

Stichprobenverteilungen in der Statistik mittels simulierter Wahlumfragen

Marloes Maathuis
ETH Zürich

Lernziele

- Das Verstehen folgender Konzepte der Statistik:
 - Population, Parameter
 - Stichprobe, Parameterschätzung, Stichprobenverteilung
- Wichtig für:
 - Berechnung der Stichprobengrösse
 - Tests
 - Vertrauensintervalle

Anwendung Wahlumfragen

- Warum?
 - Immer aktuelle Beispiele
 - Einfache diskrete Verteilung
 - “Statistical literacy”
- Referenz: A.F. Gourgey (2000), “A Classroom Simulation Based on Political Polling To Help Students Understand Sampling Distributions”, *Journal of Statistics Education* v.8, n.3.
<http://www.amstat.org/publications/JSE/secure/v8n3/gourgey.cfm>

Ablauf

- Referendum in Griechenland
- Hands-on Übung + Computersimulation
- Diskussion der Stichprobenverteilung
- Zurück zum Referendum in Griechenland
- Fragen + Diskussion

Wahlumfragen Sparmassnahmen Griechenland

- Vorhersagen am 4./5. Juli:
 - Ja: 48.5% ± 2.5%
 - Ja: 48.5% ± 2.0%
 - Ja: 48.0% ± 2.5%
 - ...



- Warum sind die Vorhersagen leicht unterschiedlich?
- Wie interpretieren wir solche Vorhersagen?

Vereinfachungen

- In der Wirklichkeit:
 - wissen wir nicht genau wer abstimmen wird
 - gibt es Personen die unentschieden sind oder ihre Meinung noch ändern werden
 - macht nicht jede Person die angefragt wird mit
 - antworten Personen nicht immer ehrlich
- Vereinfachungen:
 - wir kennen die Population
 - jede Person weiss schon was er/sie stimmen wird
 - jede Person die wir anfragen macht mit
 - jede Person antwortet ehrlich

⇒ Bügelperlen

Bügelperlen als Modell

- Wir haben eine (grosse/unendliche) Population mit $p = \text{Prozentsatz blaue Perlen}$
- Wir möchten den Wert von p wissen.
Insbesondere: gilt $p > 50\%$ oder $p < 50\%$??
- Simulierte Wahlumfrage:
 - Wir ziehen eine zufällige Stichprobe der Grösse $n = 10$
 - Wir rechnen den Prozentsatz blau (\hat{p}) in der Stichprobe.
 \hat{p} ist der Parameterschätzer.
 - Was können wir daraus schliessen?

Hands-on Übung

- 4 Gruppen
- Jede Gruppe hat eine Kopie der Population
- Vorgehen (etwa 20 mal):
 1. Ziehen Sie eine zufällige Stichprobe der Grösse $n = 10$ und notieren Sie den Prozentsatz blau (\hat{p})
 2. Legen Sie die Perlen zurück, mischen Sie sie zusammen und wiederholen Sie Punkt 1
- Wir visualisieren die Resultate

