

Zentraler Grenzwertsatz/Konfidenzintervalle

Statistik I

Sommersemester 2009

Kann Ahmadinejad die Wahl gewonnen haben?

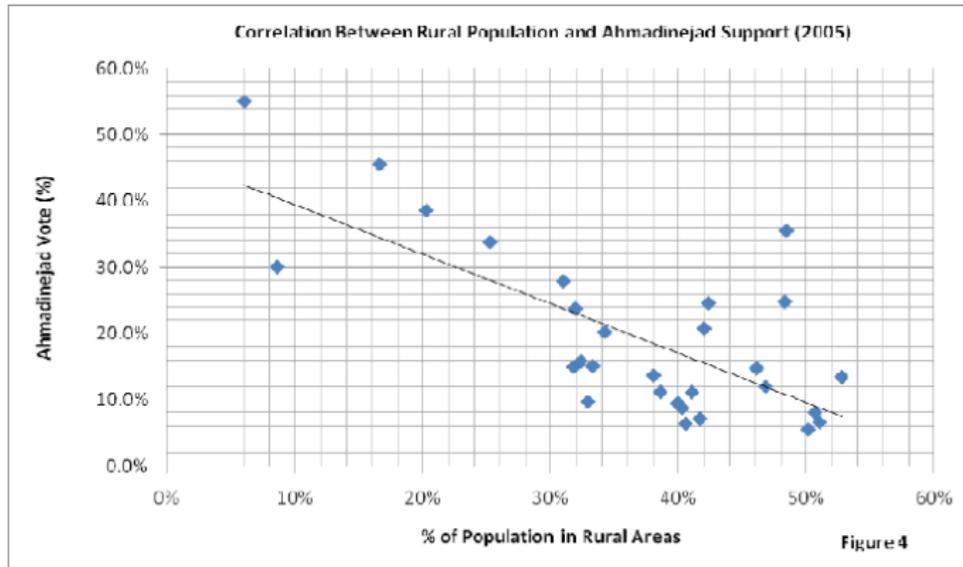
- ▶ Im wesentlichen Dreiteilung der polit. Elite
- ▶ 2005: 17.3 Millionen Stimmen (Stichwahl), Wahlbeteiligung 48%
- ▶ 2009: 24.5 Millionen Stimmen, Wahlbeteiligung ca. 83%
- ▶ Anders als 2005 kaum Unterschiede in Wahlbeteiligung zwischen den 30 Provinzen
- ▶ Woher kommt der Zuwachs von 7.2 Millionen Stimmen?



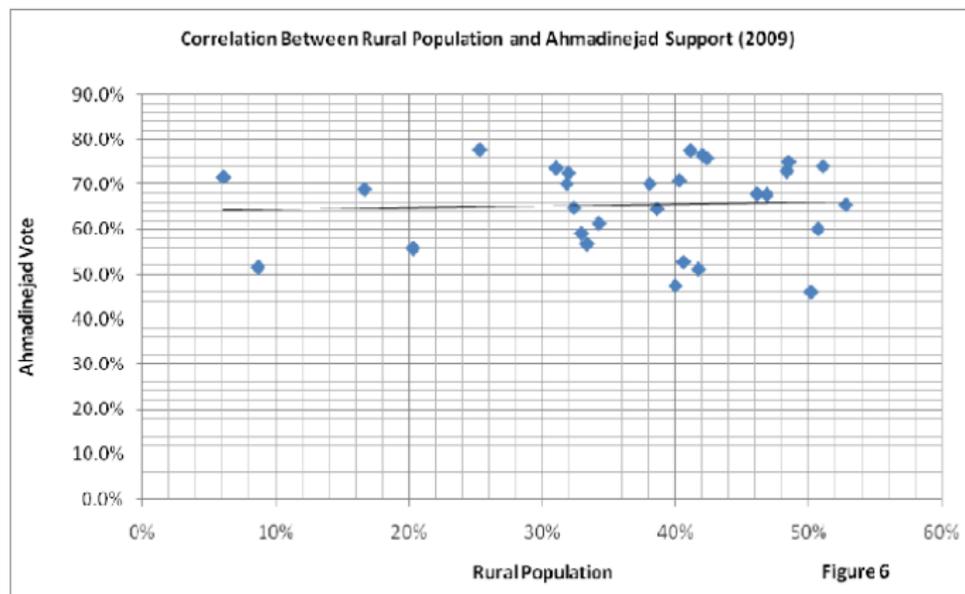
Was ist problematisch?

- ▶ Etwas über 100% Wahlbeteiligung in zwei konservativen Provinzen
- ▶ In zehn Provinzen müßte Ahmadinejad nach dem offiziellen Ergebnis
 - ▶ Alle konservativen Wähler von 2005
 - ▶ Alle Erst-/früheren Nichtwähler
 - ▶ Alle früheren Zentrumswähler
 - ▶ Und fast die Hälfte der reformistischen Wähler für sich gewonnen haben
- ▶ 1997, 2001 und 2005 konservative Kandidaten in ländlichen Provinzen sehr unpopulär
- ▶ 2009
 - ▶ Kein Zusammenhang zwischen Zunahme Wahlbeteiligung/Zunahme Ahmadinejad
 - ▶ Negativer Zusammenhang zwischen ländlich/Ahmadinejad verschwindet

