

# Diskrete Wahrscheinlichkeitsverteilungen

für D-UWIS, D-ERDW, D-USYS und D-HEST – SS15



# Warum braucht es Wahrscheinlichkeitsverteilungen?



*Essentially,  
all models are wrong,  
but some are useful.*

- George E.P. Box

“Übliche”  
Verteilung für  
eine Aufgabe



Eigenschaften in  
Büchern/Software  
vorhanden



Typische  
Probleme einfach  
lösbar

# Verteilungszoo – Diskrete W'keitsverteilungen



# Lernziele heute

- Diskrete Verteilungen
- Parameterschätzung

## Hausaufgaben

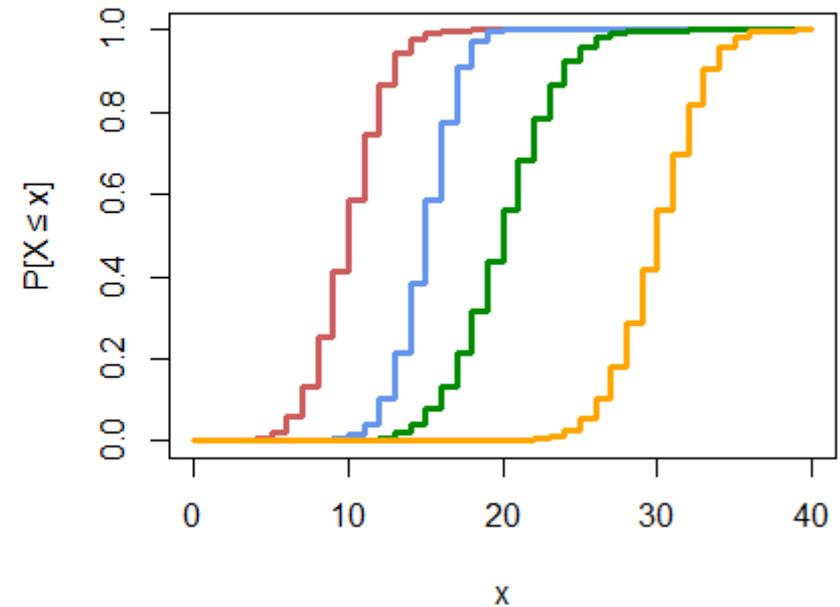
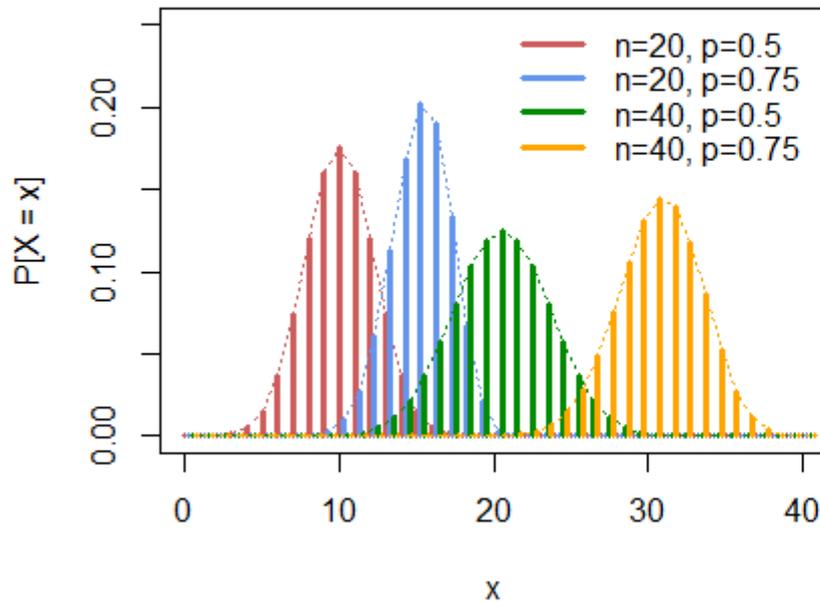
- Skript: Kapitel 3.1 – 3.2.1 lesen
- Serie 4 lösen
- Quiz 4 bearbeiten
- etutoR 3 anschauen



# Binomialverteilung – $Bin(n, \pi)$

- Situation
  - Kaufe  $n$  Lose in einer Tombola
  - Alle Lose haben die gleiche Gewinnwahrscheinlichkeit
  - Lose sind unabhängig voneinander
- Zufallsvariable  $X$ : Anzahl Gewinne unter  $n$  Losen
- $X \sim Bin(n, \pi)$
- Binomialkoeffizient:  $\binom{n}{x} = \frac{n!}{x!(n-x)!}$
- $P[X = x] = \binom{n}{x} \pi^x (1 - \pi)^{n-x}, \quad x \in \{0, 1, 2, \dots, n\}$
- $E(X) = n \cdot \pi, Var(X) = n \cdot \pi \cdot (1 - \pi)$