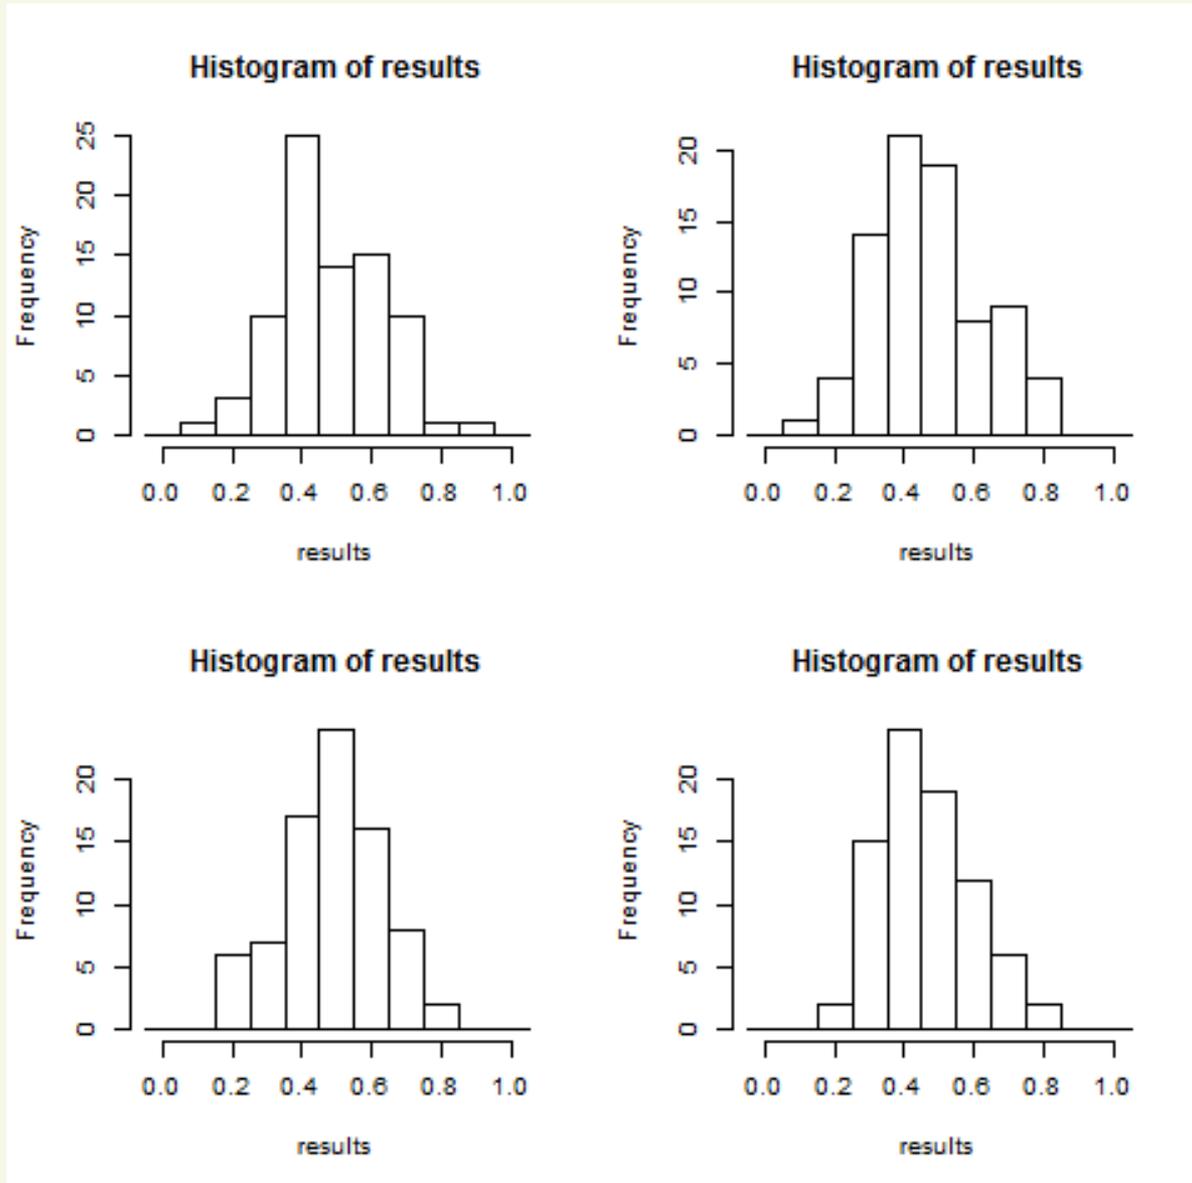
Computersimulationen mit R

```
# Parameters für die Simulation
npop      <- 2000      # Populationsumfang
p         <- 0.48      # Populationsparameter (% 1s)
nsimul    <- 80        # Anzahl Stichproben
nsample   <- 10        # Stichprobenumfang