2005: Land/Ahmadinejad

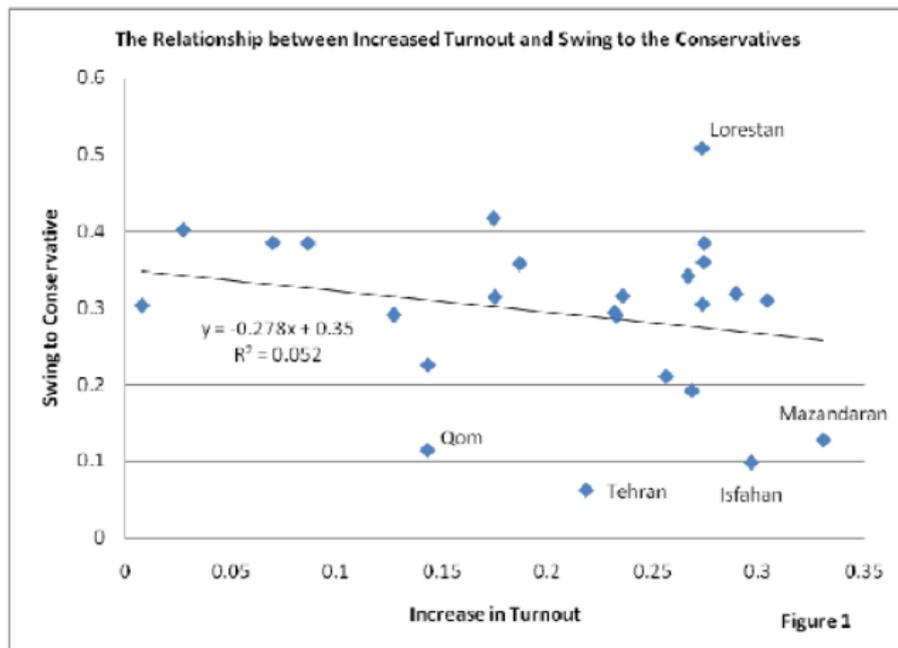


2009: Land/Ahmadinejad



Mehr: http://www.chathamhouse.org.uk/files/14234_iranelection0609.pdf

Wahlbeteiligung/Zuwachs Ahmadinejad



Iran

Wiederholung

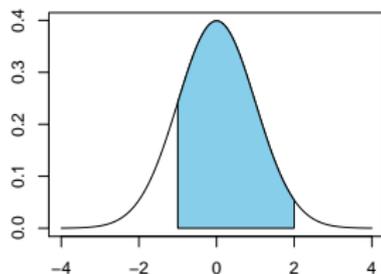
Inferenzstatistik

Punktschätzungen

Zentraler Grenzwertsatz

Konfidenzintervalle

Zusammenfassung



Zum Nachlesen

- ▶ Agresti/Finlay Kapitel 5
- ▶ Gehring/Weins Kapitel 11
- ▶ Schumann Kapitel 6

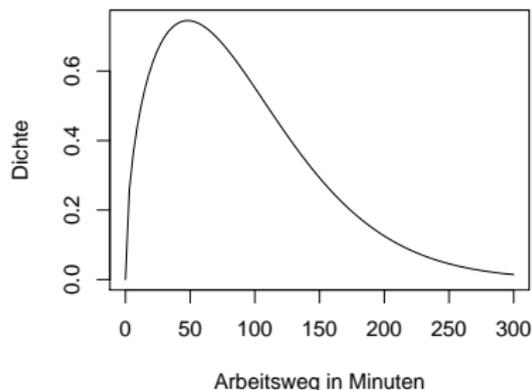
Zufallsexperiment/Wahrscheinlichkeiten

- ▶ Zufallsexperiment:
 - ▶ Ausgang hängt nur vom Zufall ab
 - ▶ (Theoretisch) beliebig oft wiederholbar
 - ▶ Relative Häufigkeiten → Wahrscheinlichkeiten
- ▶ Gedankenexperiment; Standardbeispiele: Münz- und Würfelwurf
- ▶ Nützliches Modell für Sozialwissenschaftler
- ▶ Z. B. für Stichprobenziehung

Wahrscheinlichkeitsverteilungen

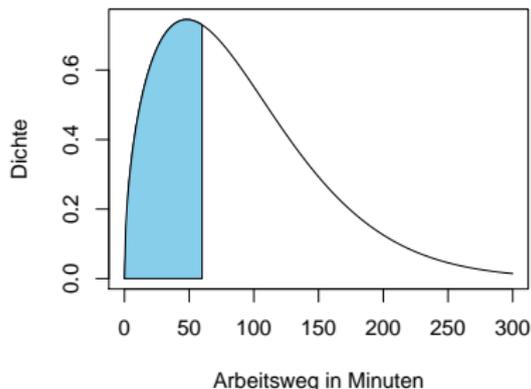
- ▶ Wahrscheinlichkeitsverteilungen fassen mögliche Ergebnisse von Zufallsexperimenten und deren Wahrscheinlichkeiten zusammen
- ▶ Summe der Balken über alle Ereignisse = 1
- ▶ Ok für abzählbare Ereignisse (diskrete Zufallsvariablen)
- ▶ Was tun mit kontinuierlichen Zufallsvariablen?
- ▶ Histogramm \rightarrow Dichteschätzung
- ▶ Fläche unter Dichtefunktion = 1 (Gesamtwahrscheinlichkeit)
- ▶ Wahrscheinlichkeit für Wert aus einem bestimmten Bereich = Fläche über diesem Intervall

Dauer: Fahrt zur Arbeit



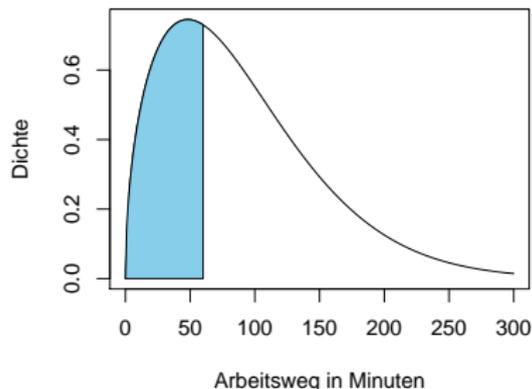
- ▶ Wieviel % der Bürger brauchen 60 Minuten oder weniger für den Weg zur Arbeit?
- ▶ Potentielle Unterstützer für Infrastrukturmaßnahmen
- ▶ Fläche links von 60?

Dauer: Fahrt zur Arbeit



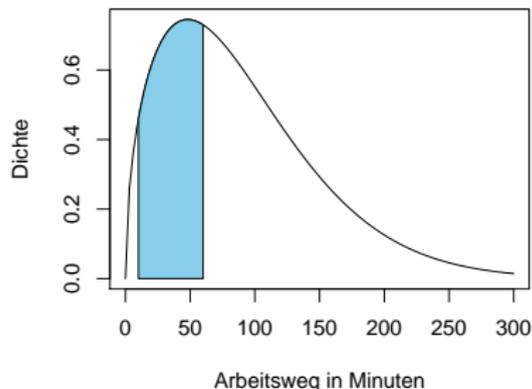
- ▶ Wieviel % der Bürger brauchen 60 Minuten oder weniger für den Weg zur Arbeit?
- ▶ Potentielle Unterstützer für Infrastrukturmaßnahmen
- ▶ Fläche links von 60? → 37%

Dauer: Fahrt zur Arbeit



- ▶ Wieviel % der Bürger brauchen 60 Minuten oder weniger für den Weg zur Arbeit?
- ▶ Potentielle Unterstützer für Infrastrukturmaßnahmen
- ▶ Fläche links von 60? → 37%
- ▶ Wieviele % brauchen mehr als 10 und weniger als 60 Minuten?

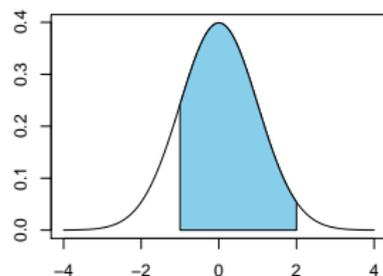
Dauer: Fahrt zur Arbeit



- ▶ Wieviel % der Bürger brauchen 60 Minuten oder weniger für den Weg zur Arbeit?
- ▶ Potentielle Unterstützer für Infrastrukturmaßnahmen
- ▶ Fläche links von 60? → 37%
- ▶ Wieviele % brauchen mehr als 10 und weniger als 60 Minuten?
- ▶ Wichtige Verteilungen tabelliert

Normalverteilung

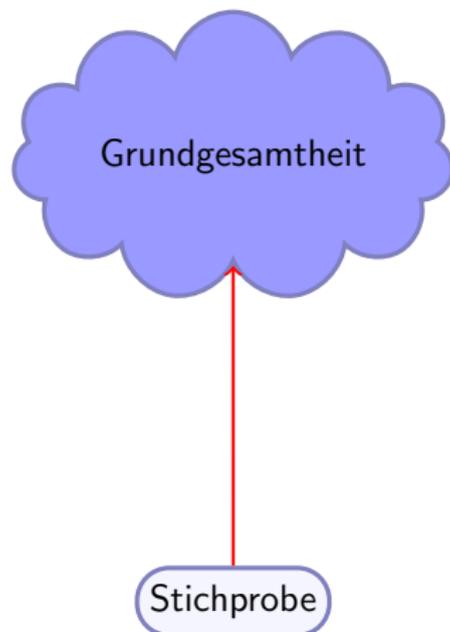
- ▶ Bekannteste und wichtigste aller kontinuierlichen Zufallsverteilungen
- ▶ Wahrscheinlichkeitsdichte für Werte zwischen $-\infty$ und $+\infty$
- ▶ Fläche unter der Kurve = 1
- ▶ Über dem Intervall $[-1;2]$ liegen rund 82% der Fläche
- ▶ D. h. in ≈ 4 von 5 Fällen zieht man einen Wert aus diesem Intervall



Worum geht es bei der Inferenzstatistik?

- ▶ Wie kommt man von einer Stichprobe zu einem (gültigen) Schluß auf die Grundgesamtheit?
- ▶ Bzw. wie groß ist der Fehler, den man dabei wahrscheinlich macht?
- ▶ Parameter in der Stichprobe vs. Parameter in der Grundgesamtheit
- ▶ Parameter z. B.:
 - ▶ Mittelwert
 - ▶ Varianz/Standardabweichung
 - ▶ Anteilswerte
 - ▶ Zusammenhangsmaße
 - ▶ Regressionskoeffizienten
 - ▶ ...

