

Diskrete Wa.verteilungen: Eine Zooführung

Statistik (Biol./Pharm./HST) – FS 2015




Admin: Übungsbetrieb & Quiz

- Gruppeneinteilung selbstständig via Webseite
- Eine e-mail mit Link für Einschreibung nur nach Belegung dieser Vorlesung in myStudies
- Genau eine e-mail mit personalisiertem Link für Einschreibung
- Link behalten !
- Eine 2. e-mail mit Link für Übungen nur nach Belegung dieser Vorlesung in myStudies
- Genau eine e-mail mit personalisiertem Link für Übungen
- Link behalten !

- Jede Woche erscheinen auf dieser Seite
 - Link zur Eingabe der Online Aufgaben
 - Lösungen und Auswertung

Warum Wa.verteilungen?

George E.P. Box



“Essentially,
all models are
wrong,
but some are
useful.”

“Standard” Wa.verteilungen




Details dieser Verteilungen
in Büchern oder Software
festgehalten




Viele typische Probleme einfach lösbar

Verteilungs-Zoo: Diskrete Wa.verteilungen


Binomialverteilung




Uniforme Verteilung



Hypergeometrische Verteilung




Poisson Verteilung




Binomialverteilung

- **Situation:** Ziehe n Lose an Losbude; gleiche Gewinnwa. für alle Lose; Lose unabhängig
- ZV X : Anzahl Gewinne unter n Losen
- $X \sim \text{Bin}(n, \pi)$
“ X ist binomial verteilt mit Parametern n und π ”
- $P(X = x) = \binom{n}{x} \pi^x (1 - \pi)^{n-x}$, $x \in \{0, 1, \dots, n\}$
- $E(X) = n \cdot \pi$, $\text{Var}(X) = n \cdot \pi \cdot (1 - \pi)$

“probability mass function” (pmf)



“cumulative mass function” (cmf)



QUIZ: BINOMIALVERTEILUNG


KAMPF DER DEPARTEMENTE

GEGEBEN: $X \sim \text{Bin}(20, 0.1)$; WIE GROSS IST $P(X = 2)$?



Stundenplan überblicken
Hörsäle finden
Lehrveranstaltungen interaktiv gestalten

Beispiel: Klinische Studien



- **Lose:** Alle denkbaren Patienten
- **n gezogene Lose:** n Patienten in Studie
- **Gewinn:** Patient wird gesund
- π : Anteil aller denkbaren Patienten, bei denen Medikament wirkt

Giftig?

Grob: Wirksam?

Genau: Wirksam?
Nebenwirkungen?

Bsp: Phase 2

- Hersteller behauptet: Neues Medikament wirkt in 80% der Fällen
- In einer Phase 2 Studie mit 100 Patienten werden aber nur 67 gesund
- Ist das plausibel, wenn die Heilungswa. 80% ist?
- 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: $P(X = 67) = 0.0008$

Sind Sie überzeugt ?

Bsp: Phase 2 - Problem

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

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

➔ $P(X = 67)$ ist **keine gute Kennzahl**, weil die Wa. 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

➔ $P(X \leq 67)$ ist eine **gute Kennzahl**; sie ist, unabhängig von der Stichprobengröße, leichter zu interpretieren.

p-Wert ("Wa. für Beob. oder etwas noch extremeres"; später mehr dazu...)

Bsp: Phase 2

- Hersteller behauptet: Neues Medikament wirkt in 80% der Fällen
- In einer Phase 2 Studie mit 100 Patienten werden aber nur 67 gesund
- Ist das plausibel, wenn die Heilungswa. 80% ist?
- X : Anzahl geheilter Patienten
- Falls Hersteller recht hat:

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

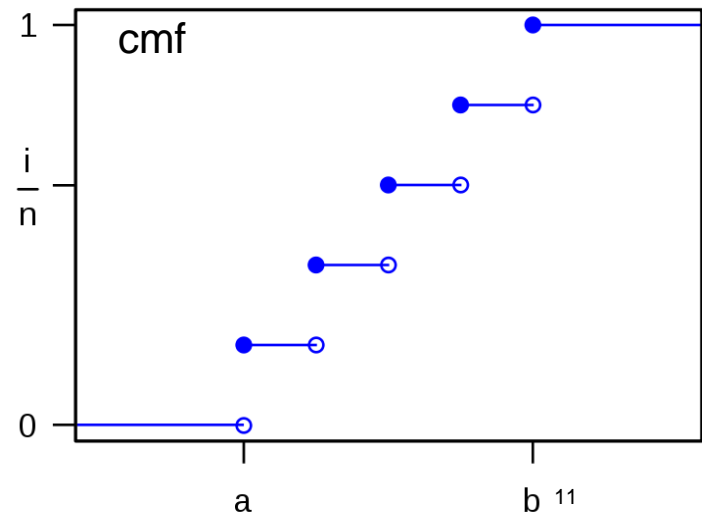

Wie testen wir diese Behauptung?