# Binomialverteilung – $Bin(n, \pi)$

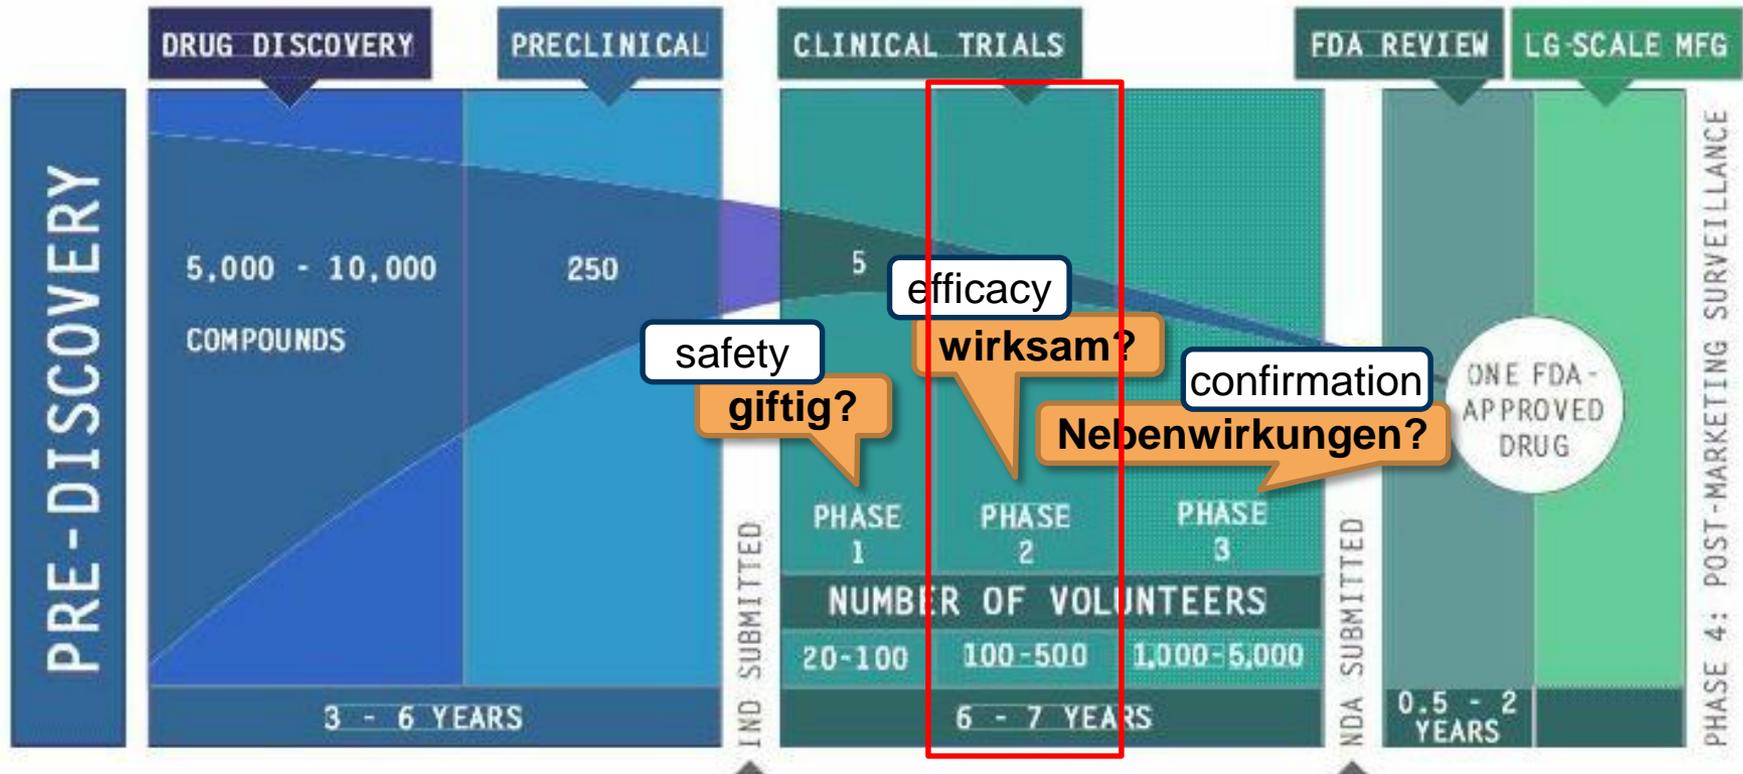


- Beispiel: **LD10**,  $X \sim Bin(20, 0.1)$

$$P[X = 2] = \binom{20}{2} \cdot 0.1^2 \cdot 0.9^{18} \approx 0.285$$

$$E(X) = n \cdot \pi = 20 \cdot 0.1 = 2$$

# Beispiel «Klinische Studie»



- **Lose:** Alle denkbaren Patienten
- **$n$  gezogene Lose:** Patienten in der Studie
- **Gewinn:** Patient wird gesund
- **$\pi$ :** Anteil aller denkbaren Patienten, die gesund werden

## Beispiel «Clinical Trial – Phase 2»

- Hersteller behauptet: Medikament wirkt in 80% der Fällen
- Phase 2 Studie: von 100 Patienten werden nur 73 gesund
  - Ist das, bei einer Heilungsw'keit 80%, plausibel?

- $X$ : Anzahl geheilter Patienten
- Falls Hersteller recht hat:

$$X \sim \text{Bin}(n = 100, \pi = 0.8)$$

- Wie testen wir die Behauptung « $\pi = 0.8$ »?

- Versuch 1:  $P[X = 73] = 0.022$

Überzeugt?

## Exkurs: Größe einer Stichprobe

- $X \sim \text{Bin}(n = 100, \pi = 0.8)$
- Angenommen, wir haben genau  $n \cdot \pi = 80$  Genesungen gesehen; wir sollten dem Hersteller also glauben

	n=100	n=1000	n=10'000	n=100'000
$P(X = n\pi)$	0.10	0.03	0.01	0.003

- $P[X = 73]$  ist **keine gute Kennzahl**, weil die W'keit für jede beliebige Zahl klein wird, wenn man nur genug Beobachtungen hat!

	n=100	n=1000	n=10'000	n=100'000
$P(X \leq n\pi)$	0.54	0.51	0.504	0.501

- $P[X \leq 73]$  ist eine **gute Kennzahl**; sie ist unabhängig von der Stichprobengröße und leichter zu interpretieren.