Grundgesamtheit/Stichprobe



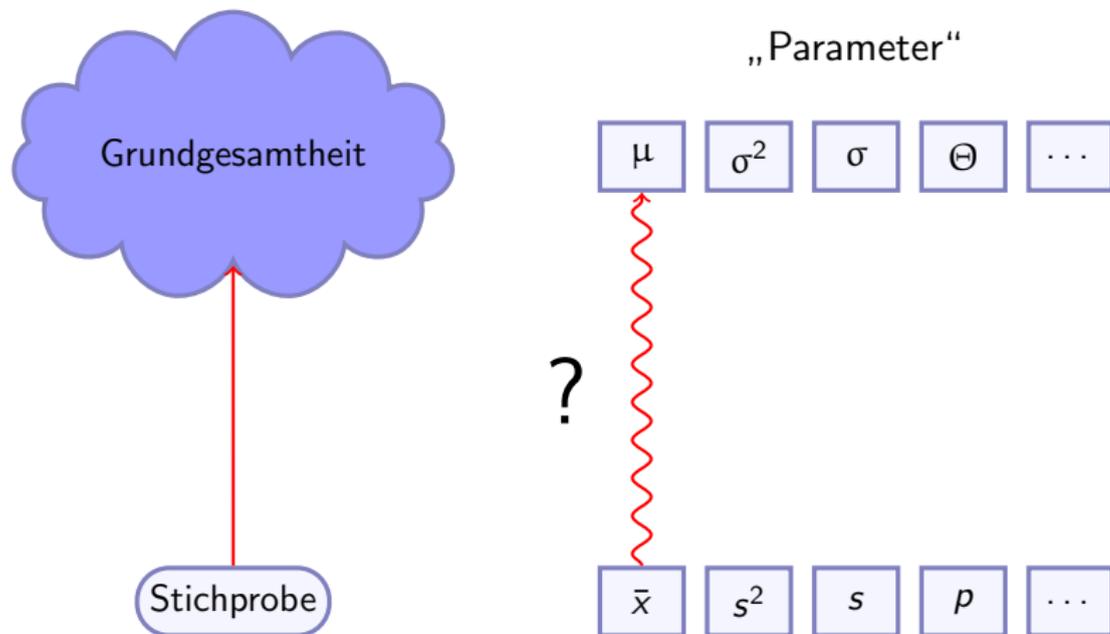
„Parameter“



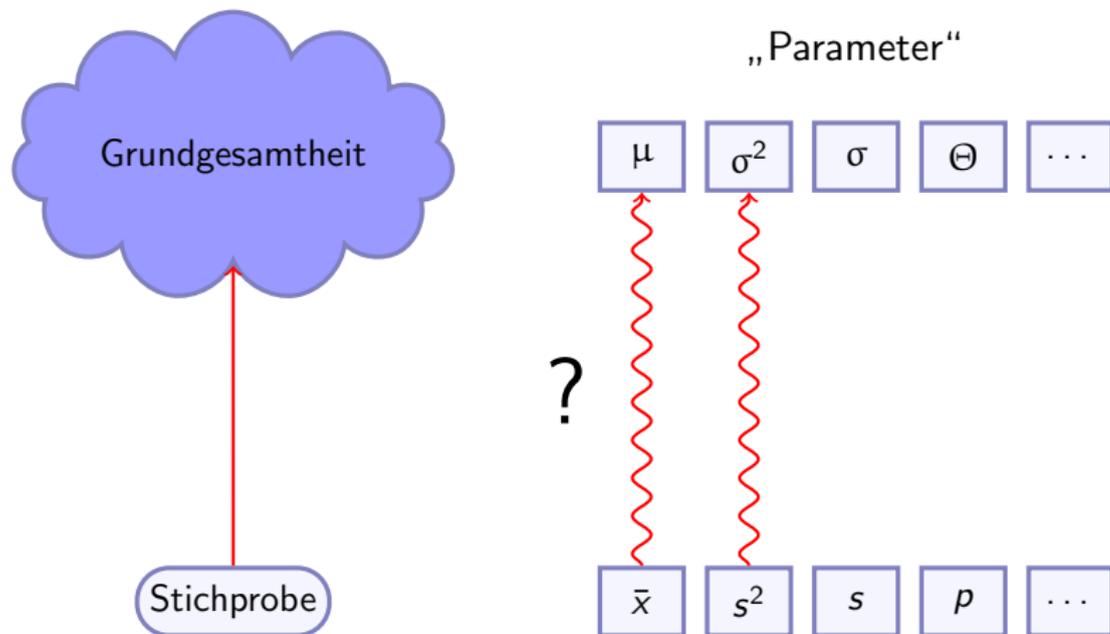
?



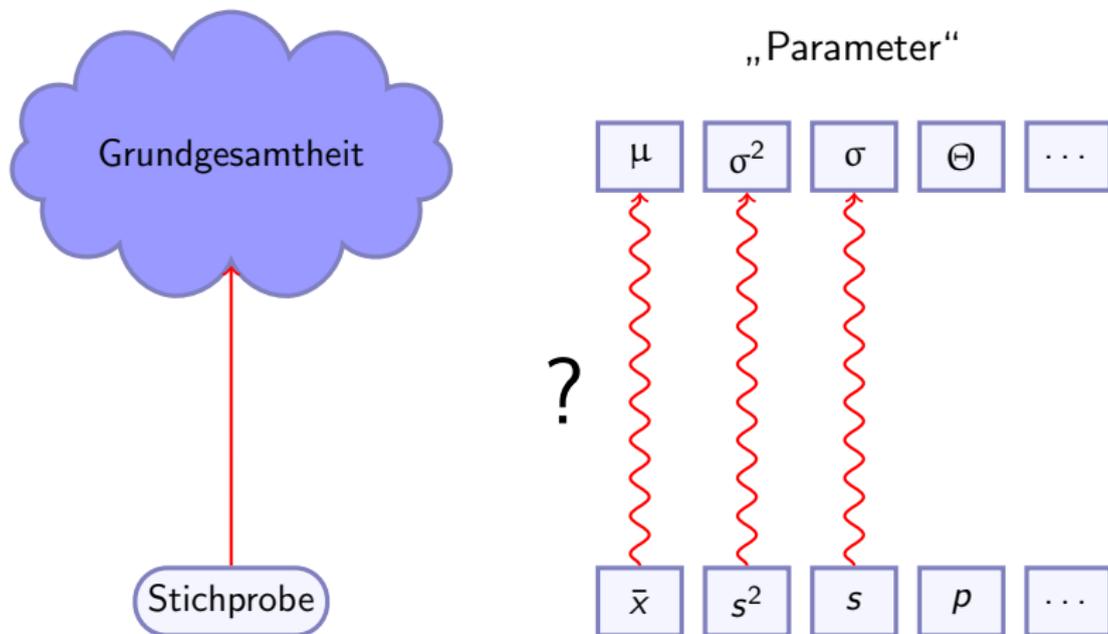
Grundgesamtheit/Stichprobe



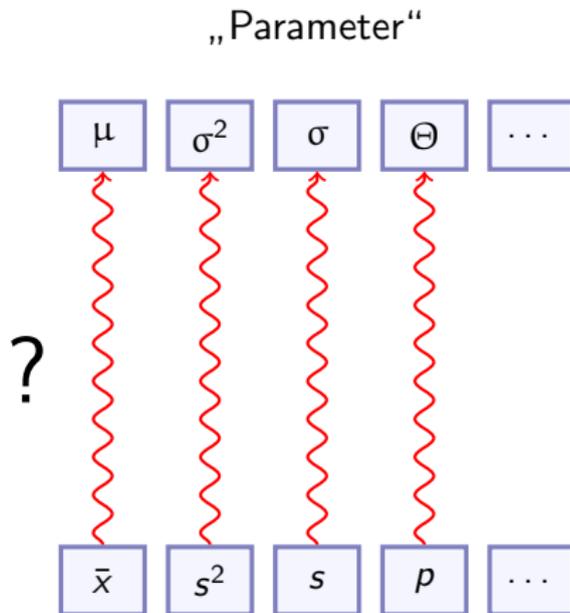
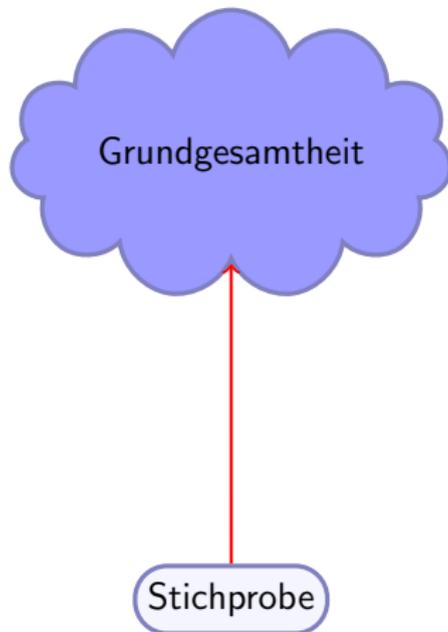
Grundgesamtheit/Stichprobe



Grundgesamtheit/Stichprobe



Grundgesamtheit/Stichprobe



Wie funktionieren Punktschätzungen?

