

Vorlesung 1b

Wahrscheinlichkeit von Kollisionen

bei der wiederholten rein zufälligen Wahl

aus endlich vielen möglichen Ausgängen

(Buch S. 1-5)


Teil Eins:

Vom Modell zur Formel

1. Die Fragestellung

– in verschiedenen Verpackungen

n -mal wiederholt wird rein zufällig
ein Pixel aus $g = 10^6$ Pixeln gewählt.



$$i = 1, \dots, n$$

n -mal wiederholt wird rein zufällig
ein Pixel aus $g = 10^6$ Pixeln gewählt.

Wie wahrscheinlich ist es, dass dabei
lauter verschiedene Pixel gewählt werden?

Ziemlich unwahrscheinlich
oder ziemlich hoch wahrscheinlich,
oder so “mittendrin”, für

$$n = 100 \quad ?$$

$$n = 1000 \quad ?$$

$$n = 10000 \quad ?$$

Was schätzen Sie?

Bei der “wiederholten rein zufälligen Pixelwahl”

handelt es sich um ein

Ziehen mit Zurücklegen.

Man kann auch denken an eine Urne
mit g Kugeln, nummeriert mit $1, 2, \dots, g$.

Es wird n -mal gezogen.

Nach jedem Zug wird die gezogene Kugel zurückgelegt,
vor jedem Zug wird “perfekt durchmischt”.

Tema con variazioni:

n Objekte,
 g Plätze.


Jedes Objekt wird auf einen
rein zufällig ausgewählten Platz gesetzt.

(Mehrfachbelegungen sind erlaubt!)

Wie wahrscheinlich ist es, dass dabei
keine Mehrfachbelegung ("Kollision") auftritt?

Objekte

1 ... n



Plätze

1 ... g

Anders als im Buch wird hier die Anzahl der Kennzeichen mit g (und nicht mit r) bezeichnet - wegen des besseren typographischen Unterschieds von g zu n und der Assoziation von g mit **G**esamtzahl der Plätze, **G**eburtstage,...

Populäre Version:

$n = 25$ Personen auf einer Party

Platz \longleftrightarrow Geburtstag ($\in \{1, 2, \dots, 365\}$)

Wie wahrscheinlich ist es,
dass keine zwei Personen am selben Tag Geburtstag haben?

2. Beschreibung durch eine Zufallsvariable und ein Ereignis.

(Buch S. 2-3)

Die Objekte denken wir uns mit 1 bis n
und die Plätze mit 1 bis g nummeriert.

Ein **Ausgang** der Platzwahl (ein **“Wahlprotokoll”**)
lässt sich beschreiben durch das n -tupel

$$a = (a_1, \dots, a_n),$$

wobei a_i den für das i -te Objekt gewählte Platz bezeichnet

$$(1 \leq a_i \leq g).$$

Die Menge der möglichen Wahlprotokolle ist

$$S := \{1, \dots, g\}^n,$$


die Menge aller n -tupel (a_1, \dots, a_n)

mit Einträgen (Komponenten)

$$a_i \in \{1, \dots, g\}, \quad i = 1, \dots, n.$$

Die zufällige Platzwahl

beschreiben wir durch eine S -wertige Zufallsvariable X .



X kommt durch zufällige Wahl
eines Elementes aus S zustande.

Die Menge S heißt *Zielbereich* (oder *Wertebereich*)
der Zufallsvariable X .

Wie jedes Element (a_1, \dots, a_n) unserer Menge S

besteht auch die Zufallsvariable X aus n Komponenten:

$$X = (X_1, \dots, X_n) .$$

Wir interessieren uns für das *Ereignis*,
dass **keine zwei Komponenten von X gleich** sind.

Dieses Ereignis schreiben wir als

$$\{X_i \neq X_j \text{ für alle } i \neq j\}$$

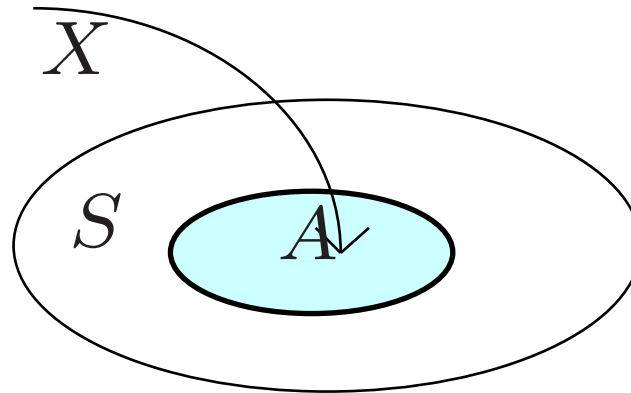
oder auch als

$$\{X \in A\}$$

mit der Teilmenge


$$A := \{a \in S : a_i \neq a_j \text{ für alle } i \neq j\} .$$

Ein Logo für das Ereignis $\{X \in A\}$:



3. Die Wahrscheinlichkeit für Kollisionsfreiheit

(Buch S. 3)



Wie kommt man zur **Wahrscheinlichkeit**
des Ereignisses $\{X \in A\}$?

Zum Merken:

Wahrscheinlichkeiten gehören zu Ereignissen.