Versuch 2: $P(X \leq 67) = 0.001$

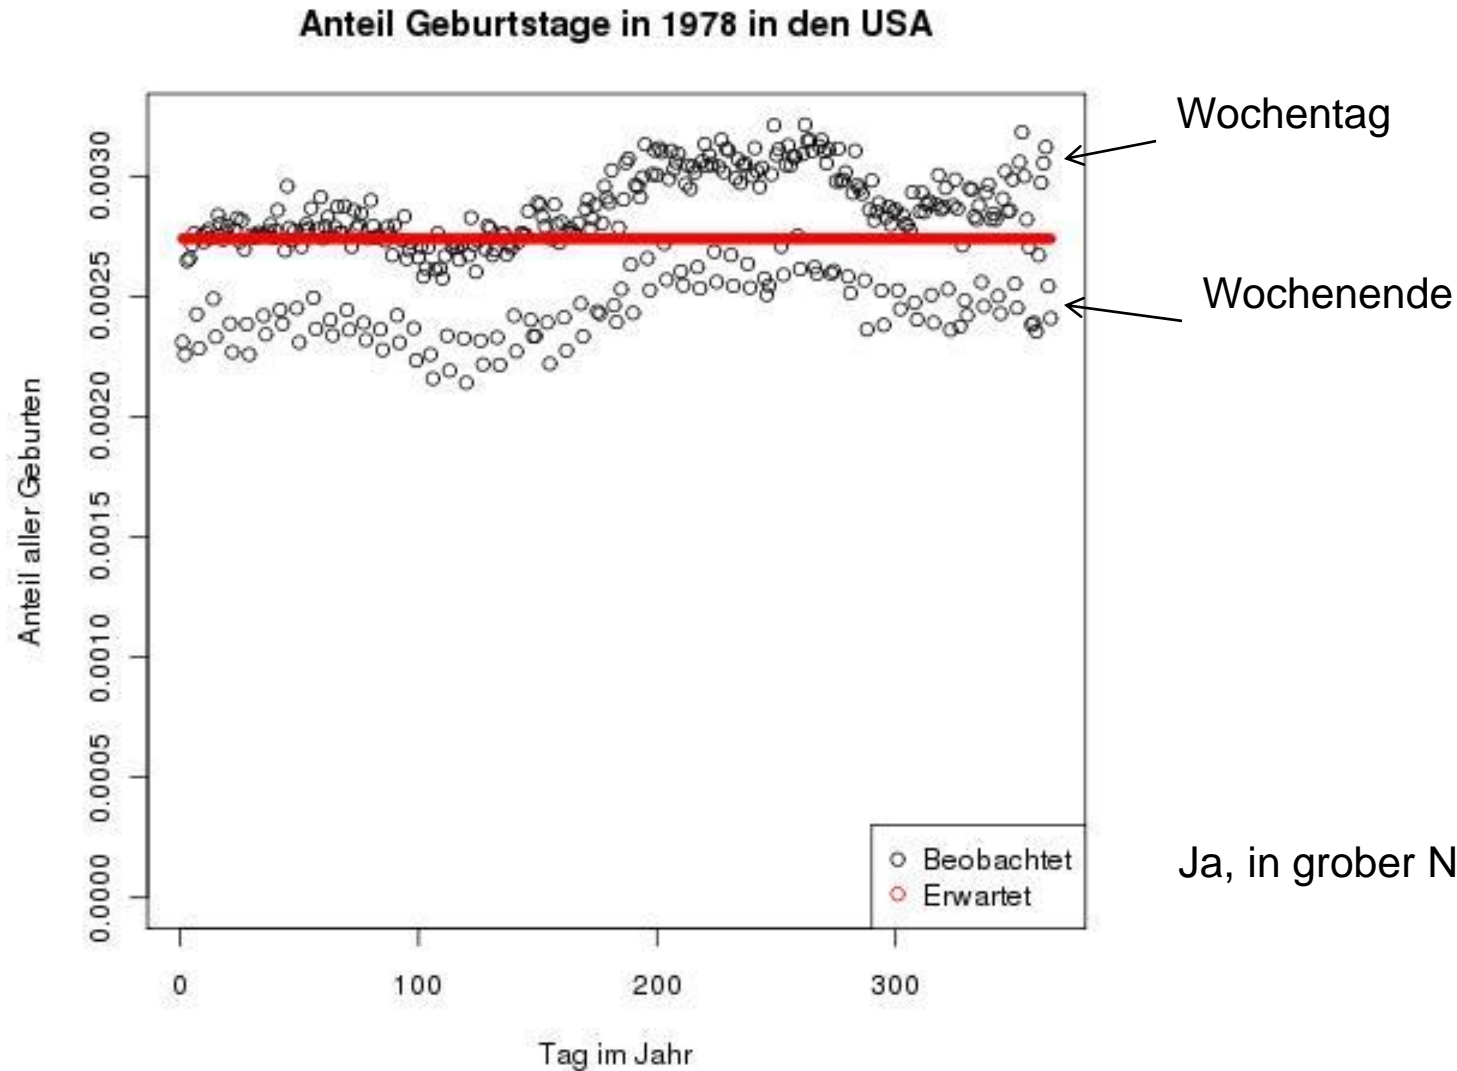
→ Beobachtung und Hypothese passen nicht zusammen;
vermutlich wirkt das Medikament schlechter als 80%.

