

# Statistik für Digital Humanities

## Statistische Modelle

Dr. Jochen Tiepmar

Institut für Informatik  
Abteilung Computational Humanities  
**Universität Leipzig**

28. Oktober 2019

[Letzte Aktualisierung: 28/10/2019, 13:07]




# Agenda

- 1 Modellbildung
- 2 Sampling
- 3 Mittelwert als Modell
- 4 Testen


- Phänomene meistens nicht anhand der Realität erforschbar
  - Aufwand
  - Störfaktoren / Variablenisolierung
  - Wiederholbarkeit
- meist Forschung anhand von Auszügen der Realität (Modelle)
- Fitting eines Modells = Übertragbarkeit auf Realität (gut, moderat, schlecht)
- Schlechtes Fitting führt zu fehlerhaften und gefährlichen Schlüssen
- Zu genaues Fitting (Overfitting) führt zu Fehlschlüssen und mangelnder Wiederholbarkeit



Gut



Moderat



Schlecht



- Population = Alle Betroffenen / Grundgesamtheit
- Stichprobe (Sample) = Ausschnitt aus einer Population
- Stichprobenverteilung (Sampling Distribution) = Verteilung über alle Stichproben (Schätzfunktion auf (unbekannte) Population)
- $n$  = Stichprobengröße,  $N$  = Populationsgröße,  $n_{group}$  = Gruppengröße
  - **Achtung:** Andy Field verwendet  $N$  für Stichprobengröße, aber sonst scheinbar kaum jemand
- Forschungsarbeit anhand Sample, anschließend (meist induktiver) Schluss auf gesamte Gruppe
- Je größer das Sample, desto wahrscheinlicher ist ein guter Fit
  - (→ Gesetz der großen Zahlen)
- Zusammensetzung des Samples von Experiment abhängig
  - für die Hypothese identifizierte Variablen sollten vorhanden sein
  - weitere Varianten sollten random-ish auftreten

Die folgenden Berechnungen können analog für andere Modelle angewendet werden, sind hier aber beispielhaft auf den Mittelwert bezogen

Arithmetisches Mittel  $\bar{x} = \frac{\sum(x_0, x_1, \dots, x_n)}{n}$

Beispiel Anzahl der Twitter Follower:  $X = \{22, 40, 53, 57\}$

- $\bar{x} = \frac{22+40+53+57}{4} = \underline{43}$



- Abweichung (deviance) =  $x_i - \bar{x}$
- Naiv: Abweichungen addieren =  $\sum(x_i - \bar{x})$

- Abweichung (deviance) =  $x_i - \bar{x}$
- Naiv: Abweichungen addieren =  $\sum(x_i - \bar{x})$ 
  - $X = \{22, 40, 53, 57\}$
  - $\bar{x} = 43$
  - Totaler Fehler =  $-21 + -3 + 10 + 14 = 0$  😞
- Halbgut: Quadratabweichungen addieren  $SS = \sum(x_i - \bar{x})^2$

- Abweichung (deviance) =  $x_i - \bar{x}$
- Naiv: Abweichungen addieren =  $\sum(x_i - \bar{x})$ 
  - $X = \{22, 40, 53, 57\}$
  - $\bar{x} = 43$
  - Totaler Fehler =  $-21 + -3 + 10 + 14 = 0$  😞
- Halbgut: Quadratabweichungen addieren  $SS = \sum(x_i - \bar{x})^2$ 
  - Sum of Squares steigt mit Stichprobengröße 😞
- Gut: SS mit Stichprobengröße normalisieren

**Varianz**  $s^2 = \frac{\sum(x_i - \bar{x})^2}{n-1}$

**Standardabweichung**  $s = \sqrt{s^2}$

- $n - 1$  gleicht stichprobenbezogenen statistischen Fehler bei  $\bar{x}$  (etwas) aus (Für genauere Informationen Siehe Freiheitsgrade bezogen auf Grundgesamtheit und Stichproben)

Beispiel Anzahl der Instagram Follower

- $X = \{22, 40, 53, 57\}$
- $\bar{x} = 43$

**Varianz**  $s^2 =$

Beispiel Anzahl der Instagram Follower

- $X = \{22, 40, 53, 57\}$
- $\bar{x} = 43$

**Varianz**  $s^2 = \frac{\sum(x_i - \bar{x})^2}{n-1} = \frac{(-21)^2 + (-3)^2 + 10^2 + 14^2}{3} = \frac{746}{3} = 248.67$

**Standardabweichung**  $s =$

Beispiel Anzahl der Instagram Follower

- $X = \{22, 40, 53, 57\}$
- $\bar{x} = 43$

**Varianz**  $s^2 = \frac{\sum(x_i - \bar{x})^2}{n-1} = \frac{(-21)^2 + (-3)^2 + 10^2 + 14^2}{3} = \frac{746}{3} = 248.67$

**Standardabweichung**  $s = \sqrt{s^2} = \sqrt{248.67} = 15.77$


- $Ergebnis = Modell + Fehler$
- $Abweichung = \sum (Beobachtung - Modell)^2$
- $s$  und  $s^2$  beschreiben statistischen Fehler des Modells, also das Ausmaß, in dem beispielsweise das Modell *mean* von den Daten der Stichprobe abweicht.