Die Wahrscheinlichkeit eines Ereignisses
misst dessen Chance einzutreten
mit einer Zahl zwischen 0 und 1:

$$P(\{X \in A\})$$

Statt $\mathbf{P}(\{X \in A\})$

schreiben wir kurz

$$\mathbf{P}(X \in A)$$

Statt $\mathbf{P}(X \in \{a\})$

schreiben wir kurz

$$\mathbf{P}(X = a)$$

Eine einleuchtende Regel
für das Rechnen mit Wahrscheinlichkeiten ist die
Additivität:

Für disjunkte $A, A' \subset S$ gilt
$$\mathbf{P}(X \in A \cup A') = \mathbf{P}(X \in A) + \mathbf{P}(X \in A').$$

Daraus folgt im Fall endlich vieler möglicher Ausgänge,
d.h. für $\#S < \infty$:

$$\mathbf{P}(X \in A) = \sum_{a \in A} \mathbf{P}(X = a)$$

Um die Wahrscheinlichkeit $\mathbf{P}(X \in A)$ berechnen zu können,

muss man eine **Modellannahme** treffen.

Eine prominente Modellannahme ist die einer
rein zufälligen Wahl.

Damit ist gemeint, dass für je zwei $a, a' \in S$

$$\mathbf{P}(X = a) = \mathbf{P}(X = a').$$

Das heißt: kein Ausgang ist bevorzugt.

Gemäß der Additivität gilt:

$$\mathbf{P}(X \in S) = \sum_{a \in S} \mathbf{P}(X = a).$$

Und wir hatten schon vereinbart: $\mathbf{P}(X \in S) = 1$

Für eine rein zufällige Wahl folgt daraus sofort:

$$P(X = a) = \frac{1}{\#S}, \quad a \in S.$$

Und

$$P(X \in A) = \frac{\#A}{\#S}.$$

Wir haben nun die Aufgabe des Abzählens der zwei Mengen

$$S := \{1, \dots, g\}^n = \{(a_1, \dots, a_n) : 1 \leq a_i \leq g\}$$

und

$$A := \{a \in S : a_i \neq a_j \text{ für alle } i \neq j\}$$

$$\#S = g^n$$

$$S = \{(a_1, \dots, a_n) : 1 \leq a_i \leq g\}$$

$$A := \{a \in S : a_i \neq a_j \text{ für alle } i \neq j\}$$

$$\#A = ?$$

Für a_1 gibt es g mögliche Werte, für a_2 dann noch $g - 1$,
usw. Also:

$$\#A = g(g - 1) \cdots (g - (n - 1))$$


$$\mathbf{P}(X \in A) = \frac{g(g-1) \cdots (g-(n-1))}{g^n}$$

$$= \frac{g-1}{g} \frac{g-2}{g} \cdots \frac{g-(n-1)}{g}$$

$$\mathbf{P}(X \in A) = \prod_{i=1}^{n-1} \left(1 - \frac{i}{g}\right) =: w(n, g)$$

ist die Wahrscheinlichkeit für Kollisionsfreiheit
bei der n -maligen wiederholten rein zufälligen Platzwahl
aus g Plätzen

Wahrscheinlichkeit fuer Kollisionsfreiheit bei $g=365$



4. Der Zeitpunkt der ersten Kollision und seine Verteilung

Ein dynamisches Bild:

Die Anzahl g der Plätze ist fest.

Jetzt wird ein Objekt nach dem anderen ($i = 1, 2, \dots, g + 1$)
auf einen (immer wieder neu)
rein zufällig gewählten Platz gesetzt.

Es sei X_i der von Objekt i gewählte Platz.

Eines ist sicher:

Spätestens bis $i = g + 1$ muss eine Kollision kommen
(warum?)

Das “zufällige Wahlprotokoll”

$(X_1, X_2, \dots, X_{g+1})$

ist somit eine Zufallsvariable mit Wertebereich

$S :=$

$\{(a_1, \dots, a_{g+1}) : a_i \in \{1, \dots, g\}; \exists i \neq j \text{ mit } a_i = a_j\}$

$$T := \min\{n \leq g + 1 : \exists i < n : X_i = X_n\}$$

ist der *Zeitpunkt der ersten Kollision*.

T ist eine aus (X_1, \dots, X_{g+1}) ablesbare Zufallsvariable.

Für das Ereignis

$E_n :=$ “keine Kollision bis (einschließlich) n ” gilt:

$$E_n = \{T > n\}$$

also insbesondere auch

$$\mathbf{P}(E_n) = \mathbf{P}(T > n).$$

$$\mathbf{P}(E_n) = \mathbf{P}(T > n)$$

In Abschnitt 3 hatten wir berechnet:

$$\mathbf{P}(E_n) = \prod_{i=1}^{n-1} \left(1 - \frac{i}{g}\right) =: w(n, g) =: w(n)$$

$$w(n) = \mathbf{P}(T > n)$$

Wie bekommen wir daraus die **Verteilungsgewichte**

$$\mathbf{P}(T = n), n = 1, 2, \dots$$

der \mathbb{N} -wertigen Zufallsvariablen T ?

$$w(n) = \mathbf{P}(T > n)$$

Aus der Additivität der Wahrscheinlichkeit erhalten wir

$$\mathbf{P}(T > n - 1) = \mathbf{P}(T = n) + \mathbf{P}(T > n).$$

Also:

$$\mathbf{P}(T = n) = w(n - 1) - w(n).$$

Die \mathbb{N} -wertige Zufallsvariable T

(den Zeitpunkt der ersten Kollision) haben wir bekommen

als “Verarbeitung” des zufälligen Wahlprotokolls X :

$$T = h(X) \text{ mit passendem } h : S \rightarrow \mathbb{N}.$$

Aus der Gleichheit der Ereignisse

$$\{T = n\} = \{h(X) = n\} = \{X \in h^{-1}(n)\}$$

ergibt sich die Gleichheit

$$\mathbf{P}(T = n) = \mathbf{P}(X \in h^{-1}(n)), \quad n \in \mathbb{N}.$$

Empirische Verteilung von T (1000 Simulationen)

