

# Vorlesung 1b

Wiederholte rein zufällige Wahl (aus endlich vielen  
möglichen Ausgängen)

mit dem Beispiel

“Wahrscheinlichkeit von Kollisionen”

$n = 25$  Individuen,

$r = 365$  Plätze.

Jedes Individuum wird auf einen  
rein zufällig ausgewählten Platz gesetzt.

(Mehrfachbelegungen sind erlaubt!)



Wie wahrscheinlich ist es, dass dabei  
keine Mehrfachbelegung auftritt?

Individuen

1

...

$n$



Plätze

1

...

$r$

Ein anderer Blick:

Jedes von  $n$  Individuen  
ist mit je einem von  $r$  möglichen Kennzeichen versehen,  
das vom Zufall bestimmt ist.

Wie stehen die Chancen,  
dass keine der zwei Individuen gleich gekennzeichnet sind?

(Zitat aus “dem Buch”, Seite 1)

In der Informatik denkt man bei den Individuen an Daten  
und spricht bei den Kennzeichen  
von Hash-Werten oder Fingerabdrücken.

Populäre Version:

$n = 25$  Leute auf einer Party

Kennzeichen ... Geburtstag ( $\in \{1, 2, \dots, 365\}$ )

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

Die Individuen denken wir uns mit 1 bis  $n$   
und die Kennzeichen mit 1 bis  $r$  nummeriert.

Ein **Ausgang** der Kennzeichnung lässt sich beschreiben  
durch das  $n$ -tupel

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

wobei  $a_i$  das Kennzeichen des  $i$ -ten Individuums bezeichnet

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

Die Menge der möglichen Ausgänge der Kennzeichnung ist


$S := \{1, \dots, r\}^n$ , die Menge aller  $n$ -tupel  $(a_1, \dots, a_n)$  mit  
 $a_i \in \{1, \dots, r\}$ .

Manchmal schreiben wir dafür auch

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

die Menge aller Abbildungen von  $\{1, \dots, n\}$  nach  $\{1, \dots, r\}$ .

Den zufälligen Ausgang der Kennzeichnung beschreiben wir durch eine *Zufallsvariable*  $X$ .



$X$  kommt durch zufällige Wahl eines Elementes aus  $S$  zustande.

Die Menge  $S$  heißt *Zielbereich* 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

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



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

Zur Erinnerung:

*Wahrscheinlichkeiten* gehören zu Ereignissen  
und messen deren Chance einzutreten  
mit einer Zahl zwischen 0 und 1:

$$P(X \in A)$$

Zwei einleuchtende Regeln  
für das Rechnen mit Wahrscheinlichkeiten:

$$\mathbf{P}(X \in S) = 1 .$$

d.h. das *sichere Ereignis*  $\{X \in S\}$  hat Wahrscheinlichkeit 1

und (bei endlich vielen möglichen Ausgängen, d.h.  $\#S < \infty$ )

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

(Additivität.)

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

muss man eine **Modellannahme** treffen.

Unsere Modellannahme:

*rein zufällige 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.

Also:

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

Und

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

Wir haben nun die Aufgabe des Abzählens der Mengen

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

und

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

$$\#S = r^n$$

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

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

$$\#A = ?$$

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

Also:

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

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

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

$$\mathbf{P}(X \in A) = \prod_{i=1}^{n-1} \left(1 - \frac{i}{r}\right).$$

$$\mathbf{P}(X \in A) = \frac{r!}{r^n (r-n)!}$$

mit  $k! := 1 \cdot 2 \cdots k$ , lies:  $k$ -Fakultät

Eine Formel aus der Mathe 1 (“AnaLinA”):

$$e^{-h} = 1 - h + o(h) \quad \text{für } h \rightarrow 0.$$

Damit bekommen wir die “AnaLinA - Approximation:”

$$\begin{aligned} \prod_{i=1}^{n-1} \left(1 - \frac{i}{r}\right) &\approx \prod_{i=1}^{n-1} \exp\left(-\frac{i}{r}\right) \\ &= \exp\left(-\sum_{i=1}^{n-1} \frac{i}{r}\right) = \exp\left(-\frac{(n-1)n}{2r}\right). \end{aligned}$$

$$\mathbf{P}(X \in A) \approx \exp\left(-\frac{(n-1)n}{2r}\right).$$

Die Stirling-Formel:

$$k! \approx \sqrt{2\pi k} \left(\frac{k}{e}\right)^k$$



Abraham de Moivre (1667-1754)