Uniforme Verteilung

- Situation: Ziehe eine Zahl aus $\{1,2,\dots,n\}$; alle Zahlen sind gleich wahrscheinlich
- ZV X : Gezogene Zahl
- $X \sim \text{Unif}(n)$
“ X ist uniform verteilt auf den Zahlen 1 bis n ”
- $P(X = x) = \frac{1}{n}, x \in \{1,2, \dots, n\}$
- $E(X) = \frac{n+1}{2}, \text{Var}(X) = \frac{(n+1)(n-1)}{12}$





Bsp: Sind Geburtstage uniform verteilt?



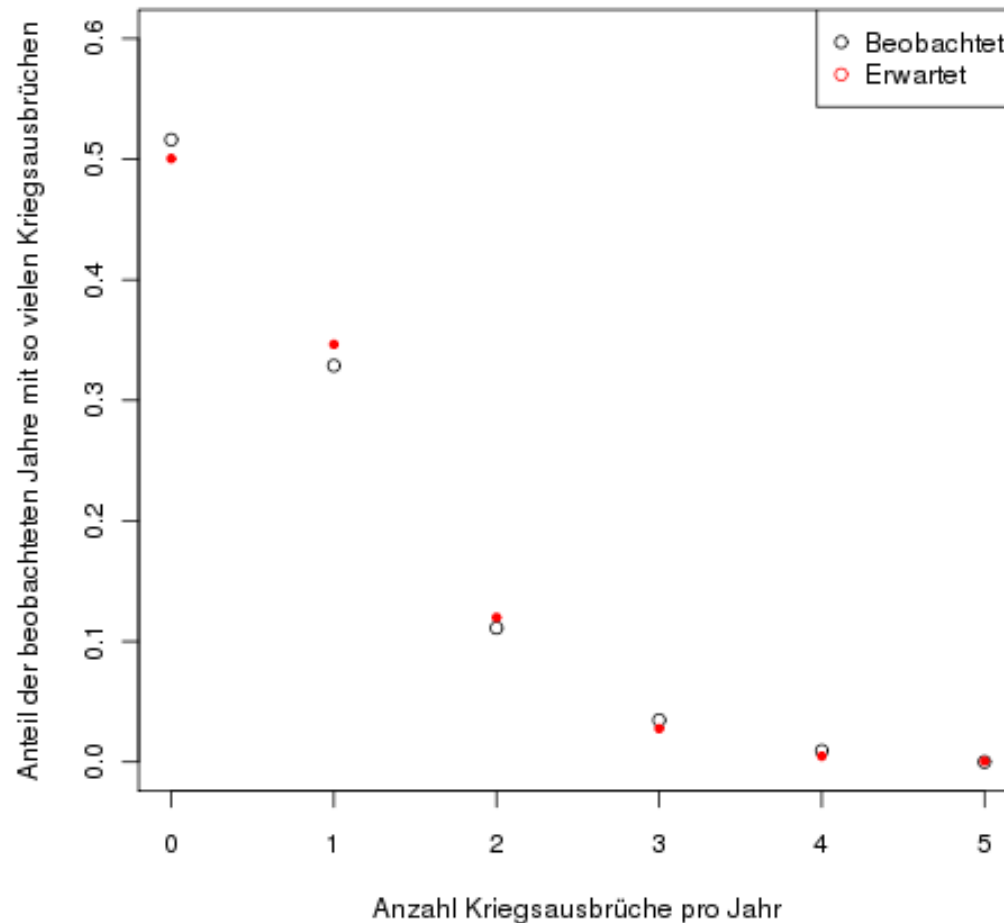
Ja, in grober Näherung schon

Poisson Verteilung

- Situation: Seltene Ereignisse werden in einem vorgegebenen Zeitraum gezählt
- ZV X : Anzahl beobachteter Ereignisse
- $X \sim Pois(\lambda)$
' X ist poisson verteilt mit Parameter λ '
- $P(X = x) = \frac{\lambda^x}{x!} \exp(-\lambda)$, $x \in \{0, 1, \dots, \infty\}$
- $E(X) = \lambda, Var(X) = \lambda$