- ▶ *Ein* Wert als Schätzung für Parameter in der Grundgesamtheit
- ▶ Punktschätzungen sollen präzise sein (wenig Variationen über Stichproben)
- ▶ Punktschätzungen sollen unverzerrt / „erwartungstreu“ sein (kein bias)
- ▶ Stichprobenmittelwert: unverzerrte Schätzung für Mittelwert in Grundgesamtheit
- ▶ Anteilswert in Stichprobe: unverzerrte Schätzung für Anteilswert in Grundgesamtheit

Wie funktionieren Punktschätzungen?

- ▶ *Ein* Wert als Schätzung für Parameter in der Grundgesamtheit
- ▶ Punktschätzungen sollen präzise sein (wenig Variationen über Stichproben)
- ▶ Punktschätzungen sollen unverzerrt / „erwartungstreu“ sein (kein bias)
- ▶ Stichprobenmittelwert: unverzerrte Schätzung für Mittelwert in Grundgesamtheit
- ▶ Anteilswert in Stichprobe: unverzerrte Schätzung für Anteilswert in Grundgesamtheit
- ▶ Varianz (Standardabweichung) in Stichprobe:

Wie funktionieren Punktschätzungen?

- ▶ *Ein* Wert als Schätzung für Parameter in der Grundgesamtheit
- ▶ Punktschätzungen sollen präzise sein (wenig Variationen über Stichproben)
- ▶ Punktschätzungen sollen unverzerrt / „erwartungstreu“ sein (kein bias)
- ▶ Stichprobenmittelwert: unverzerrte Schätzung für Mittelwert in Grundgesamtheit
- ▶ Anteilswert in Stichprobe: unverzerrte Schätzung für Anteilswert in Grundgesamtheit
- ▶ Varianz (Standardabweichung) in Stichprobe: **unterschätzt** Varianz in Grundgesamtheit

Was ist los mit der Varianz?

- ▶ Varianz s^2 in Stichprobe unterschätzt Varianz σ^2 um Faktor $\frac{n-1}{n}$
- ▶ Mit $\frac{n}{n-1}$ multiplizieren
- ▶ Berechnung von Stichprobenvarianz *als Schätzung für Grundgesamtheit* läßt sich vereinfachen:

$$\begin{aligned}\hat{\sigma}^2 &= s^2 \times \frac{n}{n-1} \\ &= \frac{\sum (x_i - \bar{x})^2}{n} \times \frac{n}{n-1} \\ &= \frac{\sum (x_i - \bar{x})^2}{n-1}\end{aligned}$$

- ▶ Irrelevant in großen Stichproben

Warum reichen Punktschätzungen nicht?

$$\hat{\sigma} = \sqrt{\hat{\sigma}^2}$$

- ▶ Schätzungen basieren auf Zufallsstichproben
- ▶ Parameter in Stichprobe sind Zufallsvariablen – kontinuierliche Verteilung um wahren Wert (Grundgesamtheit)
- ▶ Wahrscheinlichkeit wahren Wert exakt zu treffen = 0
- ▶ Wahrscheinlichkeit, Stichprobenwert aus einem bestimmten Intervall zu erhalten?
- ▶ Analyse der Zufallsverteilung

Wiederholung: Repräsentative Umfrage

„Die Repräsentativitätslüge“

„Meinungsumfragen nennen sich oft ‚repräsentativ‘ tatsächlich aber werden die Befragten meist nach dem Zufallsprinzip ausgewählt (aus „Vorwärts“, 10/1994, S. 23)

Def. repräsentativ:

- ▶ Jedes Element der GG hat gleiche
- ▶ oder angebbare
- ▶ Wahrscheinlichkeit in die Stichprobe zu gelangen

Wiederholung: Repräsentative Umfrage

„Die Repräsentativitätslüge“

„Meinungsumfragen nennen sich oft ‚repräsentativ‘ tatsächlich aber werden die Befragten meist nach dem Zufallsprinzip ausgewählt (aus ‚Vorwärts‘, 10/1994, S. 23)

- ▶ *Zufällige Auswahl* der Untersuchungsobjekte

Def. repräsentativ:

- ▶ Jedes Element der GG hat gleiche
- ▶ oder angebbare
- ▶ Wahrscheinlichkeit in die Stichprobe zu gelangen

Wiederholung: Repräsentative Umfrage

„Die Repräsentativitätslüge“

„Meinungsumfragen nennen sich oft ‚repräsentativ‘ tatsächlich aber werden die Befragten meist nach dem Zufallsprinzip ausgewählt (aus ‚Vorwärts‘, 10/1994, S. 23)

- ▶ *Zufällige Auswahl* der Untersuchungsobjekte
- ▶ **Voraussetzung für Inferenzstatistik**

Def. repräsentativ:

- ▶ Jedes Element der GG hat gleiche
- ▶ oder angebbare
- ▶ Wahrscheinlichkeit in die Stichprobe zu gelangen

Stichprobenziehung als komplexes Zufallsexperiment

- ▶ Zufällige Auswahl von n Befragten
- ▶ Berechnung eines Stichprobenparameters (z. B. Mittelwert LRS) über n Befragte
- ▶ Stichprobenparameter als *Ergebnis* des komplexen Zufallsexperimentes
- ▶ Experiment (prinzipiell) sehr oft wiederholbar
- ▶ *Wahrscheinlichkeit*, ein bestimmtes Ergebnis/Ergebnis innerhalb eines bestimmten Wertebereiches zu erhalten
- ▶ Berechenbar, wenn Verteilung der Zufallsvariable bekannt

Stichprobenziehung als komplexes Zufallsexperiment

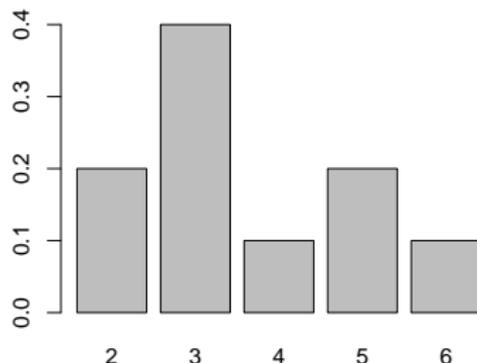
- ▶ Zufällige Auswahl von n Befragten
- ▶ Berechnung eines Stichprobenparameters (z. B. Mittelwert LRS) über n Befragte
- ▶ Stichprobenparameter als *Ergebnis* des komplexen Zufallsexperimentes
- ▶ Experiment (prinzipiell) sehr oft wiederholbar
- ▶ *Wahrscheinlichkeit*, ein bestimmtes Ergebnis/Ergebnis innerhalb eines bestimmten Wertebereiches zu erhalten
- ▶ Berechenbar, wenn Verteilung der Zufallsvariable bekannt
- ▶ Wie sieht die Verteilung des Stichprobenparameters (z. B. Mittelwert) aus? → „Grenzwertsatz“