$$k! \approx \sqrt{2\pi k} \left(\frac{k}{e}\right)^k$$

$$\begin{aligned} \frac{r!}{r^n (r-n)!} &\approx \sqrt{\frac{r}{r-n}} \left(\frac{r}{r-n}\right)^{r-n} e^{-n} \\ &= \frac{1}{\sqrt{1 - \frac{n}{r}}} \left(1 - \frac{n}{r}\right)^{n-r} e^{-n} \end{aligned}$$

$$\begin{aligned}
\left(1 - \frac{n}{r}\right)^{n-r} e^{-n} &= \exp\left(-n + (n-r) \ln\left(1 - \frac{n}{r}\right)\right) \\
&= \exp\left(-r \left(\frac{n}{r} + \left(1 - \frac{n}{r}\right) \ln\left(1 - \frac{n}{r}\right)\right)\right) \\
&= \exp\left(-r \eta\left(\frac{n}{r}\right)\right)
\end{aligned}$$

mit  $\eta(t) := t + (1-t) \ln(1-t)$ ,  $0 \leq t \leq 1$ .

$$\eta(t) := t + (1 - t) \ln(1 - t), \quad 0 \leq t \leq 1.$$




$$\mathbf{P}(X \in A) \approx \frac{1}{\sqrt{1 - \frac{n}{r}}} \exp\left(-r \eta\left(\frac{n}{r}\right)\right)$$

Für  $n \ll r$ , also  $t := \frac{n}{r} \ll 1$ ,


können wir  $\eta(t)$  quadratisch approximieren:

$$\eta(t) := t + (1 - t) \ln(1 - t), \quad 0 \leq t \leq 1.$$




$$\eta(0) = \eta'(0) = 0, \quad \eta''(0) = 1$$

$$\eta(t) = t + (1 - t) \ln(1 - t), \quad 0 \leq t \leq 1$$
$$\eta(0) = 0, \quad \eta'(0) = 0, \quad \eta''(0) = 1$$



$t^2/2$  ist die quadratische Approximation von  $\eta(t)$  um  $t = 0$ .  
(Taylor-Entwicklung der Ordnung 2.)



$t^2/2$  ist die quadratische Approximation von  $\eta(t)$  um  $t = 0$ .

Für  $n \ll r$  (wie z. B. für  $n = 25$ ,  $r = 365$ ) ist also

$$\eta\left(\frac{n}{r}\right) \approx \left(\frac{n}{r}\right)^2 / 2.$$

Fazit:

Für  $n < r$  ist  $\mathbf{P}(X \in A) \approx \frac{1}{\sqrt{1 - \frac{n}{r}}} \exp\left(-r \eta\left(\frac{n}{r}\right)\right)$

mit  $\eta(t) = t + (1 - t) \ln(1 - t)$ ,  $0 \leq t \leq 1$

(Stirling-Approximation).

Für  $n \ll r$  ist  $\mathbf{P}(X \in A) \approx \exp\left(-\frac{n^2}{2r}\right)$

(Stirling+Taylor-Approximation)

Für  $n^2 \ll r$  ist  $\mathbf{P}(X \in A) \approx 1$ .

Man beachte:

Die Stirling+Taylor Approximation

$$\mathbf{P}(X \in A) \approx \exp\left(-\frac{n^2}{2r}\right)$$

ist fast identisch mit der “AnaLinA-Approximation”

$$\mathbf{P}(X \in A) \approx \exp\left(-\frac{n(n-1)}{2r}\right)$$

Beispiel:  $n = 25, r = 365$ :

$$\mathbf{P}(X \in A) = \frac{r(r-1) \cdots (r-n+1)}{r^n} = 0.431300$$

$$\frac{1}{\sqrt{1 - \frac{n}{r}}} \exp\left(-r \eta\left(\frac{n}{r}\right)\right) = 0.431308$$

$$\exp\left(-\frac{n^2}{2r}\right) = 0.425$$

Von der Statik zur Dynamik:  
Der Zeitpunkt der ersten Kollision.

Wir denken uns  $r$  fest und lassen  $n$  laufen ( $n = 1, 2, \dots$ )

Vorstellung: Ein Individuum nach dem anderen wird auf einen  
(immer wieder neu) rein zufällig gewählten Platz gesetzt.

Die Folge  $(X_1, X_2, \dots)$  der gewählten Plätze ist dann  
eine rein zufällige  $1 \dots r$ -Folge

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

$T :=$  Zeitpunkt der ersten Kollision

(ist ablesbar aus  $(X_1, X_2, \dots)$ ). Es gilt

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

also insbesondere auch

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

Wir haben somit AUCH die Verteilung der Zufallsvariablen  $T$   
(exakt und näherungsweise) berechnet.

Die Ferebee-Wandtner'schen Programme zur VL 1b (siehe Homepage)  
geben dazu erhellende Illustrationen.