 **P-Wert** – W'keit für eine Beobachtung oder etwas noch Extremes

## Beispiel «Clinical Trial – Phase 2»

- Hersteller behauptet: Medikament wirkt in 80% der Fällen
- Phase 2 Studie: von 100 Patienten werden nur 73 gesund
  - Ist das, bei einer Heilungsw'keit 80%, plausibel?

- $X$ : Anzahl geheilter Patienten
- Falls Hersteller recht hat:

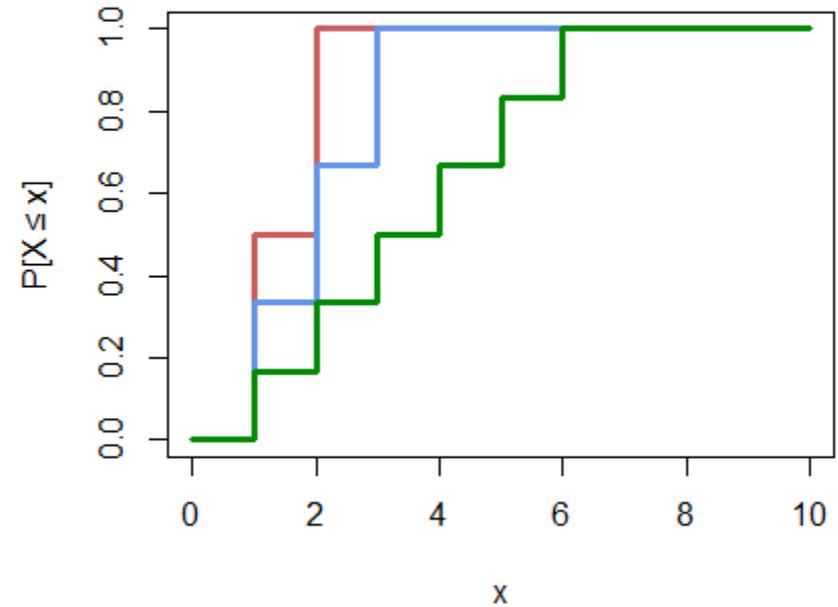
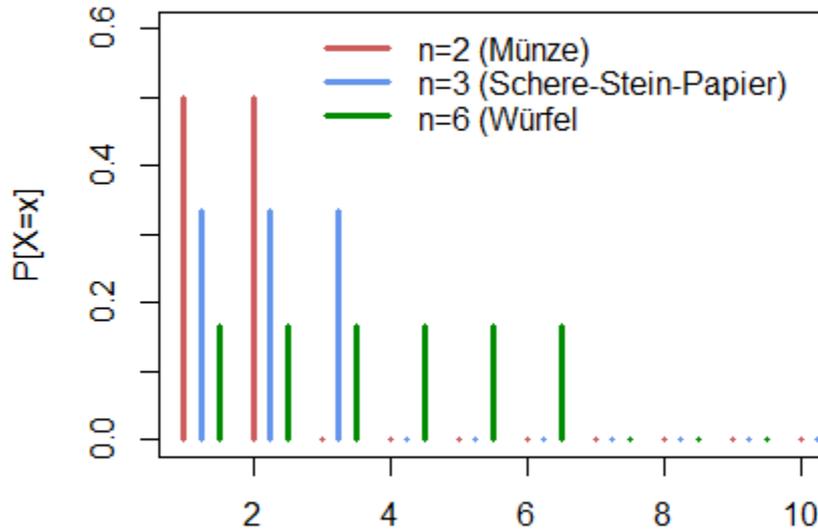
$$X \sim \text{Bin}(n = 100, \pi = 0.8)$$

- Wie testen wir die Behauptung « $\pi = 0.8$ »?
- Versuch 2:  $P[X \leq 73] = 0.056$

# Uniforme Verteilung - $Unif(n)$

- Situation
  - Ziehe eine Zahl aus  $\{1, 2, 3, \dots, n\}$
  - Alle Zahlen haben die gleiche Wahrscheinlichkeit
- Zufallsvariable  $X$ : Gezogene Zahl
- $X \sim Unif(n)$
  
- $P[X = x] = \frac{1}{n}, \quad x \in \{1, 2, \dots, n\}$
- $E(X) = \frac{n+1}{2}, \quad Var(X) = \frac{(n+1)(n+2)}{12}$

