalb  $EX = \sum_{i=1}^n EX_i = \sum_{i=1}^n p = np$ .

### Allgemein

$$X = 1_A \Rightarrow EX = 0P(1_A = 0) + 1P(1_A = 1) = P(1_A = 1) = P(A)$$

Die Einbettung  $A \mapsto 1_A$  des Systems der Ereignisse in das System der ZV setzt  $P$ , was zu  $E$  führt.

### Definition 4.12

Das k-te Moment von  $X$  ist  $EX^k$  (vorausgesetzt  $\sum_x |x|^k P(X = x) < \infty$ )

Die Varianz von  $X$  ist  $\text{var}(X) = E(X - EX)^2$  (wieder unter der Voraussetzung, dass  $EX^2 < \infty$ , sonst sagt man, die Varianz existiert nicht)

Schließlich heißt  $\sigma(X) = \sqrt{\text{var}(X)}$  die Standardabweichung von  $X$ .

Die Varianz ist ein Maß für die Streuung einer ZV um ihren EW.

### Rechenregel:

$$\begin{aligned} E(X - EX)^2 &= E(X^2 - 2X(EX) + (EX)^2) \\ &= E(X^2) - E(2XE(X)) + E((EX)^2) \\ &= E(X^2) - 2E(X)E(X) + (EX)^2 \\ &= E(X^2) - (EX)^2 \end{aligned}$$

also  $\boxed{\text{var}(X) = E(X^2) - (EX)^2}$

### Beispiel 4.13

$X \sim P(\lambda)$ . Dann wissen wir  $EX = \lambda$  (Bsp. 4.7), und  $EX(X-1) = \lambda^2$  (Bsp. 4.9).

Frage  $\text{var}(X) = ?$

$$E(X^2) = E(X^2 - X) + EX = \lambda^2 + \lambda$$

$$(EX)^2 = \lambda^2$$

$$\Rightarrow \text{var}(X) = E(X^2) - (EX)^2 = \lambda^2 + \lambda - \lambda^2 = \lambda$$



### Weitere Rechenregeln

Sei  $c \in \mathbb{R}$ , dann

$$\begin{aligned}\text{var}(X+c) &= E((X+c) - E(X+c))^2 = E(X+c - EX - c)^2 \\ &= E(X - EX)^2 = \text{var}(X)\end{aligned}$$

$$\begin{aligned}\text{var}(cX) &= E(c^2X^2) - (E(cX))^2 = c^2E(X^2) - c^2(EX)^2 \\ &= c^2(E(X^2) - (EX)^2) = c^2 \text{var}(X)\end{aligned}$$

Damit klar:

$$\sigma(X+c) = \sigma(X), \quad \sigma(cX) = |c| \sigma(X)$$

Tabelle mit den Erwartungswerten und Varianzen der im vorausgegangenen Unterabschnitt eingeführten Variablen:

Verteilung	Parameter	EW	Var
Poisson	$\lambda$	$\lambda$	$\lambda$
Binominal	$n, p$	$n \cdot p$	$n \cdot p(1-p)$
Geometrisch	$p$	$\frac{1}{p}$	$\frac{1-p}{p^2}$
Hypergeometrisch	$M, m, n$	$\frac{n \cdot m}{M}$	$\frac{m \cdot n}{M} \cdot \frac{M-m}{M} \cdot \frac{M-n}{M-1}$

## 7. Vorlesung (25.11.2004)

### §5 Stetige Zufallsgrößen

#### 5.1 Allgemeines

Viele Zufallsgrößen können ein Kontinuum von Werten annehmen: Lebensdauer, Messfehler, Proportionen, etc.

#### Definition 5.1.1


Eine ZV  $X$  heißt absolutstetig verteilt (kurz: stetig) mit Wahrscheinlichkeitsdichtefunktion  $f_x$  (kurz: Dichte), wenn

$$P(X \leq x) = \int_{-\infty}^x f_x(y) dy, \quad \forall x \in \mathbb{R} \text{ gilt.}$$

Die Funktion  $F_x : \mathbb{R} \rightarrow \mathbb{R}$ ,  $F_x = P(X \leq x)$ , heißt die Verteilungsfunktion zu  $X$ .

(Index  $X$  bei  $f_x$ ,  $F_x$  wird weggelassen, wenn  $X$  aus dem Zusammenhang hervorgeht.)

Im diskreten Fall ist  $F_x$  von reinem Sprungtyp:



Im stetigen Fall ist  $F_x$  „glatt“: Grob ist  $f_x$  die Ableitung von  $F_x$ , insbesondere also  $F_x$  stetig.




Insbesondere  $P(X = x) = 0 \quad \forall x \in \mathbb{R}$  bei stetigen ZV.

Mit der Additivität ( $-\infty < a < b < \infty$ )

$$\begin{aligned} P(a < X \leq b) &= P(X \leq b) - P(X \leq a) \\ &= \int_{-\infty}^b f(y) dy - \int_{-\infty}^a f(y) dy = \int_a^b f(y) dy \\ &= P(a \leq X \leq b) = P(a < X < b) \end{aligned}$$

Die führt auf die folgende wichtige Interpretation von Wahrscheinlichkeitsdichte:



$$\int_a^b f(y) dy = P(X \in [a, b])$$

Die Wahrscheinlichkeit für  $X \in A$  ist die Fläche unter  $f$  über  $A$ .

Eigenschaften von Dichten:  $f \geq 0$ ,  $\int_{-\infty}^{\infty} f(y) dy = 1$  ( $P(X \in \mathbb{R})$ )

Analogie zur Massenfunktion:  $p \geq 0$ ,  $\sum_x p(x) = 1$

Im Gegensatz zur Massenfunktion können Dichten durchaus  $>1$  sein.

Die Werte von  $f$  lassen sich als „Infinitesimale Wahrscheinlichkeit“ interpretieren als

$$\lim_{h \downarrow 0} \frac{1}{h} P\left(x - \frac{h}{2} \leq X \leq x + \frac{h}{2}\right) = \lim_{h \downarrow 0} \frac{1}{h} \int_{x-\frac{h}{2}}^{x+\frac{h}{2}} f(y) dy = f(x), \text{ wenn } f \text{ stetig in } x.$$

Näherungsweise hat man also bei kleinen  $h$ :  $P\left(x - \frac{h}{2} \leq X \leq x + \frac{h}{2}\right) \approx hf(x)$ .


## 5.2 Einige wichtige stetige Verteilungen

### 5.2.1 (Die Gleichverteilung)

Eine ZV  $X$  heißt gleichverteilt auf dem Intervall  $[a, b]$

(kurz:  $\mathcal{L}(X) = \text{unif}(a, b)$ ,  $X \sim \text{unif}(a, b)$ , wenn  $X$  die Dichtefunktion


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



ist.

(‘<’ oder ‘≤’ ist egal, da die einzelnen Punkte die Wahrscheinlichkeit 0 haben)

Wie sieht die zugehörige Verteilungsfunktion aus?  $F(x) = \int_{-\infty}^x f(y) dy$



$\text{unif}(a, b)$  kann als kontinuierliches Analogon zur Laplace-Verteilung (auf  $(a, b)$ ) angesehen werden: alle infinitesimalen Wahrscheinlichkeiten haben denselben Wert.  $\text{unif}(0, 1)$  spielt bei stochastischen Simulationen eine zentrale Rolle.

### 5.2.2 (Die Exponentialverteilung)

Die Exponentialverteilung mit Parameter  $\lambda$  ( $> 0$ ) wird durch die Dichte

$$f(x) = \begin{cases} \lambda e^{-\lambda x}, & x \geq 0 \\ 0, & \text{sonst} \end{cases} \text{ beschrieben,}$$

die sog. Verteilungsfunktion ist  $F(x) = \begin{cases} 1 - e^{-\lambda x}, & x \geq 0 \\ 0, & x < 0 \end{cases}$

(taucht häufig im Zusammenhang mit Wartezeiten und Lebensdauer auf)

$P(X \geq x + y | X \geq y)$  Wahrscheinlichkeit dafür, dass das Bauteil noch weitere  $x$  Einheiten durchhält, wenn es das Alter  $> y$  hat.

$$= \frac{P(X \geq x + y \text{ und } X \geq y)}{P(X \geq y)} = \frac{1 - F(x + y)}{1 - F(y)} = \frac{1 - (1 - e^{-\lambda(x+y)})}{1 - (1 - e^{-\lambda y})} = e^{-\lambda x} = P(X \geq x)$$

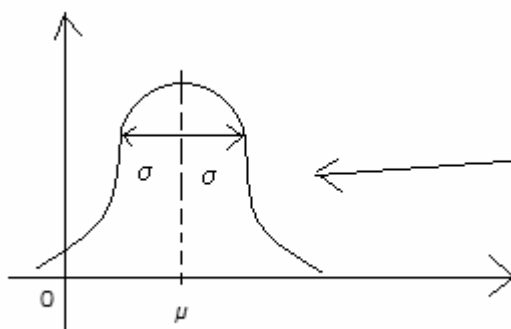
Kann gestrichen werden, da bereits in erster Bedingung enthalten.

Also: Das Alter spielt bei dieser Verteilung keine Rolle, „Gedächtnislosigkeit“ der Exponentialverteilung. („Bauteil altert nicht“)

### 5.2.3 (Die Normalverteilung)

Die wichtigste Verteilung ist die Normalverteilung mit Parametern  $\mu \in \mathbb{R}$  und  $\sigma^2 > 0$ , kurz:  $N(\mu, \sigma^2)$ , mit Dichtefunktion

$$f(x) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left(-\frac{1}{2\sigma^2}(x - \mu)^2\right), \quad -\infty < x < \infty.$$



Gaußsche Glockenkurve  
Wendepunkte in  $\mu \pm \sigma$

Taucht häufig bei Messfehlern auf  
(zentraler Grenzwertsatz)

Für die zugehörige Verteilungsfunktion gibt es keine einfache Formel. Für die Werte  $\mu = 0$ ,  $\sigma^2 = 1$  (man nennt  $N(0,1)$  auch die Standardverteilung) sind die Werte der

Verteilungsfunktion  $\Phi(x) = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^x e^{-\frac{1}{2}y^2} dy$  verteilt.

Beispielsweise gibt  $\Phi(1.645) \approx 0,95$

Lemma 5.3

Für alle  $\beta \in \mathbb{R}$ ,  $\alpha \neq 0$  gilt:

$$X \sim N(\mu, \sigma^2) \Rightarrow \alpha X + \beta \sim N(\alpha\mu + \beta, \alpha^2\sigma^2)$$

Beweis:

Sei  $Y := \alpha X + \beta$ .