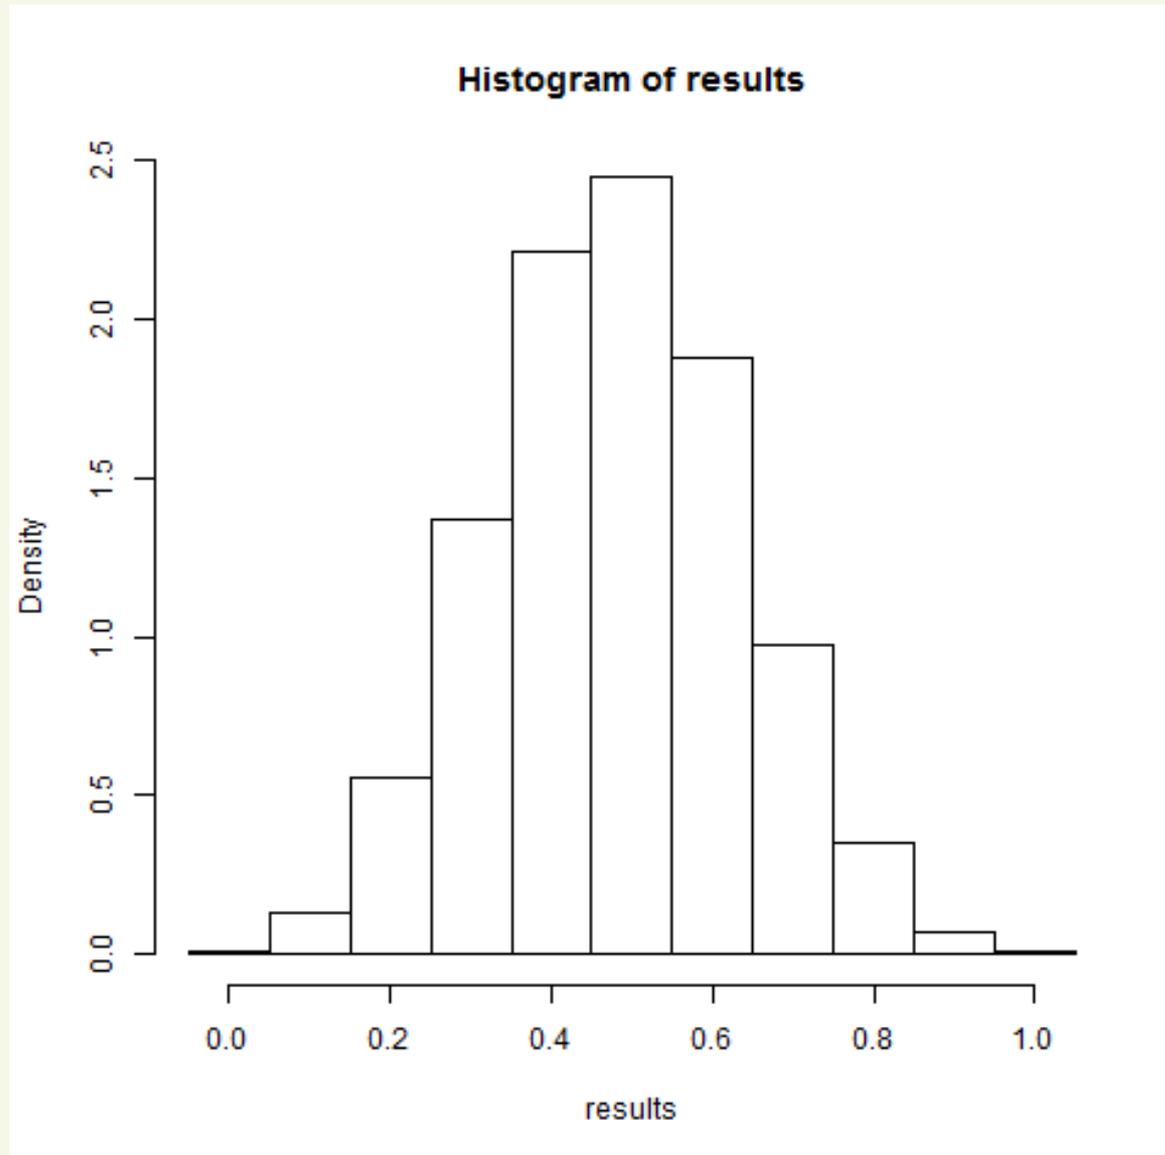
# Die Population
population <- c(rep(1, npop*p), rep(0, npop*(1-p)))

# Simulation
results <- rep(NA, nsimul)
for (i in 1:nsimul){
  sample <- sample(population, nsample, replace=F)
  results[i] <- sum(sample)/nsample
}
```