# Uniforme Verteilung - $Unif(n)$

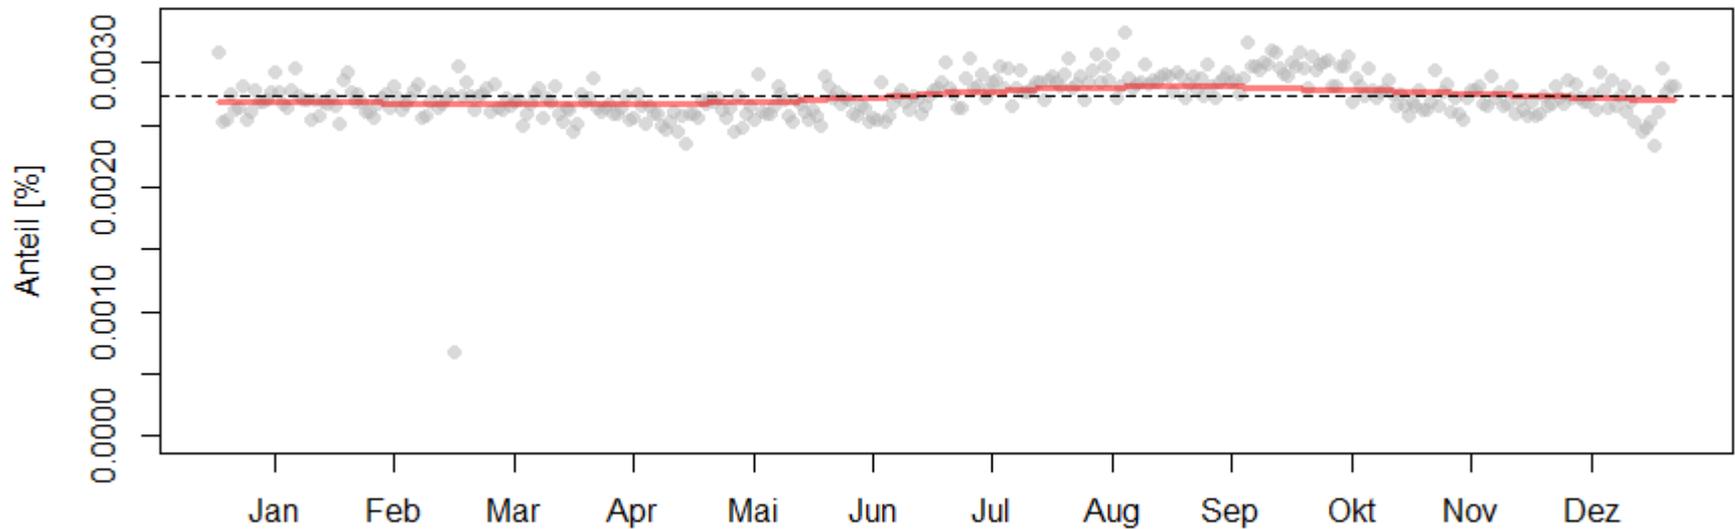


- Beispiel: **Würfel**,  $X \sim Unif(6)$

$$P[X = x] = \frac{1}{6}$$
$$E(X) = \frac{6 + 1}{2} = 3.5$$

# Sind Geburtstage uniform verteilt?

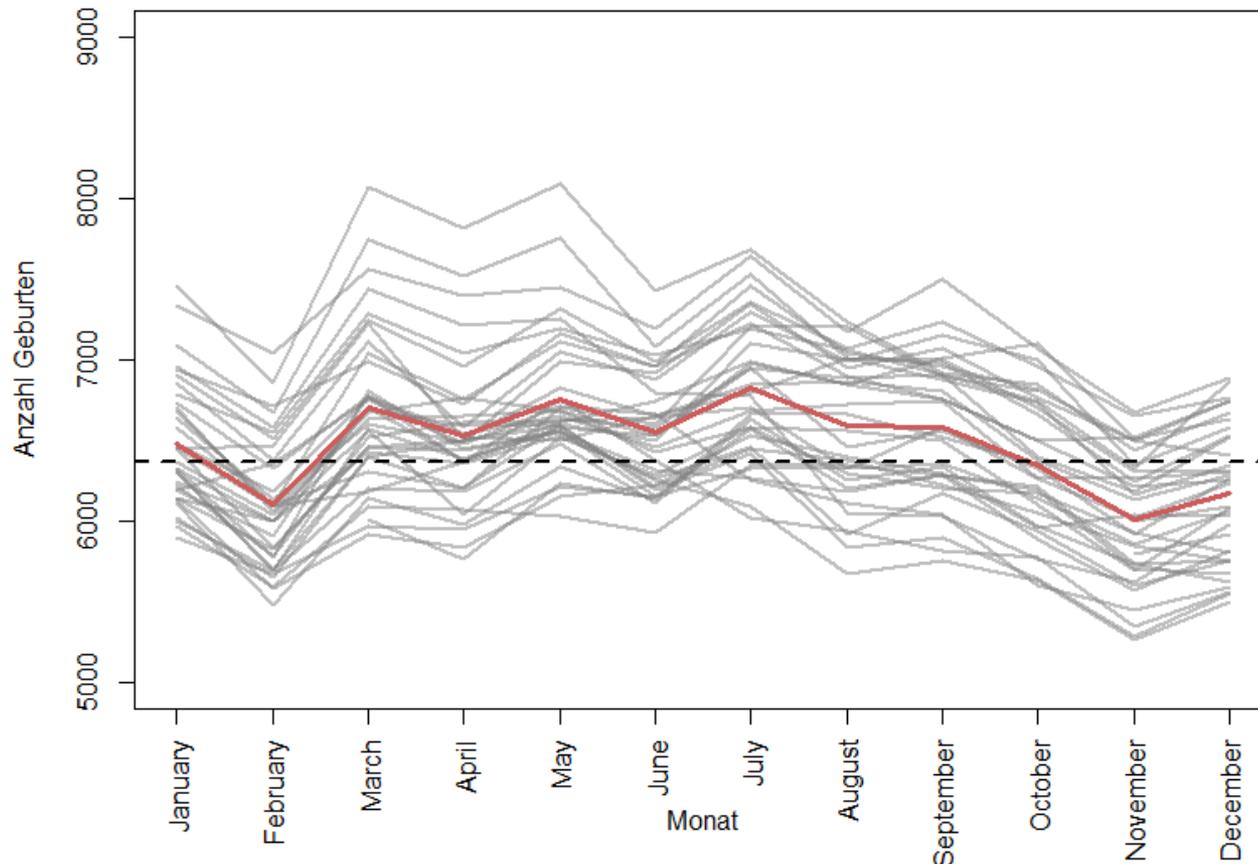
- Geburtstage aus einer Lebensversicherung 1981 – 1994



- In grober Näherung schon!