Die zugehörige Verteilungsfunktion ist  $F_Y(y) = P(Y \leq y) = P(\alpha X + \beta \leq y)$

$$= P\left(X \leq \frac{y - \beta}{\alpha}\right) = F_X\left(\frac{y - \beta}{\alpha}\right)$$

$$= \int_{-\infty}^{\frac{y - \beta}{\alpha}} \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left(\frac{-1}{2\sigma^2}(x - \mu)^2\right) dx$$

Substituiere  $z = \alpha X + \beta$

Dichtefunktion zu $N(\alpha\mu + \beta, \alpha^2\sigma^2)$	→	$= \int_{-\infty}^y \frac{1}{\sqrt{2\pi\alpha^2\sigma^2}} \exp\left(\frac{-1}{2\alpha^2\sigma^2}(z - (\alpha\mu + \beta))^2\right) dz$
--	---	--

Die Verteilungsfunktion zu Y ist also die zu  $N(\alpha\mu + \beta, \alpha^2\sigma^2)$  d.h.  $Y \sim N(\alpha\mu + \beta, \alpha^2\sigma^2)$ .

Beispiel 5.4

(I) Angenommen, es ist  $P(1 < y < 1.5)$  für  $Y \sim N\left(1, \frac{1}{4}\right)$  zu bestimmen.

Mit Lemma 5.3 folgt  $2(Y - 1) = 2Y - 2 \sim N(0,1)$ ,

also  $P(1 < y < 1.5) = P(0 < 2(Y - 1) < 1)$

$$= P(2(Y - 1) \leq 1) - P(2(Y - 1) \leq 0)$$

$$= \Phi(1) - \Phi(0) = 0.8413... - 0.5 = 0.3413...$$

↖  

s. Tabelle
------------

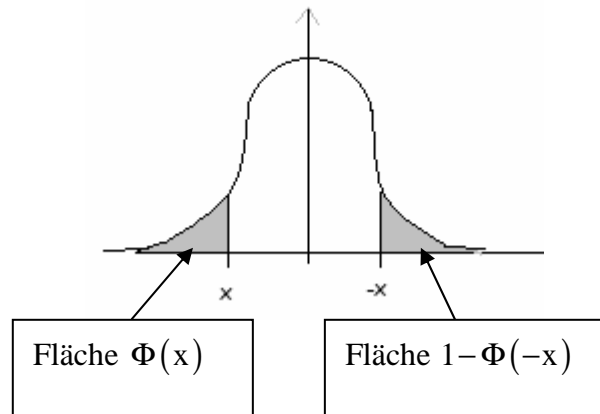
(II) Es sei Y wie in (I), nun soll ein Wert q mit der Eigenschaft  $P(Y \leq q) : 0,95$  bestimmt werden.

Wegen  $Y \leq y \Leftrightarrow 2(Y - 1) \leq 2(y - 1)$  und  $P(2(Y - 1) \leq 2(y - 1)) = \Phi(2(y - 1))$

und  $\Phi(1.645) \approx 0,95$  führt dies auf  $2(y - 1) = 1.645$ , also  $q = 1.8225$ .

Bei Standardparametern  $\mu = 0, \tau^2 = 1$  ist die Glockenkurve symmetrisch um 0, dies ergibt

$$\Phi(-x) = 1 - \Phi(x).$$



Insbesondere reicht eine Tafel für die Werte  $x \geq 0$ .

## 8. Vorlesung (02.12.2004)

absolutstetig verteilte Zufallsgröße  $X$  Dichte  $f$  heißt  $P(X \in A) = \int_A f(x) dx$

(Wahrscheinlichkeit als Fläche unter der Dichtefunktion)

### 5.3 Erwartungswert und Momente

Ist  $X$  eine stetige ZV mit Dichte  $f$ , so wird der Erwartungswert  $EX$  von  $X$  definiert durch

$$EX = \int x f(x) dx,$$

vorausgesetzt, es gilt  $\int |x| f(x) dx < \infty$  (sonst sagt man, dass der Erwartungswert nicht existiert).

### Satz 5.5

$$Eg(x) = \int g(x) f(x) dx$$

### Satz 5.6

Unter der Voraussetzung, dass die beteiligten Erwartungswerte existieren, gilt

$$E(X + Y) = EX + EY, \quad E(cX) = cEX \quad (c \in \mathbb{R}, \text{ linearität})$$

$$X \leq Y \Rightarrow EX \leq EY \quad (\text{Monotonie})$$

### Definition 5.7

Das  $k$ -te Moment einer (stetigen) ZV  $X$  ist  $EX^k$ , die Varianz  $\text{var}(X) = E(X - EX)^2$ , die Standardabweichung  $\sigma(X) = \sqrt{\text{var}(X)}$ .

### Rechenregeln:

$$\text{var}(X) = EX^2 - (EX)^2$$

$$\text{var}(cX) = c^2 \text{var}(X)$$

$$\text{var}(X + c) = \text{var}(X)$$

### Beweis:

$$\text{var}(X) = E(X - EX)^2 = E(X^2 - 2XEX + (EX)^2)$$

$$(\text{Linearität}) = EX^2 - 2EXEX + (EX)^2 = EX^2 - (EX)^2$$

$$\text{var}(cX) = E(cX)^2 - (E(cX))^2 = E(c^2X^2)$$

$$= c^2E(X^2) - c^2(EX)^2 = c^2(EX^2 - (EX)^2) = c^2 \text{var}(X)$$

### Beispiel 5.8

(I) Ist  $X$  gleichverteilt auf dem Intervall  $(0,1)$ , so gilt:

$$f(x) = \begin{cases} 1 & , 0 < x < 1 \\ 0 & , \text{sonst} \end{cases}$$

$$\text{Also } EX = \int x f(x) dx = \int_0^1 x dx = \frac{1}{2}.$$

$$EX^2 = \int g(x) f(x) dx = \int_0^1 x^2 dx = \frac{1}{3}, \text{ also}$$

$$\text{var}(X) = EX^2 - (EX)^2 = \frac{1}{3} - \left(\frac{1}{2}\right)^2 = \frac{1}{12}$$

=  $Eg(x)$  mit  
 $g(x) = x^2$

(II) Im Falle  $X \sim N(0,1)$  hat man  $f(x) = \frac{1}{\sqrt{2\pi}} e^{-\frac{x^2}{2}}$ , also

$$EX = \int x \frac{1}{\sqrt{2\pi}} e^{-\frac{x^2}{2}} dx.$$

$$\begin{aligned} \text{var}(X) = EX^2 &= \frac{1}{\sqrt{2\pi}} \int x^2 e^{-\frac{x^2}{2}} dx \\ &= \frac{1}{\sqrt{2\pi}} \int x \left( x e^{-\frac{x^2}{2}} \right) dx \\ &= \left[ -\frac{1}{\sqrt{2\pi}} x e^{-\frac{x^2}{2}} \right]_{-\infty}^{\infty} = \frac{1}{\sqrt{2\pi}} \int 1 \cdot \left( e^{-\frac{x^2}{2}} \right) dx = 0 + \frac{1}{\sqrt{2\pi}} \int e^{-\frac{x^2}{2}} dx = 1 \end{aligned}$$

Integral über die  
Dichtefkt. zu  $N(0,1)$

Zur „Standartnormalverteilung“  $N(0,1)$  gehören der Erwartungswert 0 und die Varianz 1.



Gilt allgemein  $X \sim N(\mu, \sigma^2)$ ,  $\mu \in \mathbb{R}$  und  $\sigma^2 > 0$ , so folgt mit Lemma 5.2, dass  $Y := \frac{X - \mu}{\sigma}$  die Verteilung  $N(0,1)$  hat.

Also:

$$0 = EY = E\left(\frac{X - \mu}{\sigma}\right) = \frac{1}{\sigma}(EX - \mu)$$

damit  $EX = \mu$

$$1 = \text{var}(Y) = \text{var}\left(\frac{X - \mu}{\sigma}\right) = \frac{1}{\sigma^2} \text{var}(X - \mu) = \frac{1}{\sigma^2} \text{var}(X)$$

$$\boxed{\Rightarrow \text{var}(X) = \sigma^2}$$

### §6 Mehrdimensionale Zufallsgrößen und Unabhängigkeit

Hat man mehrere von dem Ergebnis  $\omega$  eines Zufallsexperiments abhängige Größen  $X_1(\omega), X_2(\omega), \dots, X_n(\omega) \in \mathbb{R}$ , so kann man diese zu einem stochastischen Vektor  $X$  zusammenfassen:  $X = (X_1, \dots, X_n)$ ,  $X: \Omega \rightarrow \mathbb{R}^n$ ,  $\omega \rightarrow (X_1(\omega), X_2(\omega), \dots, X_n(\omega))$ .

Konkret: Einer von ihnen wird zufällig ausgewählt. Angenommen, man interessiert sich für die Matrikelnummer, die Körpergröße und das Gewicht:

$\omega$ : ausgeählte Person

$X_1(\omega)$ : Körpergröße

$X_2(\omega)$ : Gewicht

$X_3(\omega)$ : Matrikelnummer

Wir betrachten hauptsächlich  $n = 2$ , also Paare von ZV.

#### Definition 6.1

Die gemeinsame Verteilungsfunktion  $F_{X,Y}: \mathbb{R}^2 \rightarrow \mathbb{R}$  zweier ZV  $X$  und  $Y$  (oder auch die Verteilungsfunktion  $(X, Y)$ ) wird definiert durch:

$$F_{X,Y}(x, y) = P(X \leq x \text{ und } Y \leq y) = P(\{\omega \in \Omega: X(\omega) \leq x \cap Y(\omega) \leq y\})$$

Von zentraler Bedeutung sind stochastische Abhängigkeiten von ZV.

Was bedeutet „Unabhängigkeit“ bei ZV?

(Bei Ereignissen:  $A, B$  unabhängig, wenn  $P(A \cap B) = P(A)P(B)$ )

Betrachte die Ereignisse  $\{X \leq x\}$  und  $\{Y \leq y\}$ ,  $x, y \in \mathbb{R}$ .

