

# Mathematik für Biologen

Prof. Dr. Rüdiger W. Braun

Heinrich-Heine-Universität Düsseldorf

9. Dezember 2010

## 1 Konfidenzintervalle

- Idee
- Schätzung eines Konfidenzintervalls mit der 3-sigma-Regel
- Grundlagen
- Quantile
- Einseitige Konfidenzintervalle
- Tabelle: Konfidenzintervalle bei bekannter Varianz

# Idee

- Parameterschätzungen geben keine Auskunft über ihre Genauigkeit
- Jeder Schätzer ist selbst eine Zufallsvariable
- Alternative: Intervallschätzung
- Es gibt in der Regel kein Intervall, in welchem der zu schätzende Parameter mit Sicherheit liegt
- Eine Irrtumswahrscheinlichkeit  $\alpha$  muss vorgegeben werden
- $1 - \alpha$  heißt dann *Konfidenzniveau*
- Bei der Schätzung eines Konfidenzintervalls sind die Randpunkte selber Zufallsvariable

# Intervalle

- Für Zahlen  $a \leq b$  ist

$$[a, b] = \{x \mid a \leq x \leq b\}$$

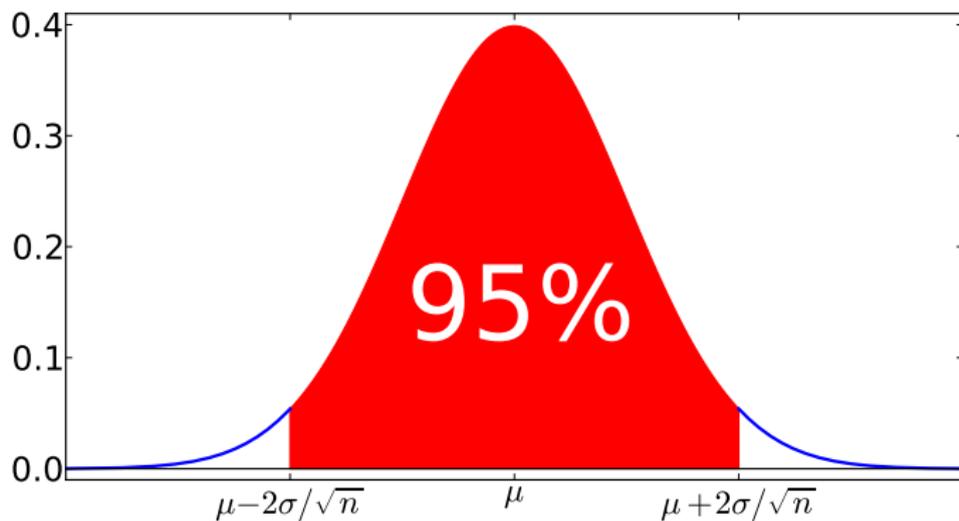
das (abgeschlossene) Intervall mit den Randpunkten  $a$  und  $b$

- Spezialfälle

$$(-\infty, b] = \{x \mid x \leq b\}$$

$$[a, \infty) = \{x \mid x \geq a\}$$

# $3\sigma$ -Regel



# Schätzung eines Konfidenzintervalls für den Erwartungswert bei bekannter Varianz mittels der $3\sigma$ -Regel

- $X_1, \dots, X_n$  seien normalverteilt gemäß  $N(\mu, \sigma^2)$  für bekanntes  $\sigma$  und unbekanntes  $\mu$
- Für  $\mu$  soll ein Konfidenzintervall zum Konfidenzniveau 95% geschätzt werden.
- Verwende dazu das arithmetische Mittel

$$\bar{X} = \frac{1}{n}(X_1 + \dots + X_n)$$

- $3\sigma$ -Regel

$$P\left(\mu - \frac{2\sigma}{\sqrt{n}} \leq \bar{X} \leq \mu + \frac{2\sigma}{\sqrt{n}}\right) = 0.95$$

- Beachte die Gleichwertigkeit der Ungleichungen

$$\bar{X} \leq \mu + \frac{2\sigma}{\sqrt{n}} \quad \text{und} \quad \mu \geq \bar{X} - \frac{2\sigma}{\sqrt{n}}$$