Stichprobenziehung als komplexes Zufallsexperiment

- ▶ Zufällige Auswahl von n Befragten
- ▶ Berechnung eines Stichprobenparameters (z. B. Mittelwert LRS) über n Befragte
- ▶ Stichprobenparameter als *Ergebnis* des komplexen Zufallsexperimentes
- ▶ Experiment (prinzipiell) sehr oft wiederholbar
- ▶ *Wahrscheinlichkeit*, ein bestimmtes Ergebnis/Ergebnis innerhalb eines bestimmten Wertebereiches zu erhalten
- ▶ Berechenbar, wenn Verteilung der Zufallsvariable bekannt
- ▶ Wie sieht die Verteilung des Stichprobenparameters (z. B. Mittelwert) aus? → „Grenzwertsatz“
- ▶ Bei Konstruktion der Zufallsvariable Mittelwert wirken viele (n) einfache Zufallsvariablen zusammen

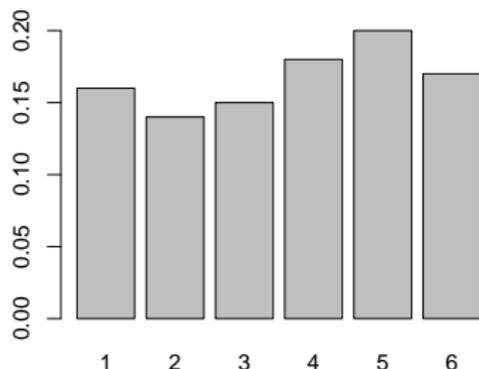
Einfaches Zufallsexperiment: $n = 1$

- ▶ Würfel einmal werfen ($n = 1$), Ergebnis notieren
- ▶ Experiment sehr oft wiederholen
- ▶ Häufigkeit der Werte 1, 2, \dots 6 nähert sich an Verteilung in GG (Gleichverteilung) an („Gesetz der großen Zahl“)
- ▶ 10 Wiederholungen



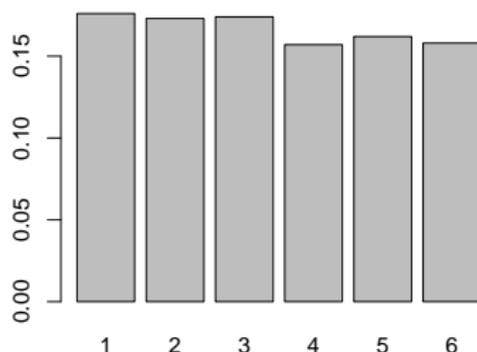
Einfaches Zufallsexperiment: $n = 1$

- ▶ Würfel einmal werfen ($n = 1$), Ergebnis notieren
- ▶ Experiment sehr oft wiederholen
- ▶ Häufigkeit der Werte 1, 2, \dots 6 nähert sich an Verteilung in GG (Gleichverteilung) an („Gesetz der großen Zahl“)
- ▶ 100 Wiederholungen



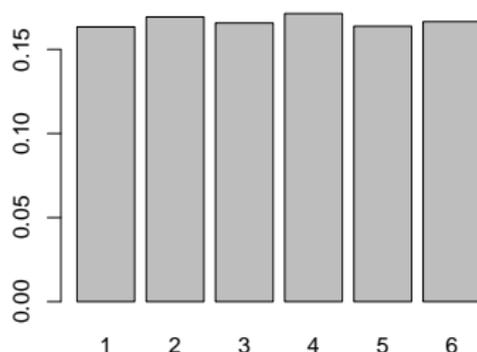
Einfaches Zufallsexperiment: $n = 1$

- ▶ Würfel einmal werfen ($n = 1$), Ergebnis notieren
- ▶ Experiment sehr oft wiederholen
- ▶ Häufigkeit der Werte 1, 2, \dots 6 nähert sich an Verteilung in GG (Gleichverteilung) an („Gesetz der großen Zahl“)
- ▶ 1 000 Wiederholungen



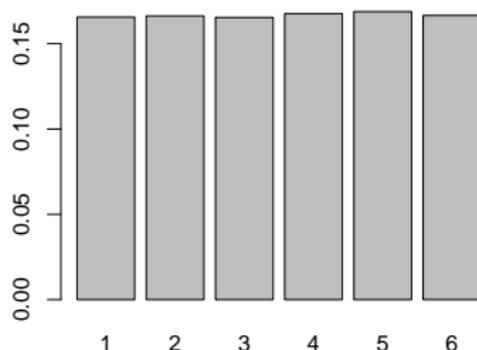
Einfaches Zufallsexperiment: $n = 1$

- ▶ Würfel einmal werfen ($n = 1$), Ergebnis notieren
- ▶ Experiment sehr oft wiederholen
- ▶ Häufigkeit der Werte 1, 2, \dots 6 nähert sich an Verteilung in GG (Gleichverteilung) an („Gesetz der großen Zahl“)
- ▶ 10 000 Wiederholungen

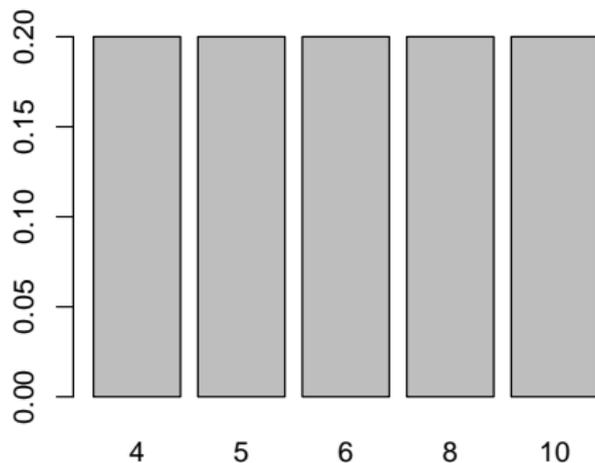


Einfaches Zufallsexperiment: $n = 1$

- ▶ Würfel einmal werfen ($n = 1$), Ergebnis notieren
- ▶ Experiment sehr oft wiederholen
- ▶ Häufigkeit der Werte 1, 2, \dots 6 nähert sich an Verteilung in GG (Gleichverteilung) an („Gesetz der großen Zahl“)
- ▶ 100 000 Wiederholungen