#### Definition 6.2

Es seien  $X, Y$  ZV mit gemeinsamer Verteilungsfunktion  $F_{X,Y}$ . Weiter sei  $F_X$  die Verteilungsfunktion zu  $X$  und  $F_Y$  die Verteilungsfunktion zu  $Y$ . Dann heißen  $X$  und  $Y$  stochastisch unabhängig, wenn gilt:

$$\boxed{F_{X,Y}(x, y) = F_X(x)F_Y(y) \text{ für alle } x, y \in \mathbb{R}}$$

Speziell bei diskreten bzw. stetigen ZV setzt man:

Definition 6.5

(I) Nehmen  $X$  und  $Y$  nur endlich viele oder höchstens abzählbar unendlich viele Werte an, so nennt man  $(X, Y)$  einen diskreten Zufallsvektor und  $p_{X,Y}(x, y) := P(X = x, Y = y)$  die gemeinsame Massenfunktion von  $X$  und  $Y$ .

(II) Gibt es eine Funktion  $f_{X,Y} : \mathbb{R}^2 \rightarrow \mathbb{R}_+$  mit der Eigenschaft

$$F_{X,Y}(x, y) = \int_{-\infty}^x \int_{-\infty}^y f_{X,Y}(s, t) ds dt \quad \forall x, y \in \mathbb{R}, \text{ so nennt man } (X, Y) \text{ einen}$$

absolutstetig verteilten (kurz: stetig) Zufallsvektor und  $f_{X,Y}$  eine gemeinsame Dichtefunktion von  $X$  und  $Y$ .

In Analogie zu den Sätzen 4.7 und 5.5 gilt nun:

Satz 6.4

Es seien  $X, Y$  ZV und  $g : \mathbb{R}^2 \rightarrow \mathbb{R}$  eine Funktion

(I) Ist  $(X, Y)$  ein diskreter Zufallsvektor mit Massenfunktion  $p_{X,Y}$ , so gilt

$$Eg(X, Y) = \sum_x \sum_y g(x, y) p_{X,Y}(x, y).$$

(II) Ist  $(X, Y)$  ein stetiger Zufallsvektor mit Dichtefunktion  $f_{X,Y}$ , so gilt

$$Eg(X, Y) = \iint g(x, y) f_{X,Y}(x, y) dx dy.$$

Interpretation bei (II): Wahrscheinlichkeit als Volumina unter der durch die Dichte definierte Oberfläche.

Zusammenhang zur Unabhängigkeit:

Satz 6.5

(I) Ist  $(X, Y)$  diskret mit Massenfunktion  $p_{X,Y}$ , so sind  $X$  und  $Y$  genau dann unabhängig, wenn gilt:  $p_{X,Y}(x, y) = p_X(x) p_Y(y)$  für alle  $x, y \in \mathbb{R}$ .

(Konkret:  $P(X = x, Y = y) = P(X = x)P(Y = y)$ )

Hierbei sind  $p_X(x) = P(X = x) = \sum_y P(X = x, Y = y) = \sum_y p_{X,Y}(x, y)$  und

$p_Y(y) = \sum_x p_{X,Y}(x, y)$  die Massenfunktion zu  $X$  bzw.  $Y$ .

(II) Sind  $X$  und  $Y$  stetig mit Dichtefunktion  $f_X$  und  $f_Y$ , so sind sie genau dann unabhängig, wenn  $f_{X,Y}$  mit  $f_{X,Y}(x, y) := f_X(x) f_Y(y)$  eine Dichtefunktion zum Zufallsvektor  $(X, Y)$  ist.

## 9. Vorlesung (09.12.2004)

### Satz 6.6 („Multiplikationsregel für Erwartungswerte“)

Für unabhängige ZV X und Y gilt:

$$E(XY) = (EX)(EY) \text{ (Vorausgesetzt, die Erwartungswerte existieren)}$$

Beweis für den stetigen Fall:

$$\begin{aligned} E(XY) &= \iint xy f_{XY}(xy) dx dy \\ &= \iint xy f_X(x) f_Y(y) dx dy \\ &= \int y \left[ \int x f_X(x) dx \right] f_Y(y) dy = (EX)(EY), \text{ da } \left[ \int x f_X(x) dx \right] = EX. \end{aligned}$$

### Definition 6.7

Die Kovarianz  $\text{cov}(X, Y)$  zweier ZV X und Y wird definiert durch

$$\text{cov}(X, Y) = E((X - EX)(Y - EY)).$$

Als Korrelationskoeffizienten  $\rho(X, Y)$  bezeichnet man  $\rho(X, Y) = \frac{\text{cov}(X, Y)}{\sigma(X)\sigma(Y)}$ .

(Wobei natürlich vorausgesetzt wird, dass X und Y eine endliche, von 0 verschiedene Varianz haben.)

Klar:

$$\begin{aligned} \text{cov}(X, Y) &= E(XY - (EX)Y - X(EY) + (EX)(EY)) \\ &= E(XY) - (EX)(EY) - (EX)(EY) + (EX)(EY) \\ &= E(XY) - (EX)(EY) \end{aligned}$$

Insbesondere (Satz 6.6): X und Y unabhängig  $\Rightarrow \text{cov}(X, Y) = 0$ . (X und Y sind unkorreliert)

Die Umkehrung gilt nicht!

cov und  $\rho$  können als Maß einer linearen Abhängigkeit angesehen werden.

### Cauchy-Schwarz-Ungleichung

$$\begin{aligned} |E(X - EX)(Y - EY)| &\leq \sqrt{E(X - EX)^2 E(Y - EY)^2} \\ |\text{cov}(X, Y)| &\leq \sqrt{\text{var}(X) \text{var}(Y)} = \sigma(X)\sigma(Y) \end{aligned}$$

Insbesondere nimmt der Korrelationskoeffizient nur Werte im Intervall  $[-1, 1]$  an.

### Beispiel 6.8

Eine Urne enthält 2 weiße, 3 schwarze und 2 rote Kugeln. 3 Kugeln werden zufällig und ohne Zurücklegen entnommen.  $X$  sei die Anzahl der entnommenen weißen und  $Y$  die der schwarzen Kugeln.

$$P(X = k, Y = l) = \frac{\binom{2}{k} \binom{3}{l} \binom{7-2-3}{3-k-l}}{\binom{7}{3}}, \text{ für } k = 0, 1, 2, l = 0, 1, 2, 3, k + l \in \{0, 1, 2, 3\}$$

Bei diesem „kleinen“ Beispiel die gemeinsame Massenfunktion komplett als Tabelle aufgeschrieben werden:

$y \backslash x$	0	1	2	
0	0	$\frac{2}{35}$	$\frac{2}{35}$	$\frac{4}{35}$
1	$\frac{3}{35}$	$\frac{12}{35}$	$\frac{3}{35}$	$\frac{18}{35}$
2	$\frac{6}{35}$	$\frac{6}{35}$	0	$\frac{12}{35}$
3	$\frac{1}{35}$	0	0	$\frac{1}{35}$
	$\frac{10}{35}$	$\frac{20}{35}$	$\frac{5}{35}$	1

$$P(X = 2) = P(X = 2, Y = 0) + P(X = 2, Y = 1) + P(X = 2, Y = 2) + P(X = 2, Y = 3) = \frac{5}{35}$$

$$\frac{2}{35} + \frac{3}{35} + 0 + 0 = \frac{5}{35}$$

Als Zeilen- bzw. Spaltensummen erhält man die Massenfunktionen zu den einzelnen ZV (der Komponenten des Zufallsvektors).

Darüber hinaus lassen sich mit der gemeinsamen Massenfunktion Wahrscheinlichkeiten für Ereignisse berechnen, die sich auf beide ZV beziehen.

$$P(X = Y) = P(X = 0, Y = 0) + P(X = 1, Y = 1) + P(X = 2, Y = 2)$$

$$= 0 + \frac{12}{35} + 0 = \frac{12}{35}$$

$$P(X = 1, Y = 1) = \frac{12}{35} \neq \frac{20}{35} \cdot \frac{18}{35} = P(X = 1) \cdot P(Y = 1)$$

Die gemeinsame Massenfunktion kann nicht als Produkt der marginalen Massenfunktionen geschrieben werden,  $X$  und  $Y$  sind also nicht unabhängig.

$$E(XY) = \sum_x \sum_y xy P(X=x, Y=y)$$

$$= \frac{1}{35}(1 \cdot 1 \cdot 12 + 2 \cdot 1 \cdot 3 + 1 \cdot 2 \cdot 6) = \frac{30}{35} = \frac{6}{7}$$

$$EX = 0 \cdot \frac{10}{35} + 1 \cdot \frac{20}{35} + 2 \cdot \frac{5}{35} = \frac{6}{7}$$

$$EY = 0 \cdot \frac{4}{35} + 1 \cdot \frac{18}{35} + 2 \cdot \frac{12}{35} + 3 \cdot \frac{1}{35} = \frac{45}{35} = \frac{9}{7}$$

$$\text{also cov}(X, Y) = E(XY) - (EX)(EY) = \frac{6}{7} - \frac{6}{7} \cdot \frac{9}{7} = \frac{-12}{49} \approx -0,245$$

(„schwach“ antilineare Abhängigkeit)

### Beispiel 6.9

Wenn X und Y die gemeinsame Verteilungsfunktion

$$F_{XY}(x, y) = \begin{cases} 1 - e^{-x} - e^{-y} + e^{-x-y} & , x, y \geq 0 \\ 0 & , \text{sonst} \end{cases}$$

haben., so gilt für alle  $x \geq 0$

$$F_X(x) = P(X \leq x) = \lim_{y \rightarrow 0} P(X \leq x, Y \leq y) = 1 - e^{-x}$$

analog für  $F_Y(y) = P(Y \leq y) = 1 - e^{-y}$ .

Insbesondere sind X und Y exponentialverteilt unter Parameter 1. Sind X und Y unabhängig?

Für  $x, y \geq 0$  gilt

$$F_{XY}(x, y) = 1 - e^{-x} - e^{-y} + e^{-x-y} = (1 - e^{-x})(1 - e^{-y}) = F_X(x)F_Y(y)$$

Da die Verteilungsfunktion als Produkt der marginalen Verteilungsfunktionen geschrieben werden kann, ist die Antwort „Ja“.