Simulierte Stichprobenverteilungen, n_{simul}=80, n_{sample}=10



Simulierte Stichprobenverteilung, nsimul=100000, nsample=10



Was sehen wir?

- $p \neq \hat{p}$
- p ist unbekannt, aber fix
- \hat{p} kann man berechnen, ist aber zufällig:
es ändert sich von Stichprobe zu Stichprobe

\hat{p} hat eine Verteilung.

Können wir die Verteilung analysieren?

Analyse der Stichprobenverteilung

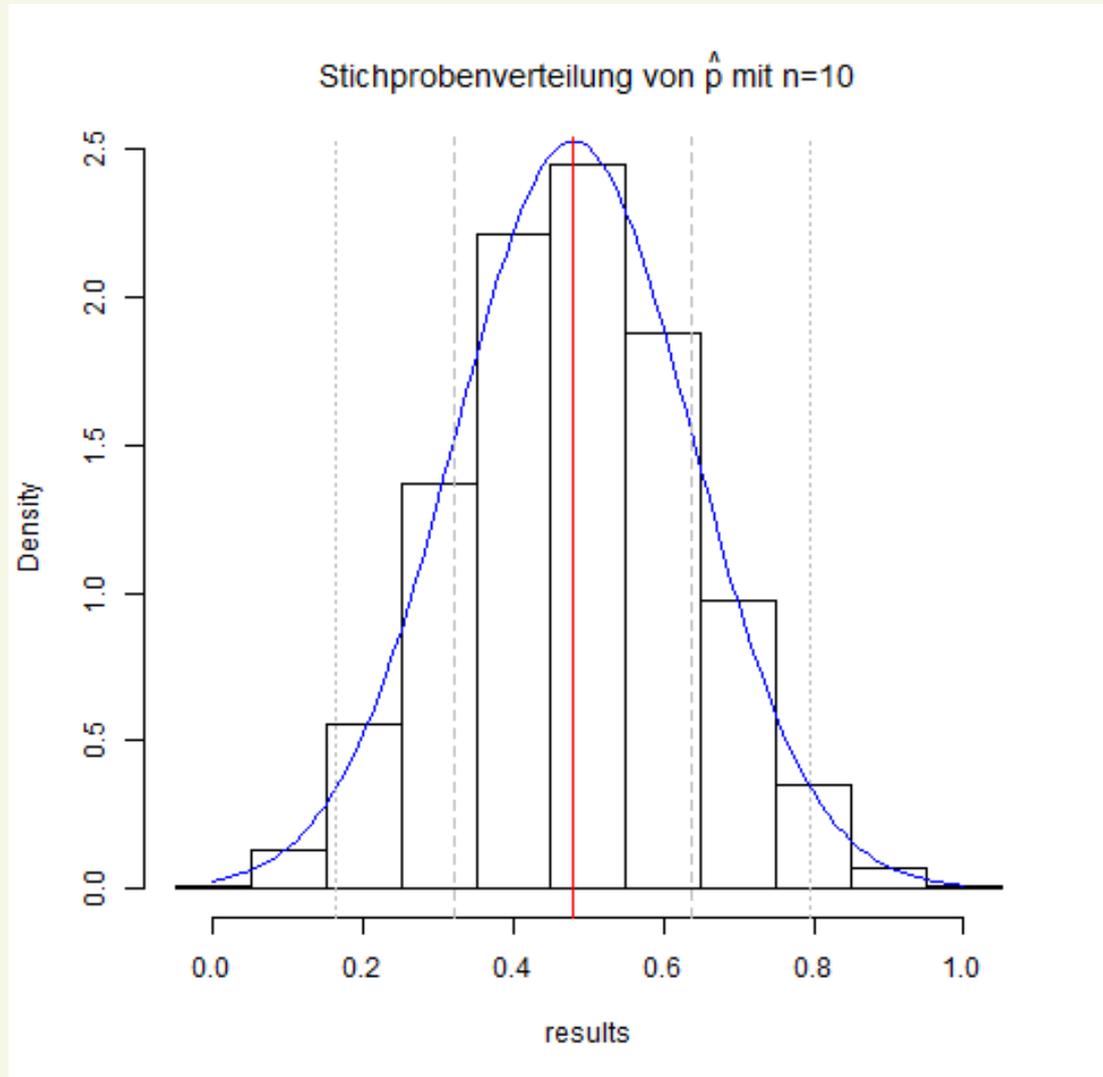
- $X = \# \text{blau in der Stichprobe}, \quad \hat{p} = X/n$
- $X \sim \text{Binom}(n, p)$
- $E(X) = np, \quad \text{Var}(X) = np(1-p)$
- $E(\hat{p}) = E\left(\frac{X}{n}\right) = \frac{1}{n}E(X) = p$
- $\text{Var}(\hat{p}) = \text{Var}\left(\frac{X}{n}\right) = \frac{1}{n^2}\text{Var}(X) = \frac{p(1-p)}{n}$
- Standardfehler $\sigma_{\hat{p}} = \sqrt{\frac{p(1-p)}{n}}; \quad \hat{\sigma}_{\hat{p}} = \sqrt{\frac{\hat{p}(1-\hat{p})}{n}}$
- Die verteilung von \hat{p} ist approximativ Normal (ZGWS)
- Bei etwa 66% der Stichproben ist \hat{p} im Intervall $p \pm \sigma_{\hat{p}}$
- Bei etwa 95% der Stichproben ist \hat{p} im Intervall $p \pm 2\sigma_{\hat{p}}$