# Sind Geburtstage uniform verteilt?

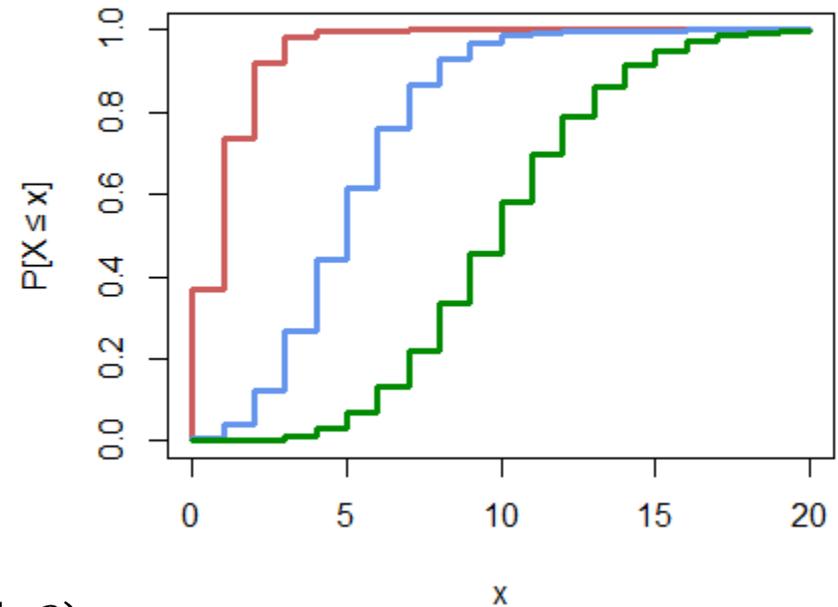
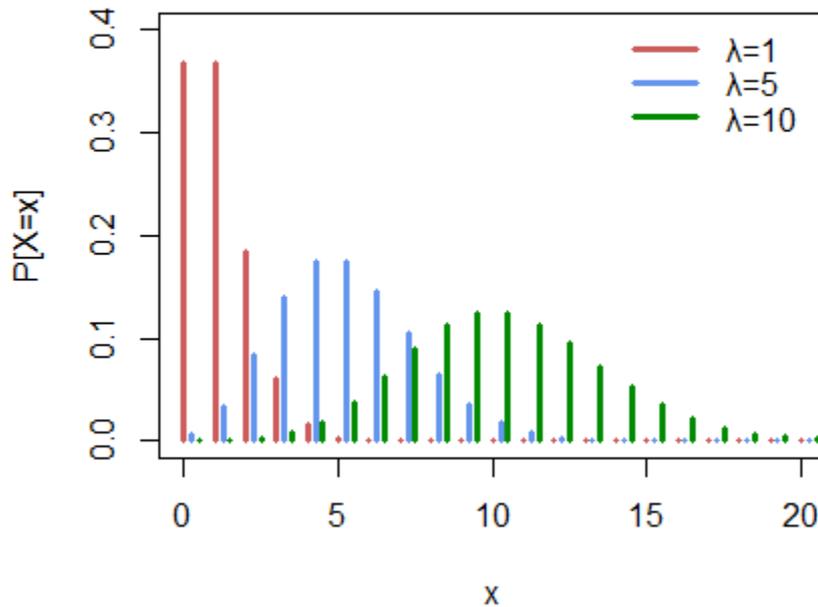
- Was wenn aus dem gleichen Land (Schweiz, 1973-2013)



# Poissonverteilung - *Pois*( $\lambda$ )

- Situation
  - Seltene Ereignisse werden in einem vorgegebenen Zeitraum gezählt
- Zufallsvariable  $X$ : Anzahl beobachteter Ereignisse
- $X \sim \text{Pois}(\lambda)$
  
- $P[X = x] = \frac{\lambda^x}{x!} \exp(-\lambda), \quad x \in \{0, 1, \dots, \infty\}$
- $E(X) = \lambda, \text{Var}(X) = \lambda$

# Poissonverteilung - $Pois(\lambda)$



- Beispiel: **Cäsium-137**,  $X \sim Pois\left(\frac{\ln 2}{27}\right) \approx Pois(0.026)$