Gibt es eine gemeinsame Dichte?

$$\frac{\partial^2}{\partial x \partial y} F(x, y) = \frac{\partial}{\partial x} (e^{-y} + e^{-x-y}) = e^{-x-y}$$

$$(\quad = f_X(x)f_Y(y))$$

Beachte: Man kann die marginale Dichtefunktion auch durch Ausintegrieren der anderen Komponenten erhalten:

$$f_X(x) = \int_0^{\infty} f_{XY}(x, y) dy = \int_0^{\infty} e^{-x-y} dy = e^{-x}$$

Damit lassen sich Wahrscheinlichkeiten ausrechnen, die sich auf beide ZV beziehen.

$$\begin{aligned}
P(X \leq 2Y) &= \iint_{\substack{(x,y): x \leq 2y \\ x,y \geq 0}} f_{XY}(x,y) dy dx \\
&= \int_0^{\infty} \int_{x/2}^{\infty} e^{-x-y} dy dx = \frac{2}{3}
\end{aligned}$$

Als Kovarianz erhält man wegen der Unabhängigkeit den Wert 0.  $\left( EXY = \int_0^{\infty} \int_0^{\infty} e^{-x-y} dx dy \dots \right)$

Der Begriff der Kovarianz erlaubt auch eine wichtige Aussage über die Varianz einer Summe von ZV:

$$\begin{aligned}
\text{var}(X+Y) &= E(X+Y)^2 - (E(X+Y))^2 \\
&= E(X^2 + 2XY + Y^2) - (EX + EY)^2 \\
&= E(X^2) - (EX)^2 + E(Y^2) - (EY)^2 + 2(E(XY) - (EX)(EY)) \\
&= \text{var}(X) + \text{var}(Y) + 2\text{cov}(X, Y)
\end{aligned}$$

Insbesondere bei Unabhängigkeit:  $\text{var}(X+Y) = \text{var}(X) + \text{var}(Y)$

#### Satz 6.10 (Gleichheit von Bienaymé)

Sind  $X_1, \dots, X_n$  unabhängige ZV mit endlicher Varianz, so gilt

$$\text{var}(X_1, \dots, X_n) = \text{var}(X_1) + \dots + \text{var}(X_n).$$

In Worten: Bei unabhängigen ZV „addieren sich die Varianzen“

Ganz allgemein hat man:

$$\text{var}\left(\sum_{i=1}^n X_i\right) = \sum_{i=1}^n \text{var}(X_i) + \sum_{\substack{i,j=1 \\ i \neq j}}^n \text{cov}(X_i, X_j)$$

10. Vorlesung (16.12.2004)

Beispiel 6.11

Es sei  $A_1, \dots, A_r$  eine Ereignispartition, also  $A_i \cap A_j = \emptyset$  für  $i \neq j$  (paarweise disjunkt), und  $A_1 \cup \dots \cup A_r = \Omega$  (ein Ereignis muss eintreten). Seien  $p_1, \dots, p_r$  die zugehörigen Wahrscheinlichkeiten, also  $p_1 + \dots + p_r = 1$  (s. Satz 3.3 (II) „Gesetz von der totalen Wahrscheinlichkeit“).

Es sei  $X_k$  die Anzahl der Experimente bei  $n$  Wiederholungen, in denen  $A_k$  eingetreten ist,

dann ist  $X = \begin{pmatrix} X_1 \\ | \\ X_r \end{pmatrix}$  ein  $r$ -dimensionaler, diskreter Zufallsvektor.

Mit den Methoden aus Abschnitt 2 erhält man:

$$P \left( X = \begin{pmatrix} X_1 \\ | \\ X_r \end{pmatrix} \right) = P(X_1 = k_1, X_2 = k_2, \dots, X_r = k_r) \\ = \frac{n!}{k_1! \cdot k_2! \cdot \dots \cdot k_r!} \cdot p_1^{k_1} \cdot p_2^{k_2} \cdot \dots \cdot p_r^{k_r}$$

Multinomialkoeffizient,  
auch:  $\binom{n}{k_1, k_2, \dots, k_r}$

(Es gibt  $\binom{n}{k_1}$  Möglichkeiten, die  $k_1$  Elemente vom Typ  $A_1$  auf die  $n$  Positionen zu verteilen,

sind diese festgelegt, so bleiben  $\binom{n-k_1}{k_2}$  für die vom Typ  $A_2, \dots$

$$\binom{n}{k_1} \binom{n-k_1}{k_2} \binom{n-k_1-k_2}{k_3} \dots \binom{n-k_1-\dots-k_{r-1}}{k_r} = \frac{n!}{k_1! (n-k_1)! k_2! (n-k_1-k_2)! \dots}$$

für alle  $k_1, \dots, k_r \in \mathbb{N}_0$  mit  $k_1 + \dots + k_r = n$ . Man nennt diese Verteilung die

Multinomialverteilung mit Parametern  $n$  und  $p = (p_1, \dots, p_r)$ . Aus Abschnitt 2.1 bekannt: Die Marginalverteilungen sind binomial,  $X_k \sim \text{Bin}(n, p_k)$ .

Zur Notation:  $\binom{n}{k} \xrightarrow{\text{würde notiert als}} \binom{n}{n, n-k}$

Numerisches Beispiel:

Wirft man einen fairen Würfel 10mal, so ist die Wahrscheinlichkeit dafür, dass 1 und 6 je dreimal, die anderen Augenzahlen je einmal auftreten,

$$\frac{10!}{3!1!1!1!1!3!} \left(\frac{1}{6}\right)^3 \cdot \frac{1}{6} \cdot \frac{1}{6} \cdot \frac{1}{6} \cdot \frac{1}{6} \cdot \left(\frac{1}{6}\right)^3 = \frac{175}{104976} \approx 0,00167.$$

### Beispiel 6.12

Ein d-dimensionaler Zufallsvektor  $\mathbf{X} = \begin{pmatrix} X_1 \\ | \\ X_d \end{pmatrix}$  mit Dichte

$f(x_1, \dots, x_d) = (2\pi)^{-\frac{d}{2}} (\det \Sigma)^{-\frac{1}{2}} \exp\left(-\frac{1}{2}(\mathbf{x} - \boldsymbol{\mu})^t \Sigma^{-1} (\mathbf{x} - \boldsymbol{\mu})\right)$  heißt d-dimensional normalverteilt unter Parametern  $\boldsymbol{\mu}$  und  $\Sigma$ . (hierbei  $\boldsymbol{\mu} \in \mathbb{R}^d$  und  $\Sigma \in \mathbb{R}^{d \times d}$  positiv definit)

In Analogie zum eindimensionalen Fall ist  $\boldsymbol{\mu} = \begin{pmatrix} \mu_1 \\ | \\ \mu_d \end{pmatrix}$  der Erwartungswert zu  $\mathbf{X}$  im Sinne von

$E X_k = \mu_k$  für  $k = 1, \dots, d$ .  $\Sigma$  ist die Kovarianzmatrix zu  $\mathbf{X}$ , d.h. in Zeile  $i$ , Spalte  $j$  steht  $(\Sigma)_{ij} = \text{cov}(X_i, X_j)$  (auf der Diagonalen:  $(\Sigma)_{ij} = \text{cov}(X_i, X_i) = \text{var}(X_i)$ )

Ist die gemeinsame Verteilung von  $\mathbf{X}$  und  $\mathbf{Y}$  bekannt, so lässt sich (im Prinzip) die Verteilung von  $\boxed{Z := g(\mathbf{X}, \mathbf{Y})}$ , durch  $g: \mathbb{R}^2 \rightarrow \mathbb{R}$  gegeben, bestimmen.

Besonders wichtig:

$Z = X + Y$ , also  $g: \mathbb{R}^2 \rightarrow \mathbb{R}$ ,  $\mathbf{x} = \begin{pmatrix} x_1 \\ x_2 \end{pmatrix} \rightarrow x_1 + x_2$

### Satz 6.13

(I) Sind  $X, Y$  unabhängige, diskrete ZV mit Massenfunktionen  $p_X, p_Y$ , so ist  $X+Y$  wieder eine diskrete ZV, mit Massenfunktion

$$\begin{aligned} p_{X+Y}(z) &= \sum_x p_X(x) p_Y(z-x) \\ &= \sum_y p_X(z-y) p_Y(y) \end{aligned}$$

(Terminologie: man nennt  $p_{X+Y}$  die Faltung von  $p_X$  und  $p_Y$ )

(II) Sind  $X, Y$  unabhängige, stetige ZV mit Dichtefunktion  $f_X, f_Y$ , so ist auch  $X+Y$  eine stetige ZV und  $f_{X+Y}(z) = \int f_X(x) f_Y(z-x) dx$

$$= \int f_X(z-y) f_Y(y) dy$$

ist eine zugehörige Dichtefunktion. (Terminologie: Man nennt  $f_{X+Y}$  die Faltung von  $f_X$  und  $f_Y$ )

### Zum Beweis im diskreten Fall:

Zerlegung nach dem Wert von  $\mathbf{X}$  liefert

$$\begin{aligned} P(X+Y=z) &= \sum_x P(X+Y=z, X=x) \\ &= \sum_x P(Y=z-x, X=x) \\ \text{(Unabhängigkeit!)} &= \sum_x P(Y=z-x) P(X=x) \\ &= \sum_x p_Y(z-x) p_X(x) \end{aligned}$$



### Beispiel 6.14

(I) Es seien  $X, Y$  Poisson-verteilt mit Parametern  $\lambda_X$  und  $\lambda_Y$ .

Welche Verteilung hat  $X+Y$ ?

Für alle  $n \in \mathbb{N}_0$  gilt:

$$\begin{aligned} p_{X+Y}(n) &= \sum_{k \in \mathbb{Z}} p_X(k) p_Y(n-k) = \sum_{k=0}^n p_X(k) p_Y(n-k) \\ &= \sum_{k=0}^n e^{-\lambda_X} \frac{(\lambda_X)^k}{k!} e^{-\lambda_Y} \frac{(\lambda_Y)^{n-k}}{(n-k)!} \\ &= e^{-\lambda_X - \lambda_Y} \frac{1}{n!} \sum_{k=0}^n \binom{n}{k} (\lambda_X)^k (\lambda_Y)^{n-k} \\ &= e^{-\lambda_X - \lambda_Y} \frac{(\lambda_X + \lambda_Y)^n}{n!} \quad (\text{binom. Lehrsatz}) \end{aligned}$$

Hieraus folgt  $X+Y$  ist Poisson-verteilt mit Parameter  $\lambda = \lambda_X + \lambda_Y$ .