Populationsverteilung versus Stichprobenverteilung

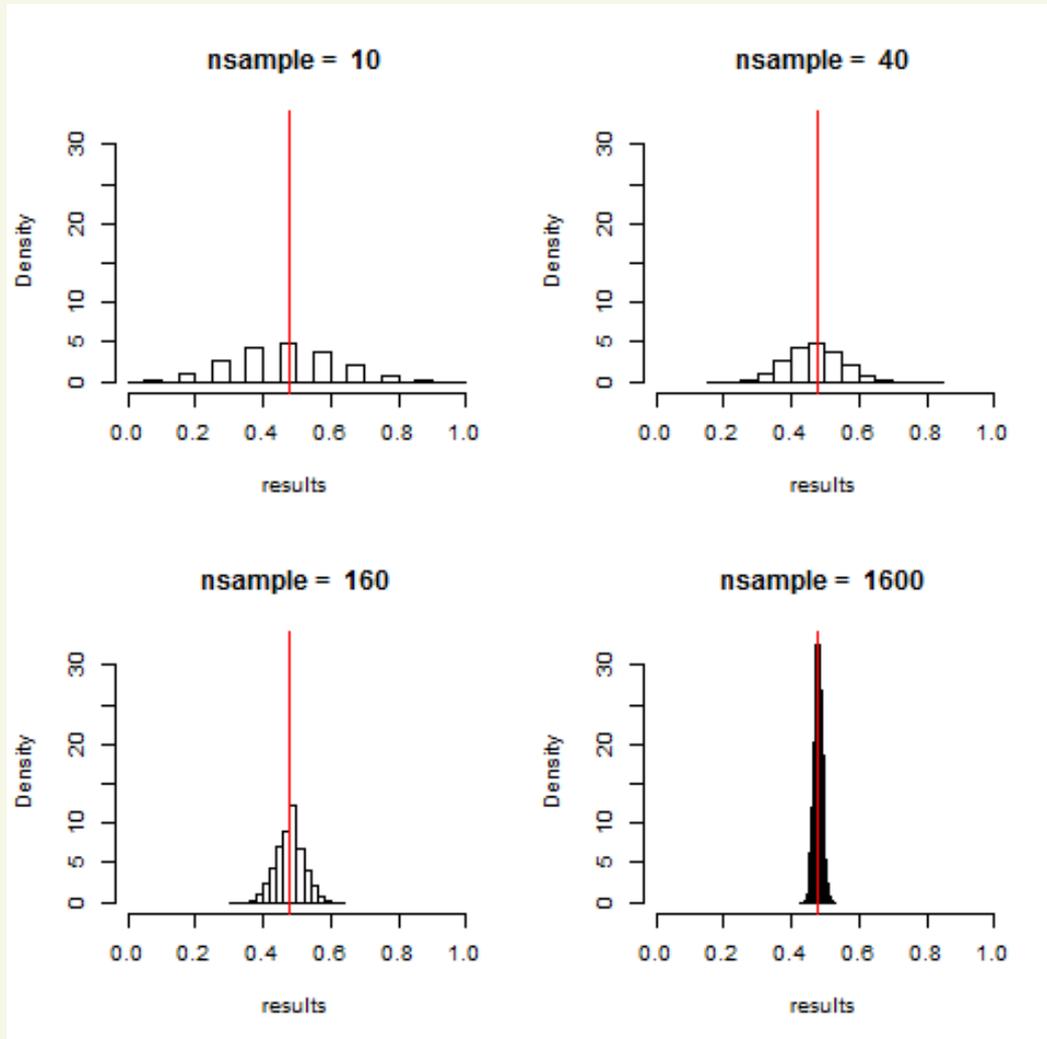
```
> table(population)
population
```

```
  0    1
1040  960
```

```