# Schätzung eines Konfidenzintervalls für den Erwartungswert bei bekannter Varianz, Fortsetzung

- Damit sieht die  $3\sigma$ -Regel so aus

$$P\left(\bar{X} - \frac{2\sigma}{\sqrt{n}} \leq \mu \leq \bar{X} + \frac{2\sigma}{\sqrt{n}}\right) = 0.95$$

- Also ist folgendes Intervall ein Konfidenzintervall zum Konfidenzniveau 95%

$$\left[\bar{X} - \frac{2\sigma}{\sqrt{n}}, \bar{X} + \frac{2\sigma}{\sqrt{n}}\right]$$

## Beispiel: Roggenpflanzen

- Gesunde Roggenpflanzen einer bestimmten Art sind im Mittel  $102.5\text{ cm}$  lang, wobei die Länge um  $7\text{ cm}$  streut. Die Länge sei normalverteilt
- Durch Umwelteinflüsse änderte sich die mittlere Halmlänge, die Streuung aber nicht
- Die folgenden Längen wurden gemessen

96.62	94.91	85.05	101.61	109.55
93.05	97.86	96.66	95.08	98.87

- Arithmetisches Mittel der Daten

$$\bar{x} = 96.93$$

## Roggenpflanzen, Fortsetzung

- $\frac{2\sigma}{\sqrt{n}} = \frac{14}{\sqrt{10}} = 4.43$
- Also ergibt sich das folgende Konfidenzintervall zum Konfidenzniveau 95%

[92.50, 101.36]

# Interpretation

- Die Frage:

*Mit welcher Wahrscheinlichkeit liegt  $\mu$  zwischen 92.50 und 101.36?*

macht keinen Sinn

- $\mu$  ist der wahre Wert, also nicht zufallsbehaftet
- "Konfidenzniveau  $1 - \alpha = 0.95$ " bedeutet

*Das verwendete Verfahren wird in 95 von 100 Fällen das richtige Ergebnis liefern*

# Definition

- Es sei  $\Theta$  eine Menge von Parameterwerten. Zu jedem Parameterwert  $\theta \in \Theta$  gebe es eine Verteilung  $P_\theta$
- Von der Zufallsvariablen  $X$  sei bekannt, dass ihre Verteilung gleich einem der  $P_\theta$  ist. Für dieses  $\theta$  soll ein Konfidenzintervall geschätzt werden
- Ein Intervall  $[G_u, G_o]$  mit der Eigenschaft

$$P_\theta(G_u \leq \theta \leq G_o) = 1 - \alpha$$

heißt *Konfidenzintervall* für den Parameter  $\theta$  zum Konfidenzniveau  $1 - \alpha$

- Übliche Konfidenzniveaus sind 90%, 95% und 99%
- $G_u$  und  $G_o$  sind Zufallsvariable. Man bezeichnet sie als untere und obere *Vertrauensgrenze*

## Zurück zum Beispiel

Das Konfidenzintervall zum Konfidenzniveau 95% für den Erwartungswert einer normalverteilten Zufallsvariable mit bekannter Varianz  $\sigma^2$  ist

$$[G_u, G_o]$$

mit

$$G_u = \bar{X} - \frac{2\sigma}{\sqrt{n}} \quad G_o = \bar{X} + \frac{2\sigma}{\sqrt{n}}$$

Dabei ist  $n$  der Stichprobenumfang

# Quantile

- $\Phi$  die Verteilungsfunktion der Standardnormalverteilung
- Die Zahl  $q_\alpha$  mit  $\Phi(q_\alpha) = \alpha$  heißt  $\alpha$ -Quantil der Standardnormalverteilung. Die wichtigsten Quantile der Standardnormalverteilung sind tabelliert

$\Phi(u)$	70%	80%	90%	95%	97.5%	99%	99.5%
$u$	0.524	0.842	1.282	1.645	1.960	2.326	2.576

- Z. B. ist das 0.975-Quantil gleich 1.960, also näherungsweise gleich 2
- Umrechnungsformel

$$q_\alpha = -q_{1-\alpha}$$

- Beispiel

$$q_{0.05} = -q_{0.95} = -1.645$$

# Einseitige Konfidenzintervalle

- Bei einigen Fragestellungen ist statt eines Intervalls nur eine obere oder eine untere Vertrauensgrenze für den Erwartungswert von Interesse
- Variation des Beispiels der Roggenpflanzen: Schätze Intervall der Form

$$(-\infty, G_o]$$

- Bei gleichem Konfidenzniveau  $1 - \alpha$  ist  $G_o$  bei der Schätzung eines einseitigen Konfidenzintervalls etwas kleiner als bei einem zweiseitigen