(II) Sind  $X$  und  $Y$  unabhängig und  $N(0,1)$ -verteilt, so gilt:

$$\begin{aligned} f_{X+Y}(z) &= \int f_X(x) f_Y(z-x) dx \\ &= \frac{1}{2\pi} \int e^{-\frac{x^2}{2}} e^{-\frac{(z-x)^2}{2}} dx \\ &= \frac{1}{2\pi} \int \exp\left(-\frac{1}{2}(2x^2 + z^2 - 2zx)\right) dx \\ \text{Subst: } y &= \left(x - \frac{1}{2}z\right) \cdot \sqrt{2} &&= \frac{1}{2\pi} \exp\left(-\frac{z^2}{4}\right) \int \exp\left(-\left(x - \frac{1}{2}z\right)^2\right) dx \\ &&&= \frac{1}{\sqrt{2\pi} \cdot 2} \exp\left(-\frac{1}{2 \cdot 2} z^2\right) \frac{1}{\sqrt{2\pi}} \int e^{-\frac{y^2}{2}} dy \end{aligned}$$

$\frac{1}{\sqrt{2\pi}} \int e^{-\frac{y^2}{2}} dy$  ist Integral zur Dichtefunktion von  $N(0,1)$ .

Der Vorfaktor ist von der Form  $\frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{1}{2\sigma^2}(z-\mu)^2}$  mit  $\mu = 0, \sigma^2 = 2$ .

Also:  $X + Y \sim N(0, 2)$

Allgemein:  $X \sim N(\mu_X, \sigma_X^2), Y \sim N(\mu_Y, \sigma_Y^2)$  unabhängig

$$\Rightarrow X + Y \sim N(\mu_X + \mu_Y, \sigma_X^2 + \sigma_Y^2)$$

(kann beispielsweise mit Lemma 5.2 bewiesen werden)

Verteilungsfkt. zu Y	zu X
-------------------------	------

Unter bestimmten Bedingungen an die Transformation  $\Psi$  hat mit  $X$  auch  $Y := \Psi(X)$  eine Dichte.

Konkret im 1-dim. Fall: Ist  $\Psi$  streng monoton wachsend und diffbar., so folgt:

$$\begin{aligned} f_Y(y) &= \frac{\partial}{\partial y} P(Y \leq y) = \frac{\partial}{\partial y} P(\Psi(X) \leq y) = \frac{\partial}{\partial y} P(X \leq \Psi^{-1}(y)) = \frac{\partial}{\partial y} F_X(\Psi^{-1}(y)) \\ &= f_X(\Psi^{-1}(y)) (\Psi^{-1})'(y) && \left( f_Y = (\Psi^{-1})' f_X \circ \Psi^{-1} \right) \end{aligned}$$

Satz 6.15 (Transformationssatz für Wahrscheinlichkeitsdichten)

Es seien  $U$  und  $V$  offene Teilmengen von  $\mathbb{R}^d$  und  $\Psi : U \rightarrow V$  eine bijektive, stetig diffbare Abbildung mit  $\det(\Psi'(x)) \neq 0$  f.a.  $x \in U$ .

Ist dann  $X$  eine ZV mit Dichte  $f_X$  und  $P(X \in U) = 1$ , so hat  $Y := \Psi(X)$  die Dichte

$$f_Y(y) = \left| \det(\Psi^{-1})'(y) \right| f_X(\Psi^{-1}(y)), \quad y \in V.$$

Beispiel 6.16 (Transformation auf Polarkoordinaten)

Wir schreiben  $r, \varphi$  anstelle von  $y_1, y_2$ .

$$\Psi^{-1} \begin{pmatrix} r \\ \varphi \end{pmatrix} = \begin{pmatrix} r \cos \varphi \\ r \sin \varphi \end{pmatrix} \quad (\Psi^{-1})' \begin{pmatrix} r \\ \varphi \end{pmatrix} = \begin{pmatrix} \cos \varphi & -r \sin \varphi \\ \sin \varphi & r \cos \varphi \end{pmatrix}$$

$$\left| \det(\Psi^{-1})' \begin{pmatrix} r \\ \varphi \end{pmatrix} \right| = r \cos^2(\varphi) - (-r \sin^2(\varphi)) = r$$

Seien  $X_1, X_2$  unabhängig und  $N(0,1)$ -verteilt

$$f_{X_1, X_2}(x_1, x_2) = f_{X_1}(x_1) f_{X_2}(x_2) = \frac{1}{2\pi} \exp\left(-\frac{x_1^2 + x_2^2}{2}\right)$$

Damit ergibt sich als gemeinsame Dichte von  $R$  und  $\Phi$

$$f_{R, \Phi}(r, \varphi) = \frac{1}{2\pi} e^{-\frac{r^2}{2}}, \quad \text{für } 0 < r < \infty, \quad 0 \leq \varphi < 2\pi$$

Ausintegrieren liefert:

$$f_R(r) = e^{-\frac{r^2}{2}} \quad f_\Phi(\varphi) = \frac{1}{2\pi}$$

Insbesondere sind  $R$  und  $\Phi$  unabhängig  $\Phi \sim \text{unif}(0, 2\pi)$ .

## 11. Vorlesung (13.01.2005)

### §7 Erzeugende Funktionen

Es geht um Transformationsmethoden, die in vielen Bereichen der (angewandten) Mathematik von großer Bedeutung sind und außerdem eine starke Verbindung zur Analysis herstellen.

Ist  $X$  eine Zufallsgröße mit Werten in  $\mathbb{N}_0$ , so heißt

$$g_X(s) = \mathbb{E}s^X = \sum_{n=0}^{\infty} P(X=n)s^n \quad (\text{Potenzreihe})$$

die Wahrscheinlichkeitserzeugende Funktion (der Verteilung).

Kennt man  $g_X$ , so lassen sich die Wahrscheinlichkeiten  $P(X=n)$  über die Ableitungen von  $g_X$  in 0 bestimmen.

$$P(X=n) = \frac{1}{n!} \cdot \frac{\delta^n}{\delta s^n} \cdot g_X(s) \Big|_{s=0}$$

Beispiele:

$$g_X(s) = \frac{1}{2}(1+s)$$

Insbesondere gilt: Die Verteilung von  $X$  ist durch  $g_X$  festgelegt.

$$P(X=0) = g_X(0) = \frac{1}{2}$$

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

Aus der Analysis sind Potenzreihen bekannt, insbesondere ist der Konvergenzradius von  $g_X$  mindestens 1.

$$\sum_{n=0}^{\infty} 1 \cdot s^n = \frac{1}{1-s} \quad (\text{geom. Reihe})$$

Außerdem gilt, wenn der Erwartungswert zu  $X$  existiert,

$$\mathbb{E}X = \sum_{n=0}^{\infty} n \cdot P(X=n) = \frac{d}{ds} \left( \sum_{n=0}^{\infty} P(X=n)s^n \right) \Big|_{s=1} = g_X'(1)$$

Analog:

$$\mathbb{E}(X(X-1)) = g_X''(1), \text{ insbesondere}$$

$$\begin{aligned} \text{var}(X) &= \mathbb{E}(X^2) - (\mathbb{E}X)^2 = \mathbb{E}(X(X-1)) + \mathbb{E}X - (\mathbb{E}X)^2 \\ &= g_X''(1) + g_X'(1) - (g_X'(1))^2 \end{aligned}$$

Sind  $X$  und  $Y$  unabhängige,  $\mathbb{N}_0$ -wertige Zufallsgrößen, so gilt

$$\begin{aligned} g_{X+Y}(s) &= \mathbb{E}s^{X+Y} = \mathbb{E}(s^X \cdot s^Y) \quad (\text{als Fkt. von unabh. ZV wieder unabhängig}) \\ (\text{Multiplikationsregel}) &= (\mathbb{E}s^X) \cdot (\mathbb{E}s^Y) = g_X(s) \cdot g_Y(s) \end{aligned}$$

Die Wahrscheinlichkeitserzeugende Funktion zur Summe von unabhängigen ZV ist das Produkt der einzelnen Wahrscheinlichkeitserzeugenden Funktionen.

### Beispiel 7.1

Ist  $X$  Poisson-verteilt mit Parameter  $\lambda$ , so erhält man

$$\begin{aligned} g_X(s) &= \sum_{n=0}^{\infty} P(X=n) s^n \\ &= \sum_{n=0}^{\infty} \left( e^{-\lambda} \frac{\lambda^n}{n!} \right) s^n \\ &= e^{-\lambda} \left( \sum_{n=0}^{\infty} \frac{(\lambda s)^n}{n!} \right) = e^{-\lambda} \cdot e^{\lambda s} = e^{\lambda(s-1)} \end{aligned}$$

$$= 1$$

Exponential-Reihe

$$g'_X(s) = \lambda \left( e^{\lambda(s-1)} \right)$$

$$g'_X(1) = \lambda \quad EX = \lambda$$

$$\text{var}(X) = \lambda^2 + \lambda - \lambda^2 = \lambda$$

Sind  $X$  und  $Y$  unabhängig und Poisson-verteilt mit Parametern  $\lambda_X$  und  $\lambda_Y$ , so gilt

$$g_{X+Y}(s) = g_X(s) \cdot g_Y(s) = e^{\lambda_X(s-1)} e^{\lambda_Y(s-1)} = e^{(\lambda_X + \lambda_Y)(s-1)}$$

Dies ist die Wahrscheinlichkeitserzeugende Funktion zur Poisson-Verteilung mit Parameter  $\lambda_X + \lambda_Y$ .

Insgesamt haben wir also bewiesen:

Sind  $X$  und  $Y$  unabhängig und Poisson-verteilt, so ist auch die Summe Poisson-verteilt (siehe Beispiel 6.14).

### Beispiel 7.2

Wir betrachten die Wiederholungen eines Zufallsexperimentes in dem ein bestimmtes Ereignis mit der Wahrscheinlichkeit  $p$  eintritt. Für jedes  $n$  sei  $X_n = 1$ , wenn dieses Ereignis in der  $n$ -ten Wiederholung eintritt, und 0 sonst. Auf diese Weise erhält man eine Folge  $(X_n)_{n \in \mathbb{N}}$  von unabhängigen ZV mit  $P(X=1) = p$ ,  $P(X_n=0) = 1-p$ .

**Problem:** Wie lange dauert es, bis erstmals hintereinander eintritt?  
(Allgemeiner: Muster in zufälliger Zeichenkette)

$$T := \inf \{ n \geq 2 : X_{n-1} = X_n = 1 \}$$

Offensichtlich gilt  $P(T=0) = P(T=1) = 0$ .

Für  $n \geq 3$  gilt  $P(T=n) = P(X_1=0, T=n) + P(X_1=1, X_2=0, T=n)$ ,

sowie  $P(T=2) = P(X_1=1, X_2=1) = p^2$ .