> p
[1] 0.48
```



Rolle des Stichprobenumfangs



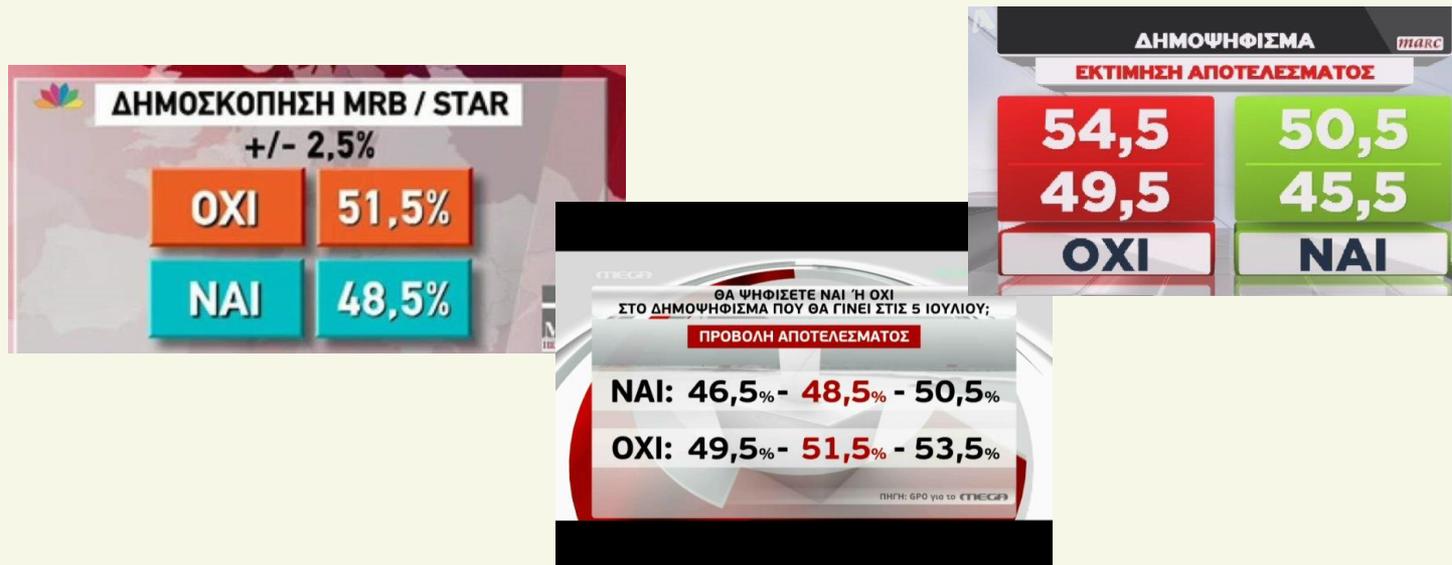
$n_{pop} = 20000$
 $n_{sample} = 10; 40; 160; 1600$
 $n_{simul} = 100000$