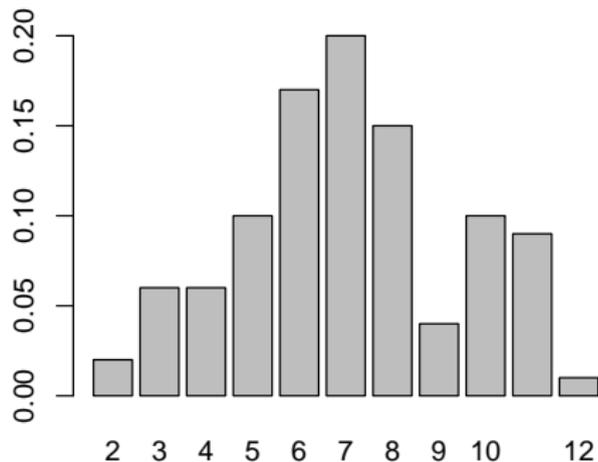


Komplexeres Zufallsexperiment: $n=2$



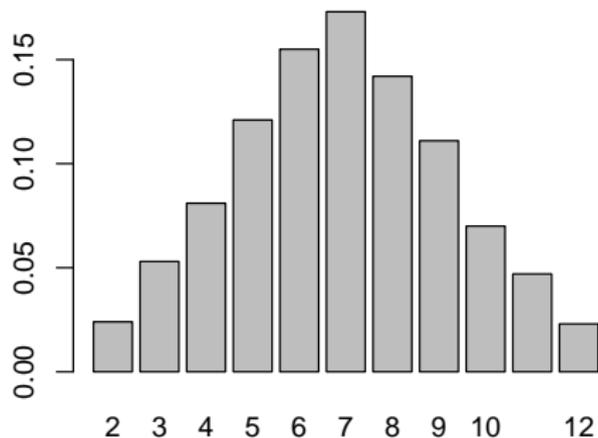
10 Wiederholungen

Komplexeres Zufallsexperiment: $n=2$



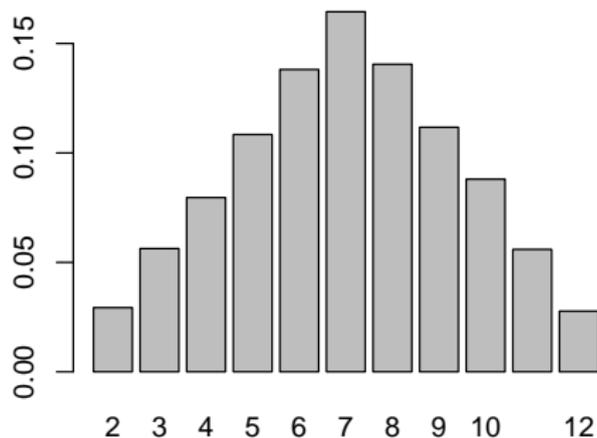
100 Wiederholungen

Komplexeres Zufallsexperiment: $n=2$



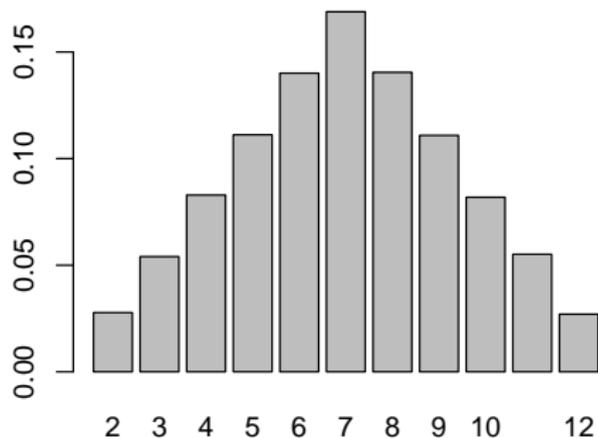
1 000 Wiederholungen

Komplexeres Zufallsexperiment: $n=2$



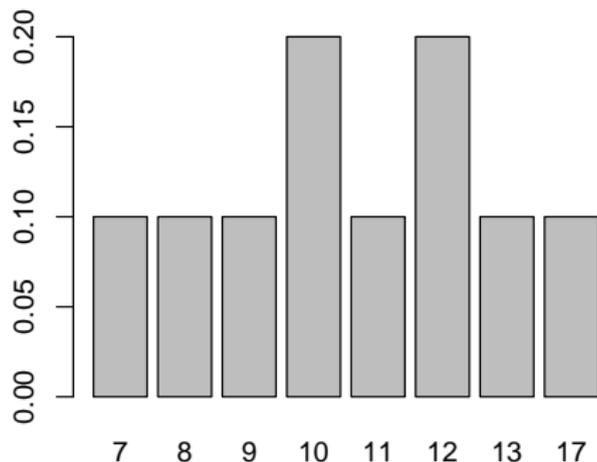
10 000 Wiederholungen

Komplexeres Zufallsexperiment: $n=2$



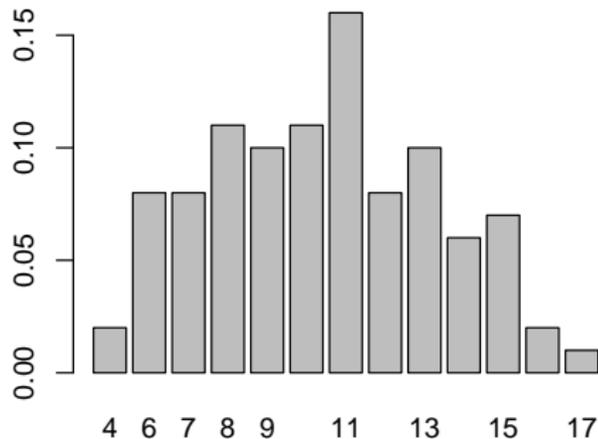
100 000 Wiederholungen

Komplexeres Zufallsexperiment: $n=3$



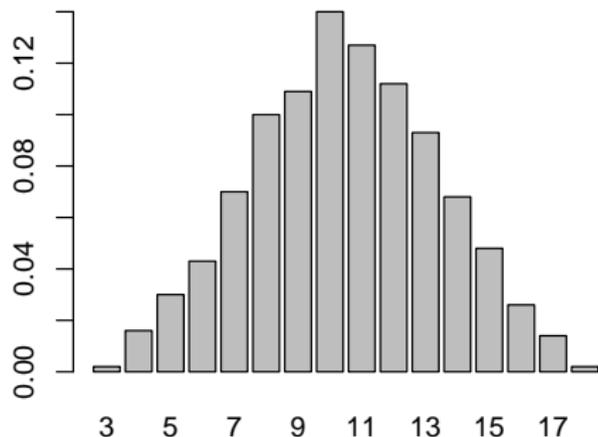
10 Wiederholungen

Komplexeres Zufallsexperiment: $n=3$



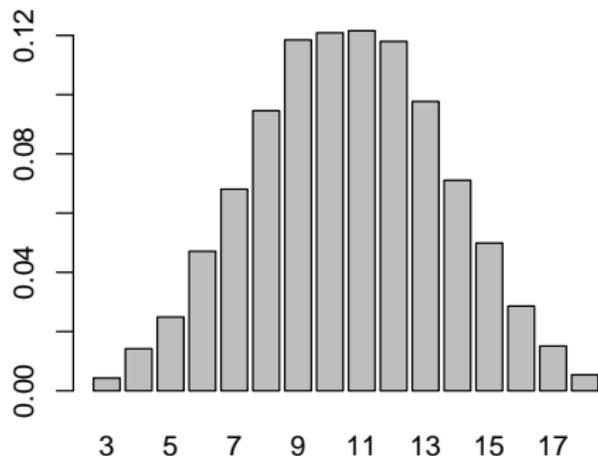
100 Wiederholungen

Komplexeres Zufallsexperiment: $n=3$



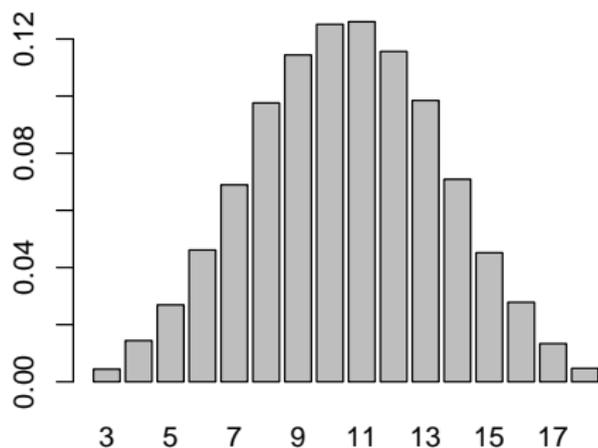
1 000 Wiederholungen

Komplexeres Zufallsexperiment: $n=3$



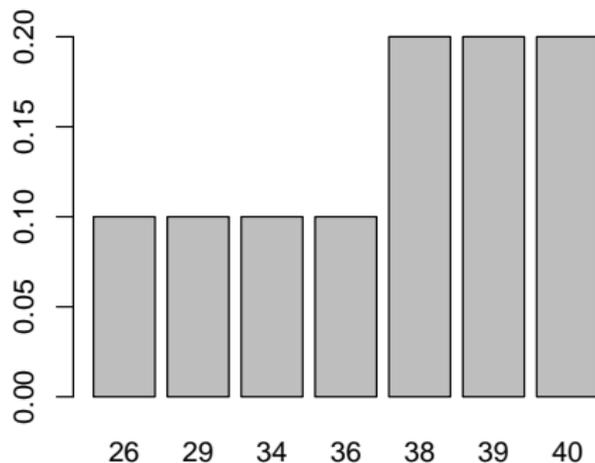
10 000 Wiederholungen

Komplexeres Zufallsexperiment: $n=3$



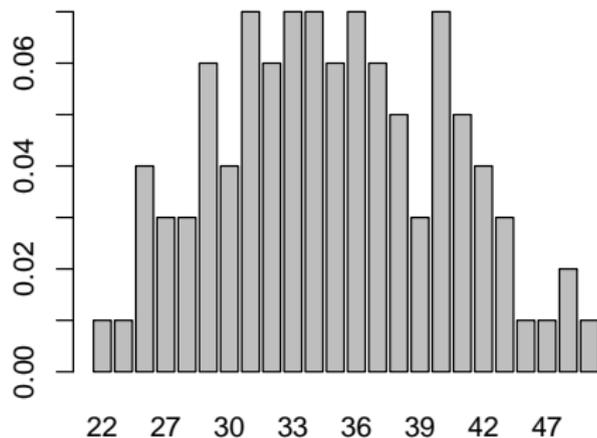
100 000 Wiederholungen

Komplexes Zufallsexperiment: $n=10$



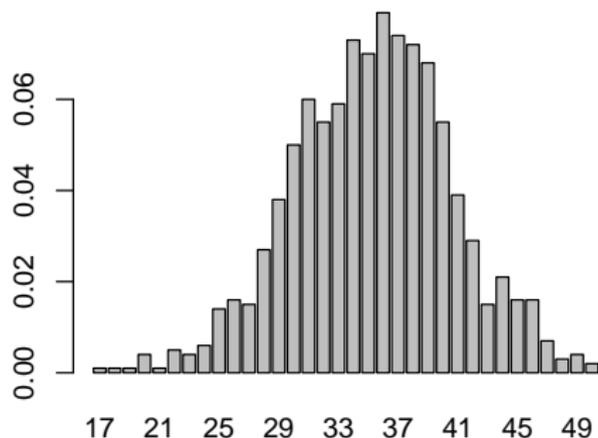
10 Wiederholungen

Komplexes Zufallsexperiment: $n=10$



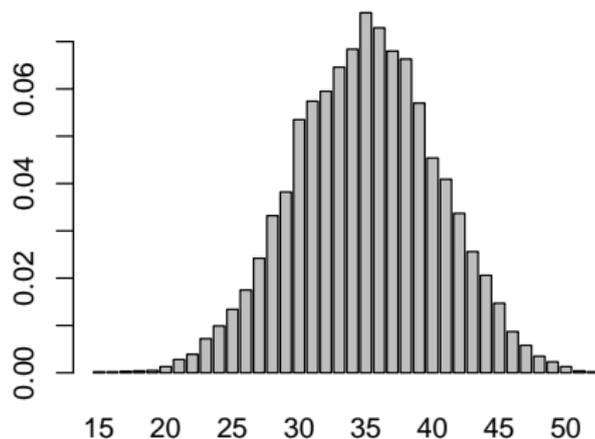
100 Wiederholungen

Komplexes Zufallsexperiment: $n=10$



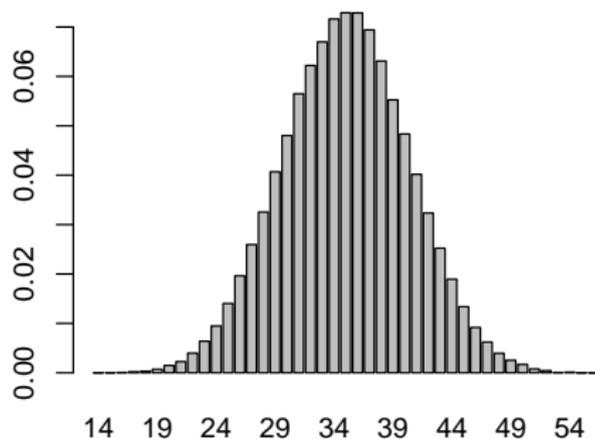
1 000 Wiederholungen

Komplexes Zufallsexperiment: $n=10$



10 000 Wiederholungen

Komplexes Zufallsexperiment: $n=10$



100 000 Wiederholungen

Zentraler Grenzwertsatz

- ▶ Stichprobenmittelwert: komplexe Zufallsvariable, additiv zusammengesetzt aus n einfachen Zufallsvariablen
- ▶ Verteilung der *Stichprobenmittelwerte* aus (theoretisch) unendlich vielen Stichproben nähert sich mit zunehmendem Stichprobenumfang an Normalverteilung an
- ▶ Mittelwert der Normalverteilung entspricht Mittelwert in GG (kein bias)
- ▶ Wenn $n > 30$, Normalverteilung brauchbare Approximation