Hilfsgröße:  $T_i := \inf \{ n \geq 2 : X_{n-1+i} = X_{n+i} = 1 \}$ ,  $i = 1, 2, \dots$

Offensichtlich hängt  $T_i$  nur von  $X_{i+1}, X_{i+2}, \dots$  ab, ist also unabhängig von  $X_1, \dots, X_i$ .  
 Außerdem ist diese Abhängigkeit dieselbe, wie die von  $T$  bezogen auf  $X_1, X_2, \dots$  d.h.

$$\boxed{P(T_1 = n) = P(T_2 = n) = P(T = n)}$$

Damit

$$\boxed{P(T = n) = P(X_1 = 0, T_1 = n-1) + P(X_1 = 1, X_2 = 0, T_2 = n-2)}$$

$$\begin{aligned} &P(X_1 = 0)P(T_1 = n-1) \text{ für } n \geq 3 \\ &= P(X_1 = 0)P(T = n-1) \\ &= (1-p)P(T = n-1) \end{aligned}$$

Übergang zur Wahrscheinlichkeitserzeugenden Funktion:

$$\begin{aligned} g_T(s) &= \cancel{P(T=0)}s^0 + \cancel{P(T=1)}s^1 + P(T=2)s^2 + \sum_{n=3}^{\infty} P(T=n)s^n \\ &= p^2s^2 + \sum_{n=3}^{\infty} ((1-p)P(T=n-1) + p(1-p)P(T=n-2))s^n \\ &= p^2s^2 + (1-p) \sum_{n=2}^{\infty} P(T=n-1)s^{n+1} + p(1-p) \sum_{n=1}^{\infty} P(T=n-2)s^{n+2} \\ &= p^2s^2 + (1-p)s \sum_{n=2}^{\infty} P(T=n)s^n + p(1-p)s^2 \sum_{n=1}^{\infty} P(T=n-2)s^n \\ &= p^2s^2 + (1-p)s \cdot g_T(s) + p(1-p)s^2 \cdot g_T(s) \end{aligned}$$

Damit

$$g_T(s) = \frac{p^2s^2}{1 - (1-p)s(1+ps)}$$

Dies liefert beispielsweise

$$ET = g_T'(1) = \frac{1+p}{p^2}$$

Weitergehende Resultate: Sind  $1/a$  und  $1/b$  die Nullstellen des Nenners von  $g_T$  (bei  $0 < p < 1$  sind diese verschieden), so liefert eine Partialbruchzerlegung (geht auch mit einem Computeralgebra-Programm):

$$\begin{aligned} g_T(s) &= p^2s^2 \frac{1}{(1-as)(1-bs)} \\ &= \frac{p^2s^2}{a-b} \left( \frac{a}{(1-as)} - \frac{b}{(1-bs)} \right) \\ &= \sum_{n=0}^{\infty} \frac{p^2}{a-b} (a^{n+1} - b^{n+1}) s^{n+2} \end{aligned}$$

Wartet man beispielsweise beim Würfelwurf, bis erstmals zweimal hintereinander eine 6 erscheint, so erhält man mit  $p = \frac{1}{6}$  für die Nennerfunktion  $1 - \frac{5}{6}s \left(1 + \frac{1}{6}s\right) = -\frac{5}{36}s^2 - \frac{5}{6}s + 1$

die Nullstellen  $\frac{1}{a}$  und  $\frac{1}{b}$  mit  $a = -3 + \frac{9}{5}\sqrt{5}$  und  $b = -3 - \frac{9}{5}\sqrt{5}$ .

$$\text{Also } P(T = n) = \frac{1(a^{n-1} - b^{n-1})}{36(a - b)} \quad ET = 42$$

Was passiert, wenn die interessierenden Zufallsgrößen nicht Werte ausschließlich in  $\mathbb{N}_0$  annehmen?

Betrachte die sog. momenterzeugende Funktion

$$\varphi_X(t) = Ee^{tX} = \int e^{tx} f(x) dx, \text{ wenn } X \text{ eine Dichtefunktion hat.}$$

(allgemeiner anwendbar, aber keine Potenzwerte mehr)

12. Vorlesung (20.01.2005)

Im Falle  $P(X \in \mathbb{N}_0) = 1: g_X(s) = Es^X$

Allgemeiner: Die momenterzeugende Funktion  $\varphi - \varphi_X$ :

$$\varphi_X(t) = Ee^{tX} = \begin{cases} \sum_x e^{tx} P(X=x) & \text{, im direkten Fall} \\ \int e^{tx} f_X(x) dx & \text{, wenn X Dichte von } f_{X \text{ hat}} \end{cases}$$

ACHTUNG: Muss nicht unbedingt außerhalb von  $t=0$  existieren.

$\varphi_X(0) = 1$  ,  $f_X(t) = \infty \quad \forall t \neq 0$  ist möglich

Existiert  $f_X(t)$  in einer Nullumgebung, so lassen sich Erwartungswert und Ableitung (nach t) vertauschen.

$$\varphi'_X(t) = \frac{d}{dt}(Ee^{tX}) = E\left(\frac{d}{dt}e^{tX}\right) = E(Xe^{tX})$$

$$\varphi'_X(0) = EX \quad \varphi''_X(t) = E(X^2 e^{tX})$$

$$\varphi_X^{(k)}(t) = E(X^k e^{tX}) \text{ , also } \varphi_X^{(k)}(0) = EX^k$$

Das k-te Moment ergibt sich als der Wert der k-ten Ableitung von  $f_X$  in 0 – daher „momenterzeugende Funktion“.

Zusammenhang zu wahrscheinlichkeitserzeugender Funktion (bei  $P(X \in \mathbb{N}_0) = 1$ ):

$$g_X(s) = Es^X = E \exp((\log s) X) = \varphi_X(\log s)$$

Bei  $X \sim \text{Poisson}(\lambda)$  ist aus Beispiel 7.1  $g_X(s) = e^{\lambda(s-1)}$  bekannt, also

$$\varphi_X(t) g_X(e^t) = \exp(\lambda(e^t - 1)).$$

Beispiel 7.3

a) Ist X exponentialverteilt mit Parameter  $\lambda$  , so erhält man


$$\varphi_X(t) = \int_0^\infty e^{tx} \lambda e^{-\lambda x} dx = \frac{\lambda}{\lambda - t} \quad \text{für } \lambda < t$$

(Insbesondere: Der Definitionsbereich von  $\varphi_X$  ist  $(-\infty, \lambda)$  , also nicht ganz  $\mathbb{R}$  , enthält aber ein Nullumgebung.

b) Ist X standartnormalverteilt, so erhält man

$$\varphi_X(t) = \int e^{tx} \frac{1}{\sqrt{2\pi}} e^{-x^2/2} dx = e^{t^2/2} \left( \int \left( \frac{1}{\sqrt{2\pi}} e^{-\frac{(x-t)^2}{2}} \right) dx \right) = e^{t^2/2} \text{ , } t \in \mathbb{R}$$

(Der Definitionsbereich ist her ganz  $\mathbb{R}$  ).



Zusammenspiel mit affinen Transformationen : Zu  $Y = aX + b$  gehört

$$\varphi_Y(t) = Ee^{tY} = Ee^{t(aX+b)} = E\left(e^{(ta)X} e^{tb}\right) = e^{tb} \varphi_X(at)$$

Ist beispielsweise  $X$  normalverteilt mit Parametern  $\mu$  und  $\sigma^2$  so ist  $Y := \frac{X-\mu}{\sigma}$

standardnormalverteilt (Beispiel 6.14 (ii)) also folgt mit Beispiel 7.3 (b)

$$\varphi_X(t) = e^{it} \varphi_Y(\sigma t) = \exp\left(it\mu + \frac{1}{2}\sigma^2 t^2\right) \quad (\text{mit } X = \mu + \sigma Y).$$

Ganz analog wie bei wahrscheinlichkeitserzeugenden Funktionen erhält man für unabhängige ZV  $X$  und  $Y$

$$\varphi_{X+Y}(t) = Ee^{t(X+Y)} = E\left(e^{tX} e^{tY}\right) = \left(Ee^{tX}\right)\left(Ee^{tY}\right) = \varphi_X(t)\varphi_Y(t)$$

Sind beispielsweise  $X$  und  $Y$  unabhängig mit  $X \sim N(\mu_X, \sigma_X^2)$ ,  $Y \sim N(\mu_Y, \sigma_Y^2)$ , so folgt:

$$\begin{aligned} \varphi_{X+Y}(t) &= \varphi_X(t)\varphi_Y(t) = \exp\left(\mu_X t + \frac{1}{2}\sigma_X^2 t^2\right) \cdot \exp\left(\mu_Y t + \frac{1}{2}\sigma_Y^2 t^2\right) \\ &= \exp\left((\mu_X + \mu_Y)t + \frac{1}{2}(\sigma_X^2 + \sigma_Y^2)t^2\right) \end{aligned}$$

Dies ist die momenterzeugende Funktion zu  $N(\mu_X + \mu_Y, \sigma_X^2 + \sigma_Y^2)$ . Man sieht: Die Summe von unabhängigen, normalverteilten Zufallsgrößen ist wieder normalverteilt.

(geht auch über Faltungsformeln, aber mühsam)

Diese Aussage lässt sich auf mehr als 2 Summanden verallgemeinern:

Sind  $X_1, \dots, X_n$  unabhängig, so gilt:

$$\varphi_{X_1+\dots+X_n}(t) = \varphi_{X_1}(t) + \dots + \varphi_{X_n}(t).$$

Dies kann sogar auf zufällige Summandenzahl verallgemeinert werden: Sind beispielsweise  $X_1, X_2, \dots$  unabhängig und identisch verteilt mit momenterzeugender Funktion  $\varphi_X$  und weiter  $N$  eine  $\mathbb{N}_0$ -wertige Zufallsgröße mit wahrscheinlichkeitserzeugender Funktion  $g_N$ ,  $N$

unabhängig von den  $X$ -Variablen, so gilt für die zufällige Summe  $Y := \sum_{n=0}^{\infty} X_n$ .