$$\sigma_{\hat{p}} = \sqrt{\frac{p(1-p)}{n}}$$

n vier mal so gross \Rightarrow
 \hat{p} zwei mal so genau

Zurück zur Abstimmung in Griechenland

- Die Vorhersagen sind gegeben als $\hat{p} \pm 2 \hat{\sigma}_{\hat{p}}$.
Diese sind 95% Vertrauensintervalle für p .

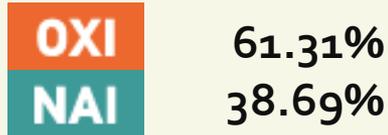


- Wir können n bestimmen:

$$\hat{\sigma}_{\hat{p}} \approx 1.25\% \Rightarrow \sqrt{\frac{0.5 * 0.5}{n}} \approx 1.25\% \Rightarrow n \approx 1600$$

Resultate Griechenland

- Die Resultate...



- In der Wirklichkeit:

- wissen wir nicht genau wer abstimmen wird
- gibt es Personen die unentschieden sind oder ihre Meinung noch ändern werden
- macht nicht jede Person die angefragt wird mit
- antworten Personen nicht immer ehrlich

Warum hands-on Übung?

- Hätten wir auch direkt Computersimulationen benutzen können?
- Ja, aber ich finde es schön zuerst die hands-on Übung zu machen:
 - Es ist konkreter. Man sieht wirklich, dass \hat{p} zufällig ist.
 - Man merkt es sich besser (?)
 - Man kann die Computersimulation nachher hoffentlich besser verstehen

Mehr Material (I)

- The power of random sampling:
 - Chapter 19 of “Basic Statistics” by Freedman, Pisani and Purves
- Hands-on Experience with Sampling Distributions of the Sample Mean and Sample Proportion
 - Election polls:

<http://www.amstat.org/publications/JSE/secure/v8n3/gourgey.cfm>
 - Dice and pennies:
https://www.causeweb.org/repository/StarLibrary/activities/andrews_2003/
 - M&Ms:
<http://www.amstat.org/education/stew/pdfs/populationparameterswithmms.pdf>

Mehr Material (II)

- Applet:
 - http://onlinestatbook.com/stat_sim/sampling_dist/index.html
- A story-based simulation for teaching sampling distributions:
 - Paper: <http://onlinelibrary.wiley.com/doi/10.1111/test.12067/full>
 - Video: <https://www.youtube.com/channel/UC-E1qTmBlpOoHXJcbuhzqdw>
- Open source statistical software R:
 - <https://cran.r-project.org/>

Fragen und Diskussion