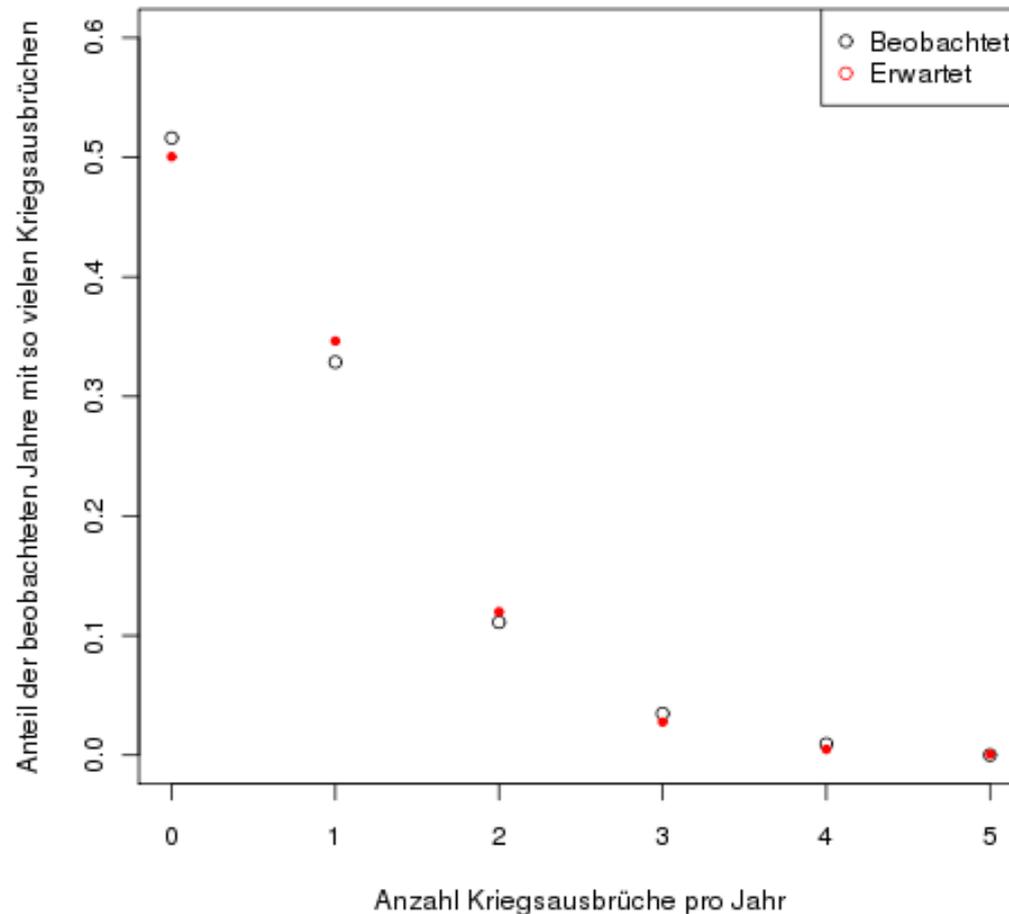
- ...Rate pro Jahr, d.h.  $8.2 \times 10^{-10} \frac{1}{s}$

$$P[X = 1] = \frac{0.026^1}{1!} e^{-0.026} \approx 0.025$$

$$E(X) = \lambda = 0.026$$

- $1\mu g$   $^{137}\text{Cs}$  enthält  $10^{15}$  Nuklei, d.h.  $\mu = N \cdot p = 8.2 \times 10^5$  Zerfälle pro Sekunde

# Beispiel «Anzahl Kriege p.a. poissonverteilt?» (1500 – 1930, weltweit)



# Exkurs: Besonderheit der Poissonverteilung

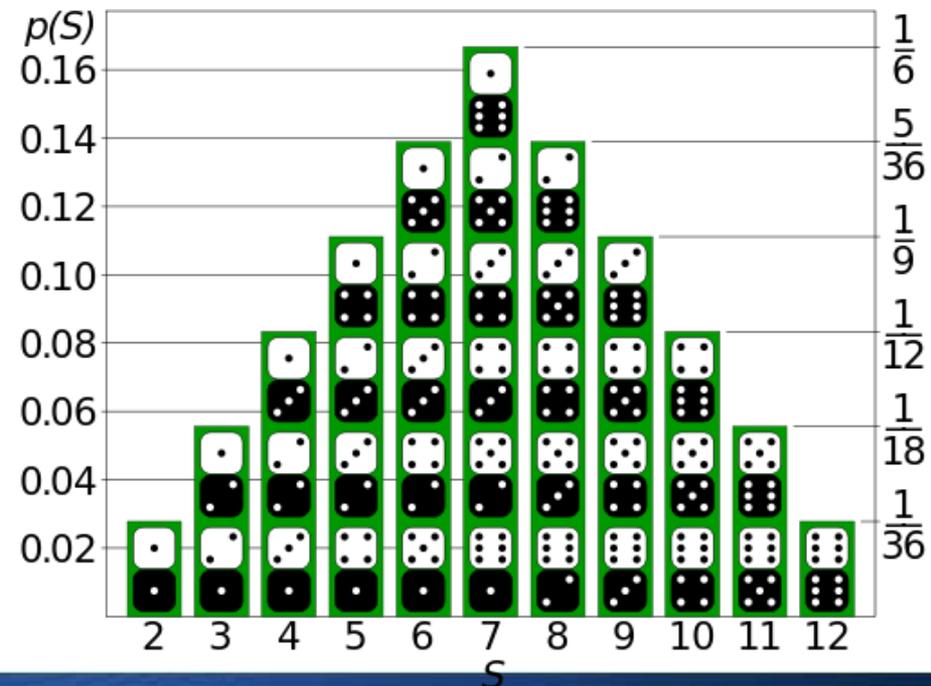
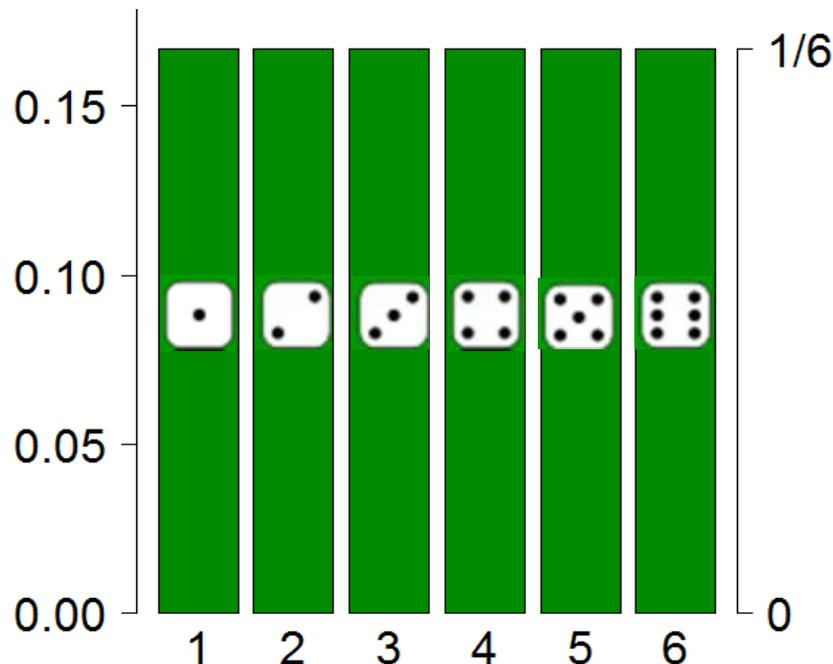
- Angenommen:
  - $X \sim \text{Pois}(\lambda_1), Y \sim \text{Pois}(\lambda_2)$
  - $X, Y$  sind unabhängig
- Bilde neue Zufallsvariable:  $Z = X + Y$