(Eine „leere Summe“ hat den Wert 0)

$$\begin{aligned} \varphi_Y(t) &= E \exp(tY) = \sum_{n=0}^{\infty} E\left(\exp(tY) 1_{\{N=n\}}\right) \\ &\quad \text{Zerlegung nach dem Wert von } N \\ &= \sum_{n=0}^{\infty} E\left(\left(\sum_{k=1}^n X_k\right) 1_{\{N=n\}}\right) \\ &= \sum_{n=0}^{\infty} E\left(\exp\left(\sum_{k=1}^n X_k\right)\right) \cdot E\left(1_{\{N=n\}}\right) \\ &= \sum_{n=0}^{\infty} \varphi_X(t)^n P(N=n) = g_N(\varphi_X(t)) \end{aligned}$$



## Beispiel 7.4

Ist  $N$  Poisson-verteilt mit Parameter  $\lambda$  und sind  $X_1, X_2, \dots$  unabhängig (auch von  $N$ ) mit  $P(X_i = 1) = p = 1 - P(X_i = 0)$  f.a.  $i \in \mathbb{N}$ , so gilt wegen

$$\varphi_X(t) = Ee^{tX_i} = e^{t \cdot 1} p + e^{t \cdot 0} (1 - p) = 1 - p + pe^t \text{ für die zufällige Summe } Y = \sum_{k=1}^N X_k :$$

$$\begin{aligned} \varphi_Y(t) &= g_N(\varphi_X(t)) && (g_N(x) = e^{\lambda(x-1)}) \\ &= \exp(\lambda(\varphi_X(t) - 1)) \\ &= \exp(\lambda(1 - p + pe^t - 1)) \\ &= \exp(\lambda p(e^t - 1)). \end{aligned}$$

Dies ist die momenterzeugende Funktion zur Poisson-Verteilung mit Parameter  $\lambda p$ . Man kann dies als Ausdünnungseigenschaft der Poisson-Verteilung ansehen.

## §8 Grenzwertsätze

### 8.1 Ein Gesetz der großen Zahlen

Es sei  $X$  eine ZV mit Erwartungswert  $\mu$  und Varianz  $\sigma^2$  ( $< \infty$ ). Wir definieren  $Y$  durch

$$Y := \begin{cases} \varepsilon, & |X - \mu| \geq \varepsilon \\ 0, & \text{sonst} \end{cases}$$

Klar:  $Y^2 \leq (X - \mu)^2$

Hieraus folgt mit Satz 4.10 bzw. Satz 5.6

$$EY^2 \leq E(X - \mu)^2 = \text{var}(X) = \sigma^2.$$

Da  $Y$  nun zwei Werte annehmen kann, erhält man

$$EY^2 = \varepsilon^2 P(Y = \varepsilon) + 0^2 P(Y = 0) = \varepsilon^2 P(|X - \mu| \geq \varepsilon).$$

### Satz 8.1 (Die Ungleichung von Chebyshev)

$$P(|X - EX| \geq \varepsilon) \leq \frac{1}{\varepsilon^2} \text{var}(X) \text{ f.a. } \varepsilon > 0$$

Spezialfall: Mit  $\varepsilon = 3\sigma$  erhält man die sog. Drei-Sigma-Regel:

Die Wahrscheinlichkeit dafür, dass der Wert einer ZV mehr als 3 Standardabweichungen vom Mittelwert entfernt ist, ist höchstens  $\frac{1}{9}$ . („10% bei Anwendern“)

Wir betrachten die folgende Situation:

Ein Zufallsexperiment wird  $n$ -mal unabhängig und ohne Veränderung der Nebenbedingungen wiederholt. Wir beobachten die ZV  $X_1, \dots, X_n$  ( $X_i$  in der  $i$ -ten Wiederholung).

Der folgende Satz zeigt, dass unter schwachen Bedingungen der Mittelwert  $\bar{X}_n := \frac{1}{n} \sum_{k=1}^n X_k$

der Beobachtungen mit  $n \rightarrow \infty$  in einem bestimmten Sinne (Konvergenz in Wahrscheinlichkeit) gegen den Erwartungswert (eine Konstante!) konvergiert.

### Satz 8.2 (Das schwache Gesetz der großen Zahlen)

Es sei  $X_1, X_2, \dots$  eine Folge von unabhängigen und identisch verteilten ZV mit Erwartungswert  $\mu$  und Varianz  $\sigma^2 < \infty$ . Dann gilt

$$\lim_{n \rightarrow \infty} P\left(\left|\bar{X}_n - \mu\right| \geq \varepsilon\right) = 0 \quad \text{f.a. } \varepsilon > 0$$

Der Beweis ist einfach: Es gilt

$$E\bar{X}_n = \frac{1}{n}(EX_1 + EX_2 + \dots + EX_n) = \mu$$

$$\begin{aligned} \text{var}(\bar{X}_n) &= \text{var}\left(\frac{1}{n} \sum_{i=1}^n X_i\right) = \frac{1}{n^2} \text{var}(X_1 + \dots + X_n) \\ &= \frac{1}{n^2} (\text{var}(X_1) + \dots + \text{var}(X_n)) \quad (\text{Bienaymé}) \\ &= \frac{\sigma^2}{n}. \end{aligned}$$

$$P\left(\left|\bar{X}_n - \mu\right| \geq \varepsilon\right) = P\left(\left|\bar{X}_n - E\bar{X}_n\right| \geq \varepsilon\right) \leq \frac{1}{\varepsilon^2} \text{var}(\bar{X}_n) = \frac{1}{\varepsilon^2} \frac{\sigma^2}{n} \xrightarrow{n \rightarrow \infty} 0.$$

q.e.d.

↑  
Chebyshev

13. Vorlesung (27.01.2005)

Ein besonders wichtiger Spezialfall ergibt sich im Zusammenhang mit relativen Häufigkeiten:  
Ist A ein Ereignis mit Wahrscheinlichkeit p und setzt man

$$X_i = \begin{cases} 1, & \text{A im } i\text{-ten Versuch eingetroffen} \\ 0, & \text{sonst} \end{cases}$$

(wird das Experiment unabhängig wiederholt und verändern sich die Rahmenbedingungen nicht, so können wir die  $X_i$ 's als unabhängig und  $\text{Bin}(1, p)$ -verteilt ansehen)

Klar:  $\mu = EX_i = p$ ,  $\text{var}(X_i) = p(1-p) < \infty$ .

Das schwache Gesetz der großen Zahlen ist also anwendbar.

Interpretation:

Wie oft ist das Ergebnis in n Versuchen eingetreten

$\bar{X}_n = \frac{1}{n} \left( \sum_{i=1}^n X_i \right)$  ist relative Häufigkeit des Eintretens von A in den ersten n Wiederholungen.

$P\left(\left|\bar{X}_n - p\right| > \varepsilon\right) \xrightarrow{n \rightarrow \infty} 0$  für alle  $\varepsilon > 0$  zeigt nur, dass relative Häufigkeiten bei großen n mit großer Wahrscheinlichkeit in der Nähe der zugehörigen Wahrscheinlichkeit liegen. Dies kann als (erste) Rechtfertigung des axiomatischen Aufbaus der Stochastik dienen.

8.2 Normalapproximation: der Zentrale Grenzwertsatz

Nach dem schwachen Gesetz der großen Zahlen liegt  $\bar{X}_n$  bei großen n in der Nähe von  $\mu$ .  
Nach 1000 Würfeln eines fairen Würfels wird man also als mittleres Würfergebnis (Augenzahl) etwa 3,5 ( $EX_n$ ) erhalten, also etwa Augensumme 3500.

Satz 8.3 (Der Zentrale Grenzwertsatz)

Zusätzlich zu den Voraussetzungen in Satz 8.2 sei  $\sigma^2 > 0$ . Dann gilt für alle  $x \in \mathbb{R}$

$$\lim_{n \rightarrow \infty} P\left(\frac{\sqrt{n}}{\sigma}(\bar{X}_n - \mu) \leq x\right) = \Phi(x) \quad \left( = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^x e^{-y^2/2} dy \right)$$

Interpretation:  $\frac{\sqrt{n}}{\sigma}(\bar{X}_n - \mu)$  ist bei großen n näherungsweise  $N(0,1)$ -verteilt.

Mit den Rechenregeln für Normalverteilungen (Lemma 5.2) erhält man die Approximationen

$\bar{X}_n$  ist näherungsweise  $N\left(\mu, \frac{\sigma^2}{n}\right)$ -verteilt.

=  $ES_n$

=  $\text{var}(S_n)$

$S_n := \sum_{i=1}^n X_i$  ist ebenfalls näherungsweise  $N(n\mu, n\sigma^2)$ -verteilt.

Mittelwert und Summe von unabhängigen, identisch verteilten ZV sind näherungsweise Normalverteilt, wobei für  $\mu$  und  $\sigma^2$  (also die Parameter der Normalverteilung) der Erwartungswert und die Varianz des Mittelwertes bzw. der Summe genommen werden.

### Beispiel 8.4

In einem Zufallsexperiment tritt ein bestimmtes Ereignis mit Wahrscheinlichkeit  $p$  ein,  $0 < p < 1$ . Konkret hat man beispielsweise  $p = \frac{1}{2}$  für „Kopf“ beim Wurf einer fairen Münze,  $p = \frac{1}{6}$  beim Würfelwurf für das Ereignis „6 kommt“.

Ist  $S_n$  die Anzahl der Erfolge nach  $n$  Wiederholungen, so gilt bekanntlich  $S_n \sim \text{Bin}(n, p)$  und der Zentrale Grenzwertsatz führt auf die Approximationen  $N(np, np(1-p))$  bzw.  $N(0,1)$  für

die standardisierte Summenvariable  $\frac{S_n - np}{\sqrt{np(1-p)}}$ . Damit lässt sich beispielsweise eine

näherungsweise Antwort auf Fragen von folgendem Typ geben:

Mit welcher Wahrscheinlichkeit erscheint beim 600maligen Wurf eines (fairen) Würfels mindestens 95mal und höchstens 105mal eine „6“?

Sei  $X$  diese Anzahl. Wegen  $X \sim \text{Bin}\left(600, \frac{1}{6}\right)$  gilt

$$P(95 \leq X \leq 105) = \sum_{k=95}^{105} \binom{600}{k} \left(\frac{1}{6}\right)^k \left(1 - \frac{1}{6}\right)^{600-k} = 0,453101\dots$$

Dies ist die exakte Antwort, die man beispielsweise mit einem Computeralgebraprogramm wie Maple leicht erhalten kann.