# Schätzung eines einseitigen Konfidenzintervalls für den Erwartungswert bei bekannter Varianz

- $X_1, \dots, X_n$  seien normalverteilt gemäß  $N(\mu, \sigma^2)$  für bekanntes  $\sigma$  und unbekanntes  $\mu$
- Für  $\mu$  soll ein einseitiges Konfidenzintervall  $(-\infty, G_o]$  zum Konfidenzniveau  $1 - \alpha$  geschätzt werden
- Verwende dazu das arithmetische Mittel

$$\bar{X} = \frac{1}{n}(X_1 + \dots + X_n)$$

- Seine Standardisierung ist

$$Y = \frac{\sqrt{n}}{\sigma}(\bar{X} - \mu)$$

# Schätzung eines einseitigen Konfidenzintervalls für den Erwartungswert bei bekannter Varianz, Fortsetzung

- $q_{1-\alpha}$  sei das  $(1 - \alpha)$ -Quantil der Standardnormalverteilung
- $Y$  ist standardnormalverteilt, also

$$P(Y \geq -q_{1-\alpha}) = 1 - \Phi(-q_{1-\alpha}) = \Phi(q_{1-\alpha}) = 1 - \alpha$$

- Für  $\bar{X}$  heißt das

$$P\left(\frac{\sqrt{n}}{\sigma}(\bar{X} - \mu) \geq -q_{1-\alpha}\right) = 1 - \alpha$$

- Man stellt  $\mu$  frei

$$P\left(\mu \leq \bar{X} + \frac{\sigma \cdot q_{1-\alpha}}{\sqrt{n}}\right) = 1 - \alpha$$

- Das Konfidenzintervall ist  $\left(-\infty, \bar{X} + \frac{\sigma \cdot q_{1-\alpha}}{\sqrt{n}}\right]$

## Beispiel: Roggenpflanzen

- Zurück zu den Roggenpflanzen: Es soll nur noch untersucht werden, ob die Umwelteinflüsse die Halmlänge *verringern*
- Die Daten waren

$$\bar{x} = 96.93$$

$$\sigma = 7$$

$$n = 10$$

$$1 - \alpha = 0.95$$

- Das Quantil ist

$$q_{0.95} = 1.645$$

- Damit erhält man als obere Vertrauensgrenze für das einseitige Konfidenzintervall

$$\bar{x} + \frac{\sigma \cdot q_{1-\alpha}}{\sqrt{n}} = 96.93 + \frac{7 \cdot 1.645}{\sqrt{10}} = 100.57$$

- Zum Vergleich: Die obere Vertrauensgrenze des zweiseitigen Konfidenzintervalls zum selben Konfidenzniveau war 101.36

## Tabelle: Konfidenzintervall für den Erwartungswert bei bekannter Varianz

- zweiseitig zum Konfidenzniveau  $1 - \alpha$

$$\bar{X} - \frac{\sigma \cdot q_{1-\alpha/2}}{\sqrt{n}} \leq \mu \leq \bar{X} + \frac{\sigma \cdot q_{1-\alpha/2}}{\sqrt{n}}$$

- einseitig, obere Vertrauensgrenze zum Konfidenzniveau  $1 - \alpha$

$$\mu \leq \bar{X} + \frac{\sigma \cdot q_{1-\alpha}}{\sqrt{n}}$$

- einseitig, untere Vertrauensgrenze zum Konfidenzniveau  $1 - \alpha$

$$\bar{X} - \frac{\sigma \cdot q_{1-\alpha}}{\sqrt{n}} \leq \mu$$

# Wichtige Werte der Quantile

Beim zweiseitigen Konfidenzintervall wird  $q_{1-\alpha/2}$  verwendet

$1 - \alpha = 0.66$	$1 - \frac{\alpha}{2} = 0.83$	$q_{0.83} = 0.95 \cong 1$
$1 - \alpha = 0.95$	$1 - \frac{\alpha}{2} = 0.975$	$q_{0.975} = 1.96 \cong 2$
$1 - \alpha = 0.99$	$1 - \frac{\alpha}{2} = 0.995$	$q_{0.995} = 2.56 \cong 3$