$$\Rightarrow Z \sim \text{Pois}(\lambda_1 + \lambda_2)$$

Das gilt normalerweise **nicht!**

## Normalerweise: Summe von zwei Verteilungen gibt eine neue Verteilung

- Bsp:  $X \sim Unif(\{1,2,3,4,5,6\})$ ,  $Y \sim Unif(\{1,2,3,4,5,6\})$   
 $X, Y$  sind unabhängig
- $S = X + Y$  ist nicht uniform verteilt (Augensumme 2 ist selten, Augensumme 7 ist häufig)



# Hypergeometrische Verteilung - $Hyper(N, n, m)$

- Situation
  - Urne mit  $N$  Kugeln,  $m$  davon weiss und  $N - m$  schwarz
  - Ziehe  $n$  Kugeln (ohne zurücklegen)
  - Wieviele Kugeln sind weiss?
- Zufallsvariable  $X$ : gezogene weisse Kugeln
- $X \sim Hyper(N, n, m)$

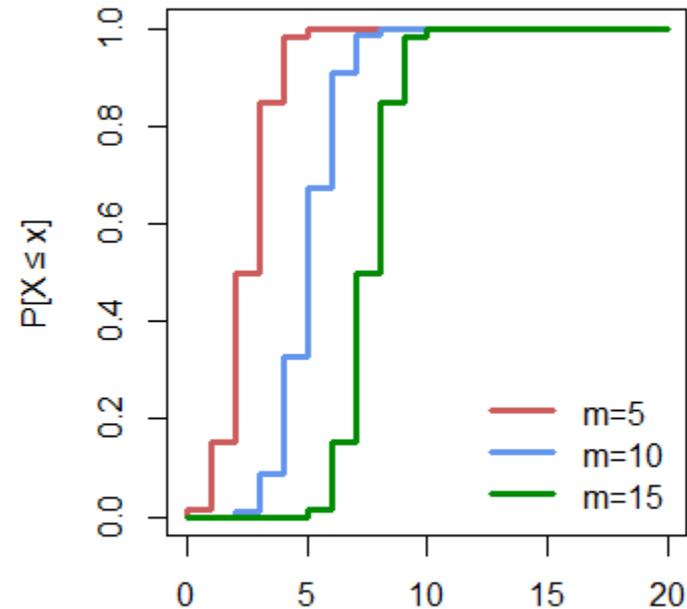
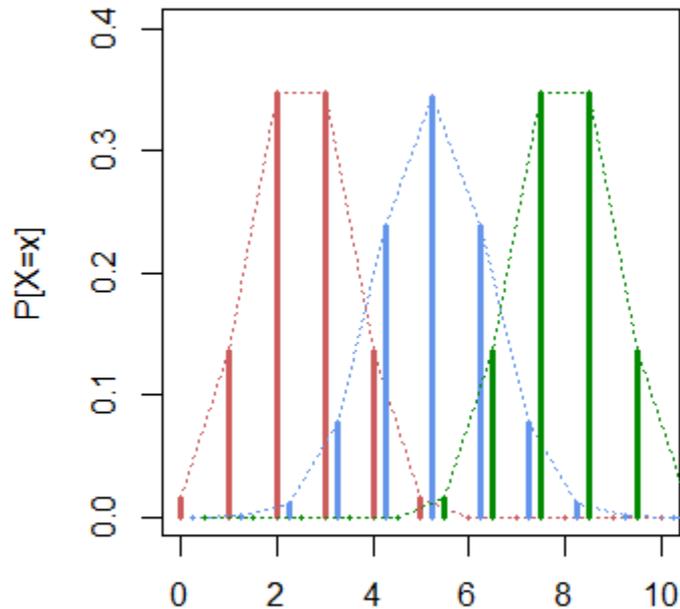
- $$P[X = x] = \frac{\binom{m}{x} \binom{N-m}{n-x}}{\binom{N}{n}}, \quad x \in \{0, 1, \dots, \min(m, n)\}$$