Mit  $EX = 600 \cdot \frac{1}{6} = 100$  und  $\text{var}(X) = 600 \cdot \frac{1}{6} \left(1 - \frac{1}{6}\right) = \frac{500}{6}$  ergibt die Normalapproximation

$$\begin{aligned} P(95 \leq X \leq 105) &= P(-5 \leq X - EX \leq 5) \\ &= P\left(\frac{-5}{\sqrt{500/6}} \leq \frac{X - EX}{\sqrt{\text{var}(X)}} \leq \frac{5}{\sqrt{500/6}}\right) \\ &\approx \Phi(0,5477) - \Phi(-0,5477) \text{ denn die standardisierte Variable} \\ &\hspace{15em} \text{ist näherungsweise } N(0,1)\text{-verteilt.} \\ &= \Phi(0,5477) - (1 - \Phi(0,5477)) \\ &= 2\Phi(0,5477) - 1 \approx 2 \cdot 0,7088 - 1 \\ &= 0,4176 \end{aligned}$$

Dies kann mit der Stetigkeitskorrektur verbessert werden:

Die Verteilungsfunktion von  $X$  ist auf Intervallen der Länge 1 konstant. Wählt man den jeweiligen Intervallmittelpunkt, so erhält man

$$\begin{aligned} P(95 \leq X \leq 105) &= P(94,5 \leq X \leq 105,5) \\ &= P(-5,5 \leq X - EX \leq 5,5) \\ \dots &\approx 2\Phi(0,65025) - 1 \approx 0,4532 \end{aligned}$$

Ein „richtiger“ Beweis liegt etwas außerhalb unserer Möglichkeiten. Wir begnügen uns mit dem Nachweis der Konvergenz der momenterzeugenden Funktion, setzen also insbesondere voraus, dass  $Ee^{tX_1} < \infty$  für  $|t| \leq \delta$  mit einem  $\delta > 0$  gilt.

Zunächst eine einfache Transformation:  $Y_n := \frac{1}{\sigma} (X_n - \mu)$ .

Dies liefert eine Folge  $(Y_n)_{n \in \mathbb{N}}$  von unabhängigen, identisch verteilten ZV mit Erwartungswert 0 und Varianz 1.

Klar:

$$\sqrt{n} \frac{\overline{X_n} - \mu}{\sigma} = \frac{1}{\sqrt{n}} \sum_{k=1}^n Y_k$$

$$\begin{aligned} \varphi_{\frac{\sqrt{n} \overline{X_n} - \mu}{\sigma}}(t) &= \varphi_{\frac{1}{\sqrt{n}} \sum_{k=1}^n Y_k}(t) \\ &= \varphi_{\sum_{k=1}^n Y_k} \left( \frac{t}{\sqrt{n}} \right) \quad (\text{Rechenregel für momenterzeugende Funktionen}) \\ &= \left( \varphi_{Y_1} \left( \frac{t}{\sqrt{n}} \right) \right)^n \quad (\text{Verhalten von momenterzeugenden Funktionen bei der Summe von unabhängigen ZV}) \\ &= \left( \underbrace{\varphi_{Y_1}(0)}_{=1} + \underbrace{\frac{t}{\sqrt{n}} \varphi'_{Y_1}(0)}_{=EY_1=0} + \underbrace{\frac{1}{2} \frac{t^2}{n} (\varphi''_{Y_1}(0) + t \cdot o(1))}_{=EY_1^2=1} \right)^n \\ &= \left( 1 + \frac{t^2}{2n} (1 + o(1)) \right)^n \xrightarrow{n \rightarrow \infty} e^{t^2/2} \quad (t > 0 \text{ fest}) \end{aligned}$$

Vernachlässigbarer Restterm

Dies ist die momenterzeugende Funktion zu  $N(0,1)$ .

### Beispiel 8.5

Die Lebensdauern  $X_1, \dots, X_{10}$  von 10 Glühlampen seien unabhängig und exponential verteilt mit Erwartungswert 100 (Stunden). Gesucht ist ein Wert  $z$  mit der Eigenschaft, dass die Gesamtbrenndauer  $S = X_1 + \dots + X_{10}$  mit Wahrscheinlichkeit 0,9 den Wert  $z$  übersteigt.

Es gilt  $ES = 1000$ ,  $\text{var}(S) = 10^5$ , also ist  $\frac{S-1000}{\sqrt{10^5}}$  näherungsweise  $N(0,1)$ -verteilt.

Gesucht ist ein Wert  $z$  mit  $P(S \geq z) = 0,9$ .

$$\begin{aligned} P(S \geq z) &= P\left( \frac{S-10^3}{\sqrt{10^5}} \geq \frac{z-10^3}{\sqrt{10^5}} \right) \\ &= 1 - P\left( \frac{S-10^3}{\sqrt{10^5}} \leq \frac{z-10^3}{\sqrt{10^5}} \right) \approx 1 - \Phi\left( \frac{z-10^3}{\sqrt{10^5}} \right) = \Phi\left( \frac{10^3 - z}{\sqrt{10^5}} \right) \end{aligned}$$

Tabelle:  $= \Phi(1,282) \approx 0,9$

Man wird auf  $\frac{10^3 - z}{\sqrt{10^5}} = 0,9$  geführt, dies liefert  $z = 10^3 - 1,282 \cdot \sqrt{10^5} = 594,6$  Stunden.

## 14. Vorlesung (03.02.2005)

### §9 Stochastik und Algorithmen

Wichtig für Anwendungen, aktuell in der Forschung: Algorithmen, die (selbstgemachten) Zufall als Hilfsmittel verwenden.

Klassisches Beispiel: Quicksort.

Gegeben ist ein  $n$ -Tupel  $(a_1, \dots, a_n)$  von (paarweise verschiedenen) reellen Zahlen; diese sollen aufsteigend geordnet werden.

(1) Wähle  $k$  zufällig und gleichverteilt (!) aus  $\{1, \dots, n\}$

(2) Bestimme durch Vergleich von  $a_k$  mit  $a_1, \dots, a_{k-1}, a_{k+1}, \dots, a_n$  die Tupel

$$a^{(L)} = (a_1^{(L)}, \dots, a_j^{(L)}), \quad a^{(R)} = (a_1^{(R)}, \dots, a_{n-j-L}^{(R)})$$

(3) Sortiere  $a^{(L)}$  zu  $b^{(L)}$  und  $a^{(R)}$  zu  $b^{(R)}$

(4) Füge zusammen:

$$(b_1, \dots, b_{n-j-L}) = (b_1^{(L)}, \dots, b_j^{(L)}, a_k, b_1^{(R)}, \dots, b_{n-j-L}^{(R)}).$$

Dies ist ein „Teile und herrsche“-Algorithmus: durch „Splitter“ (auch Pivot)  $a_k$  wird das Ausgangsproblem  $a \rightarrow b$  reduziert auf die beiden (kleineren) Teilprobleme

$$a^{(L)} \rightarrow b^{(L)}, \quad a^{(R)} \rightarrow b^{(R)}.$$

Man spricht von einem „randomisierten“ Algorithmus, weil in (1) ein zufallsabhängiger Schritt eingebaut ist.

Als Konsequenz ist die Laufzeit eine Zufallsgröße (!).

Worst-case-Analyse: Was passiert schlimmstenfalls?

Maßgeblich für die Laufzeit ist die Zahl der Vergleiche. Wird jedes Mal der kleinste Wert gewählt, so ist die (L)-menge jeweils leer, und die (R)-Menge verringert sich nur um ein Element.

$$(n-1) + (n-2) + (n-3) + \dots + 3 + 2 + 1 = \frac{1}{2}n(n-1) \approx n^2$$

Allerdings ist dieses Ereignis extrem unwahrscheinlich.

Average-case-Analyse: Was passiert im Mittel?

#### Satz 9.1

Es sei  $X_n$  die von Quicksort benötigte Anzahl von Vergleichen bei Inputumfang  $n$ . Dann

gilt  $\boxed{EX_n = 2(n+1)H_n - 4n}$ , wobei  $H_n := \sum_{k=1}^n \frac{1}{k}$  die  $n$ -te harmonische Zahl bezeichnet.

Beweis:

Sei  $f(n) = EX_n$ . Der Schritt (3) liefert

$$f(n) = (n-1) + \frac{1}{n} \sum_{k=1}^n (f(k-L) + f(n-k)) = (n-1) + \frac{2}{n} \sum_{k=0}^{n-1} f(k)$$

Klar:  $f(0) = f(1) = 0$

Diese Rekursion können wir auflösen:

$$n f(n) = n(n-1) + 2 \sum_{k=1}^{n-1} f(k)$$

$$(n-1) f(n-1) = (n-1)(n-2) + 2 \sum_{k=1}^{n-2} f(k)$$

also

$$n \cdot f(n) - (n-1) \cdot f(n-1) = 2(n-1) + 2 \cdot f(n-1)$$

$$n \cdot f(n) = (n+1) \cdot f(n-1) + 2(n-1)$$

Für  $g(n) = \frac{1}{n+1} f(n)$  bedeutet dies:

$$\begin{aligned} g(n) &= g(n-1) + \frac{2(n-1)}{n(n+1)} \\ &= g(n-2) + \frac{2(n-1)}{n(n+1)} + \frac{2(n-2)}{(n-1)n} \\ &\dots \end{aligned}$$

$$= 2 \sum_{i=1}^n \frac{i-1}{i(i+1)} = 2 \sum_{i=1}^n \left( \frac{2}{i+1} - \frac{1}{i} \right) = 2H_n - \frac{4n}{n+1}$$

und somit


$$f(n) = (n+1) \cdot g(n) = 2(n+1)H_n - 4n$$

q.e.d.

Wie verhält sich  $EX_n$  mit  $n \rightarrow \infty$ ?

Vergleicht man die Funktion  $x \rightarrow \frac{1}{x}$  mit geeigneten Treppenfunktionen, so erhält man

$$\log n \leq H_n \leq (\log n) + 1 \quad \text{f.a. } n \in \mathbb{N},$$



$$\int_1^n \frac{1}{x} dx \geq H_n - 1$$

$$\frac{1}{1} + \frac{1}{2} + \frac{1}{3} + \dots$$

Insbesondere erhält man:

$$\frac{H_n}{\log n} \xrightarrow{n \rightarrow \infty} 1, \text{ also } \lim_{n \rightarrow \infty} \frac{EX_n}{n \log n} = 2$$

Also: im Mittel braucht man nur etwa  $2n \log n$  Vergleiche. Dies ist viel besser, als  $\frac{1}{2} n^2$ ,

und die Größenordnung selbst ist in der Klasse der Vergleichsbasierten Sortieralgorithmen optimal.