- ▶ Unabhängig von Verteilung in GG/Stichproben

Zentraler Grenzwertsatz II

Variable	Verteilung
Ausgangsvariable in GG, z. B. Alter	z. B. linkssteil
Alter <i>eines</i> Befragten: einfache Zufallsvariable	wie in GG (linkssteil)
Arithmetisches Mittel des Alters: komplexe Zufallsvariable	normalverteilt <i>über viele mögliche Stichproben</i>

Berechnung des Standardfehlers

Standardfehler

$$\sigma_{\bar{x}} = \frac{\sigma}{\sqrt{n}} = \sqrt{\frac{\sigma^2}{n}}$$

- ▶ Je größer Streuung in GG, desto größer Standardfehler
- ▶ Je kleiner Stichprobenumfang, desto größer Standardfehler
- ▶ Umgekehrt quadratischer Zusammenhang:
Um Standardfehler zu halbieren muß Stichprobenumfang vervierfacht werden

Eigenschaften der Normalverteilung

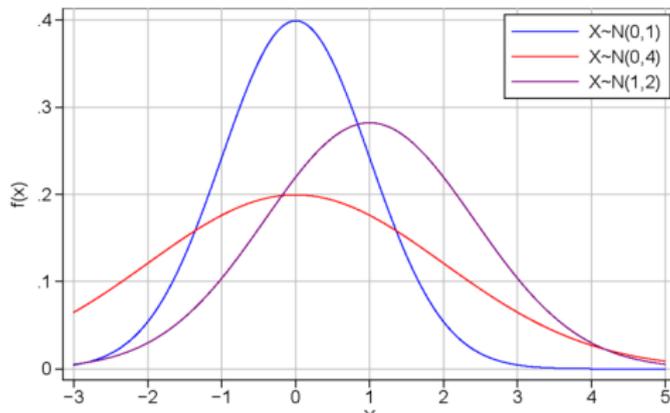
- ▶ Familie; gleiche Form, aber unterschiedliche Lage/Breite (Mittelwert/Streuung)
- ▶ Für alle Normalverteilungen
 - ▶ Ca. 68% der Fläche über Intervall ± 1 Standardabweichung um Mittelwert
 - ▶ Ca. 95% der Fläche über Intervall ± 1.96 Standardabweichungen um Mittelwert
- ▶ „Standardnormalverteilung“ (z-Verteilung): Mittelwert = 0, Standardabweichung/Varianz=1 \rightarrow Fläche unter Kurve tabelliert
- ▶ Tabelle für alle Normalverteilungen anwendbar (z-Transformation)
- ▶ Viele andere Zufallsverteilungen gehen für große n in Normalverteilung über

Eigenschaften der Normalverteilung II

Dichtefunktion

$$f(x) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{1}{2}\left(\frac{x-\mu}{\sigma}\right)^2}$$

- ▶ e Eulersche Zahl: 2.718...
- ▶ π : 3.142...
- ▶ μ : Mittelwert der Verteilung
- ▶ σ : Standardabweichung der Verteilung

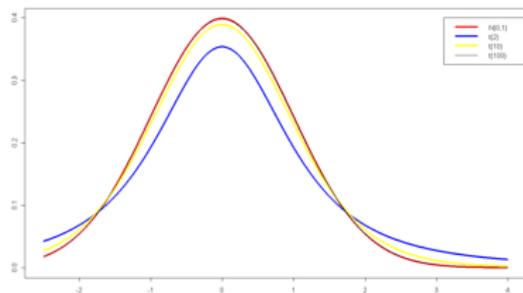


Konfidenzintervalle

- ▶ In 95% aller Stichproben ist Stichprobenmittelwert nicht weiter als 1.96 Standardfehler vom wahren Mittelwert entfernt
- ▶ Intervall von 1.96 Standardfehlern um Stichprobenmittelwert schließt in 95% der Fälle wahren Mittelwert in GG mit ein
- ▶ Intervallschätzung