- $E(X) = \frac{n \cdot m}{N}$ ,  $Var(X)$  ziemlich kompliziert siehe



WIKIPEDIA

# Hypergeometrische Verteilung - $Hyper(N, n, m)$



- Beispiel: **Urnenmodell**,  $X \sim Hyper(20, 3, 7)$ 
  - 20 Kugeln, davon 7 markiert, 3 werden ohne zurücklegen gezogen

$$P[X = 1] = \frac{\binom{7}{1} \binom{13}{2}}{\binom{20}{3}} \approx 0.48, \quad E(X) = \frac{3 \cdot 7}{20} = 1.05$$

## Beispiel «Clinical Trial – Phase 3»

- Doppel-blinde, randomisierte Studie

	Medikament	Placebo	Total
Geheilt	15	9	24
Nicht geheilt	10	11	21
Total	25	20	45

- Falls Medikament keine Wirkung hat: Es gibt 24 Personen, bei denen unabhängig von der Gruppenzuteilung fest steht, dass sie gesund werden

## Beispiel «Clinical Trial – Phase 3»

- ZV  $X$ : Anzahl geheilter Patienten in Medikamentengruppe
- unter  $\mathcal{H}_0$  (keine Wirkung):  $X \sim \text{Hyper}(N = 45, m = 24, n = 25)$

	Medikament	Placebo	Total
Geheilt	15	9	24
Nicht geheilt	10	11	21
Total	25	20	45

- Ist es dann plausibel 15 geheilte Patienten in der Medikamentengruppe zu beobachten?

$$P(X \geq 15) = 1 - P(X \leq 14) = 1 - 0.76 = 0.24$$

- Wenn nicht wirksam, durchaus möglich 15 oder mehr...

# Momentenmethode



## ■ Beispiel «Bachforellenzucht»

- in 100 zufällig ausgewählten Bächen werden Brütlinge ausgesetzt
- nach knapp einem Jahr werden in 54 Standorten grosse Jungtiere gefunden
- Wie gross ist die Wahrscheinlichkeit, dass eine solche Wildzucht erfolgreich ist?

## ■ $X$ : Anzahl Jungtiere, die überleben

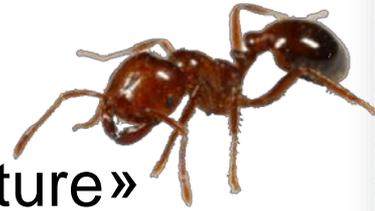
$$X \sim \text{Bin}(n = 100, \pi = ?)$$

- Beobachtung:  $x = 54$

## ■ Momentenmethode um $\pi$ zu schätzen:

$$E(X) = n \cdot \pi; \quad E(X) \approx x = 54 \rightarrow x \approx n \cdot \pi \rightarrow \pi \approx \frac{x}{n} = 0.54$$

# Momentenmethode



- Beispiel «Capture-Recapture»
  - Wie gross ist eine Population, von der wir **gar nichts** weiter wissen?
- Lincoln-Peterson Methode:
  - Fange  $m$  zufällige Tiere, markiere, lasse wieder laufen
  - Fange  $n$  zufällige Tiere
  - ZV  $X$ : Anzahl markierter Tiere im zweiten Fang
- $X \sim \text{Hyper}(N, n, m)$ , wobei  $N$  die Grösse der Pop. ist;  
 $x$  markierte Tiere im zweiten Fang
- Idee: «Erwartungswert  $\approx$  Beobachtung»
  - $E(X) = \frac{n \cdot m}{N} \approx x \rightarrow N \approx \frac{n \cdot m}{x}$
- Ungenau, aber OK für richtige Grössenordnung

# Maximum-Likelihood Methode

- Bsp:  $n=600$  Personen erhalten neues Medikament;  $x=30$  haben als Nebenwirkung Kopfschmerzen
- Wie gross ist der Anteil Personen mit diesen Nebenwirkungen in der Gesamtbevölkerung ( $>600$ )?
- Binomialverteilung:
  - $X$ : Anzahl Personen mit Kopfschmerzen
  - $X \sim \text{Bin}(n = 600, \pi)$
  - $P[X = 30] = \binom{600}{30} \pi^{30} (1 - \pi)^{570}$
- **Maximum-Likelihood Estimate (MLE)**  $\hat{\pi}$  für  $\pi$ , ist der Wert, der  $P[X = 30]$  maximiert.

# Maximum-Likelihood Methode

- mit dem Computer:
  - berechne  $P[X = 30]$  für verschiedene Werte von  $\pi$ :

$\pi$	...	0.03	0.04	0.05	0.06	0.07	...
$P[X = 30]$		0.002	0.036	0.075	0.042	0.010	

Maximum  
 $\hat{\pi} \approx 0.05$

- analytisch:
  - $P[X = x] = \binom{n}{x} \pi^x (1 - \pi)^{n-x} =: f(\pi)$  «likelihood»
  - Analysis: Finde  $\pi$ , sodass  $f(\pi)$  maximal ist (siehe Skript S. 25)
- Ergebnis:  $\hat{\pi} = \frac{x}{n} = \frac{30}{600} = 0.05$

# Zusammenfassung

- Diskrete Verteilungen:
  - Binomial, Uniform, Poisson, Hypergeometrisch
- Parameterschätzung:
  - Momentenmethode, Maximum-Likelihood Estimation

## Hausaufgaben

- Skript: Kapitel 3.1 – 3.2.1 lesen
- Serie 4 lösen
- Quiz 4 bearbeiten
- etutoR 3 anschauen