Bsp: Ist die Anzahl Kriege pro Jahr poisson verteilt? (1500-1930, weltweit)





Besonderheit der Poissonverteilung

- Angenommen:
 - $X \sim Pois(\lambda_1), Y \sim Pois(\lambda_2)$
 - X, Y sind unabhängig
- Bilde neue Zufallsvariable: $Z = X + Y$
- Dann gilt: $Z \sim Pois(\lambda_1 + \lambda_2)$
- Das gilt normalerweise nicht!

Normalerweise: Summe von zwei Verteilungen gibt 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
- $Z = X + Y$ ist nicht uniform verteilt (Augensumme 2 ist selten, Augensumme 7 ist häufig)




Hypergeometrische Verteilung

- Situation: Urne mit N Kugeln; m sind markiert; ziehen n Kugeln ohne Zurücklegen; wie viele markierte Kugeln?
- ZV X : Anzahl markierter gezogener Kugeln
- $X \sim \text{Hyper}(N, n, m)$


“ X ist hypergeometrisch verteilt mit Paramtern N , n und m ”

- $P(X = x) = \frac{\binom{m}{x} \binom{N-m}{n-x}}{\binom{N}{n}}$ ← ‘günstig’
← ‘möglich’ $x \in \{0, 1, \dots, \min(n, m)\}$
- $E(X) = \frac{n \cdot m}{N}$, $Var(X)$ kompliziert; siehe z.B. Wikipedia

Hyper(15,10,10)



Hyper(15,10,10)



Bsp: Phase 3 Studie – Wirksamer als Placebo?

Doppel-blinde, randomisierte Studie

Markierte Bälle (m)

Gezogene und markierte Bälle

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

Gezogene Bälle (n)

Bälle in Urne (N)

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

Urnenmodell → Hypergeometrische Verteilung

Bsp: Phase 3 Studie – Wirksamer als Placebo?

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

ZV X: Anzahl geheilter Patienten in Medikamenten-Gruppe
Falls Medikament keine Wirkung hat:

$$X \sim \text{Hyper}(N = 45, m = 24, n = 25)$$

Ist es dann plausibel in der Medikamenten-Gruppe 15 oder mehr geheilte Patienten zu beobachten?

$$P(X \geq 15) = 1 - P(X \leq 14) = 1 - 0.76 = \boxed{0.24} \text{ p-Wert}$$

Falls das Medikament nicht wirkt, ist es durchaus plausibel 15 oder mehr geheilte Patienten in der Medikamentengruppe zu beobachten

Momentenmethode, Bsp 1:

- 100 zufällig ausgewählte Patienten bekommen neues Medikament
- 54 werden gesund
- Wie gross ist wohl die Wirkwahrscheinlichkeit in der gesamten Bevölkerung?

- X : Anzahl Patienten, die gesund wurden

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

Beobachtung: $x = 54$

- Momentenmethode um π zu schätzen:

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

“Erstes Moment”

Momentenmethode, Bsp 2: Capture-Recapture



- Wie gross ist eine Population, von der wir sonst *gar nichts* weiter wissen?
- Bsp: Ameisen in Ameisenhaufen; Fische in See
- 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

“Erstes Moment”

Maximum-Likelihood Methode 1/3

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 π , ist der Wert, der
 $P(X = 30)$ maximiert.

Maximum-Likelihood Methode 2/3: Computer

Berechne $P(X = 30)$ für verschiedene Werte von π mit dem Computer:

π	...	0.03	0.04	0.05	0.06	0.07	...
$P(X = 30)$		0.002	0.036	0.075	0.042	0.010	



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

Maximum-Likelihood Methode 3/3: Analytisch

- $P(X = x) = \binom{n}{x} \pi^x (1 - \pi)^{n-x} =: f(\pi)$ “likelihood”
- Analysis: Finde π , sodass $f(\pi)$ maximal ist
(s. Skript S.28)
- Ergebnis: $\hat{\pi} = \frac{x}{n} = \frac{30}{600} = 0.05$

Wir erwarten, dass bei etwa 5% der Gesamtbevölkerung Kopfschmerzen als Nebenwirkung auftritt.