Konfidenzintervalle II

- ▶ Stichprobenmittelwerte nicht standardnormal-, sondern normalverteilt (z-Transformation umkehren)
- ▶ Streuung in GG muß nach bekannter Formel aus Streuung in Stichprobe geschätzt werden → doppelte Unsicherheit
- ▶ t-Verteilung (größere Wahrscheinlichkeit für extreme Werte, Freiheitsgrade)
- ▶ Geht bei großen Fallzahlen in Normalverteilung über



Konfidenzintervalle III

- ▶ Wahrscheinlichkeit, daß Intervall wahren Wert **nicht** einschließt: Irrtumswahrscheinlichkeit, α
- ▶ Wahrscheinlichkeit, daß Intervall wahren Wert einschließt: Vertrauenswahrscheinlichkeit $1 - \alpha$, manchmal γ genannt
- ▶ In der Forschungspraxis meistens Vertrauenswahrscheinlichkeiten von 95% oder 99%
 - ▶ Symmetrisches Intervall aus (Standard)Normalverteilung
 - ▶ „Kritische Werte“ ± 1.96 ; ± 2.58

Beispiel: LRS in Schweden

- ▶ $\bar{x} = 5.822$; $\sigma = \hat{2}.393$; $n = 1891$; gesucht: 90%
Konfidenzintervall

Beispiel: LRS in Schweden

- ▶ $\bar{x} = 5.822$; $\sigma = \hat{2}.393$; $n = 1891$; gesucht: 90%
Konfidenzintervall
- ▶ Standardfehler berechnen: $\sigma_{\bar{x}} = \frac{\sigma}{\sqrt{n}} = \frac{2.393}{\sqrt{1891}} = 0.055$

Beispiel: LRS in Schweden

- ▶ $\bar{x} = 5.822$; $\sigma = \hat{2}.393$; $n = 1891$; gesucht: 90%
Konfidenzintervall
- ▶ Standardfehler berechnen: $\sigma_{\bar{x}} = \frac{\sigma}{\sqrt{n}} = \frac{2.393}{\sqrt{1891}} = 0.055$
- ▶ „Kritischen Wert“ suchen

Beispiel: LRS in Schweden

- ▶ $\bar{x} = 5.822$; $\sigma = \hat{2}.393$; $n = 1891$; gesucht: 90%
Konfidenzintervall
- ▶ Standardfehler berechnen: $\sigma_{\bar{x}} = \frac{\sigma}{\sqrt{n}} = \frac{2.393}{\sqrt{1891}} = 0.055$
- ▶ „Kritischen Wert“ suchen
 - ▶ $n > 1000 \rightarrow$ Normalverteilung als Approximation für
t-Verteilung

Beispiel: LRS in Schweden

- ▶ $\bar{x} = 5.822$; $\sigma = \hat{2}.393$; $n = 1891$; gesucht: 90% Konfidenzintervall
- ▶ Standardfehler berechnen: $\sigma_{\bar{x}} = \frac{\sigma}{\sqrt{n}} = \frac{2.393}{\sqrt{1891}} = 0.055$
- ▶ „Kritischen Wert“ suchen
 - ▶ $n > 1000 \rightarrow$ Normalverteilung als Approximation für t-Verteilung
 - ▶ In Normalverteilungstabelle Wert finden, der links und rechts 5% der Fläche abtrennt

Beispiel: LRS in Schweden

- ▶ $\bar{x} = 5.822$; $\sigma = \hat{2}.393$; $n = 1891$; gesucht: 90% Konfidenzintervall
- ▶ Standardfehler berechnen: $\sigma_{\bar{x}} = \frac{\sigma}{\sqrt{n}} = \frac{2.393}{\sqrt{1891}} = 0.055$
- ▶ „Kritischen Wert“ suchen
 - ▶ $n > 1000 \rightarrow$ Normalverteilung als Approximation für t-Verteilung
 - ▶ In Normalverteilungstabelle Wert finden, der links und rechts 5% der Fläche abtrennt
 - ▶ $\pm 1.644 \rightarrow$ 5% der Fläche über Intervall $[-\infty; -1.644]$ + 5% der Fläche über Intervall $[1.644; +\infty]$

Beispiel: LRS in Schweden

- ▶ $\bar{x} = 5.822$; $\sigma = \hat{2}.393$; $n = 1891$; gesucht: 90% Konfidenzintervall
- ▶ Standardfehler berechnen: $\sigma_{\bar{x}} = \frac{\sigma}{\sqrt{n}} = \frac{2.393}{\sqrt{1891}} = 0.055$
- ▶ „Kritischen Wert“ suchen
 - ▶ $n > 1000 \rightarrow$ Normalverteilung als Approximation für t-Verteilung
 - ▶ In Normalverteilungstabelle Wert finden, der links und rechts 5% der Fläche abtrennt
 - ▶ $\pm 1.644 \rightarrow$ 5% der Fläche über Intervall $[-\infty; -1.644]$ + 5% der Fläche über Intervall $[1.644; +\infty]$
- ▶ Konfidenzintervall:
 $5.822 \pm 1.644 \times 0.055 = 5.822 \pm 0.09 = [5.732; 5.912]$

Konfidenzintervalle für Anteilswerte

- ▶ Vorgehensweise im Grunde identisch
- ▶ Verteilung von Anteilswerten binomial
- ▶ Kann durch Normalverteilung approximiert werden wenn $n \times p \times (p - 1) \geq 9$
- ▶ Varianz von Anteilswerten: $p \times (p - 1)$
 - ▶ Zwei Ausprägungen gleich häufig ($p = 0.5$) \rightarrow extreme Heterogenität
 - ▶ Je geringer Anteil eines Merkmales, desto homogener
 - ▶ Keine Varianz wenn $p = 1$
- ▶ Konfidenzintervalle können für relative Häufigkeiten oder Prozente berechnet werden

Beispiel: Wahre Wahlabsicht für FDP

- ▶ Umfrage mit $n = 1221$: 7.3% (=0.073) würden FDP wählen
- ▶ 95% Konfidenzintervall?
- ▶ $1221 \times 0.073 \times (1 - 0.073) = 82.63 (> 9)$
- ▶ Standardfehler: $\sigma_p = \sqrt{\frac{92.7\% \times 7.3\%}{1221}} = 0.744\%$
- ▶ „Kritischer Wert“: 1.96
- ▶ Konfidenzintervall: $7.3\% \pm 1.96 \times 0.744\% = [5.84\%; 8.76\%]$
- ▶ Alternativ: mit relativen Häufigkeiten rechnen

Logik Konfidenzintervall

- ▶ Über sehr viele Stichprobenziehungen hinweg Normalverteilung der Stichprobenkennwerte um wahren Wert in GG mit Streuung = Standardfehler
- ▶ 95% aller Stichprobenkennwerte nicht weiter als ± 1.96 Standardfehler vom wahren Mittelwert entfernt
- ▶ Intervall von ± 1.96 Standardfehlern um Stichprobenmittelwert wird in 95% aller Fälle wahren Mittelwert einschließen
- ▶ Habe ich persönlich eine der vielen (relativ) guten Stichproben?

Logik Standardnormalverteilung

- ▶ Standardnormalverteilung (z-Verteilung): Mittelwert: 0; Varianz/Standardabweichung: 1
- ▶ 95% aller Werte im Intervall ± 1.96
- ▶ Alle Normalverteilungen haben gleiche Form
- ▶ 95% der Werte innerhalb von ± 1.96 Standardfehler ($>$ oder $<$ 1) um jeweiligen Mittelwert

Zusammenfassung

- ▶ Inferenzstatistik – Schluß von Stichproben auf GG
- ▶ Funktioniert nur für Zufallsstichproben
- ▶ Modell für zufällige Abweichungen der Stichprobenkennwerte vom wahren Mittelwert in GG
- ▶ Konfidenzintervall: Bereich, der mit gewünschter Sicherheit wahren Wert einschließt
- ▶ Nächste Woche: Hypothesentests:
 - ▶ Agresti/Finlay: Kapitel 6+7
 - ▶ Gehring/Weins: Kapitel 12
 - ▶ (Schumann: Kapitel 7.3)