- Stichprobenvarianz: Gleiche Modelle ergeben verschiedene Ergebnisse bei verschiedenen Stichproben
- Ergebnisse verschiedener Samples unterliegen also einer Häufigkeitsverteilung, auch beim Modell *mean*
- für  $n > 30$  folgt *mean* einer Normalverteilung
- **Standardfehler**  $\sigma$  = Standardabweichungen aller möglichen Stichproben
  - Praktisch idR nicht berechenbar
- **Central Limit Theorem**  
if  $n > 30$ :  $\sigma \approx \frac{s}{\sqrt{n}}$
- $\sigma$  beschreibt den statistischen Fehler bezogen auf die Stichprobenverteilung



- Stichprobenverteilung oft nicht vollständig erfassbar
- → Abschätzung von Stichprobe auf Stichprobenverteilung
- **Central Limit Theorem**
- → Wenn Stichprobe tendenziell normalverteilt dann Stichprobenverteilung ebenfalls  
if  $n > 30$ :
  - $\sigma \approx \frac{s}{\sqrt{n}}$
  - $\bar{X}_{\text{Stichprobenverteilung}} \approx \bar{X}_{\text{population}}$
  - Stichprobenverteilung tendenziell normalverteilt

# Konfidenzintervall



- Normalverteilung erlaubt Abschätzen der Wahrscheinlichkeit des Auftretens von Werten
  - $\bar{x} = 0, s = 1$
- z-Score "transformiert" Werte zu entsprechender Normalverteilung
- $z = \frac{x - \bar{x}}{s}$
- Wahrscheinlichkeiten für Auftreten von  $x$  aus z-Score Tabelle ablesbar
- $z = 1.96$  entspricht 2.5% der höchsten Werte,  $z = -1.96$  2.5% der niedrigsten Werte
- 95% der Werte haben z-score zwischen -1.96 und 1.96

## Beispiel Anzahl der StudiVZ Freunde

- $X = \{22, 40, 53, 57\}$

$$\bar{x} = 43$$

$$s = \sqrt{s^2} = \sqrt{248.67} = 15.77$$

- Wie wahrscheinlich ist es, dass der nächste Wert mindestens 30 ist?

- $z = \frac{x - \bar{x}}{s} = \frac{30 - 43}{15.77} = -0.82$


z-Tabelle sagt .79389

$$P(x \geq 30) = 79,38\%$$

- Jedes Sample hat ein Konfidenzintervall bezogen auf ein Modell
- Höhe vorher festgelegt
- Meist 95% (manchmal 99%)
- Konfidenzintervalle von 95% der Samples enthalten den wahren Wert der Population
- Berechnung für 95%:  
Untergrenze =  $\bar{x} - (1.96 * \sigma)$   
Obergrenze =  $\bar{x} + (1.96 * \sigma)$


- Jedes Sample hat ein Konfidenzintervall bezogen auf ein Modell
- Höhe vorher festgelegt
- Meist 95% (manchmal 99%)
- Konfidenzintervalle von 95% der Samples enthalten den wahren Wert der Population
- Berechnung für 95%:  
Untergrenze =  $\bar{x} - (1.96 * \sigma)$   
Obergrenze =  $\bar{x} + (1.96 * \sigma)$   
 $\sigma$  = Standardfehler
- z-Score für 99%:  $\pm 2.58$
- Bei kleinen Stichproben ( $< 30$ ) t-Score (two-tailed) statt z-Score verwenden mit  $df = n-1$

# Konfidenzintervall



- Visualisierung mittels Fehlerbalken (Error Bar)
- Überschneidungsfreiheit zweier Samples bedeutet:

# Konfidenzintervall



- Visualisierung mittels Fehlerbalken (Error Bar)
- Überschneidungsfreiheit zweier Samples bedeutet:
  - Ein Sample enthält nicht den "wahren" Populationswert (5% wahrscheinlich)
  - Samples stammen aus verschiedenen Populationen bspw. vor und nach experimenteller Manipulation (95% wahrscheinlich)
- Ein präziseres Modell hat ein kleineres Konfidenzintervall



- Experimentelle (alternative) Hypothese  $H_1$  = ursprüngliche Hypothese
- Nullhypothese  $H_0$  = Verneinung von  $H_1$
- Beweis von  $H_1$  mit Statistik nicht möglich, aber Ablehnung von  $H_0$  für unser Experiment
- "Unsere Stichprobe wäre unwahrscheinlich, wenn  $H_0$  wahr wäre, daher ist  $H_1$  wahrscheinlicher."
- "Unsere Stichprobe wäre 5% wahrscheinlich, wenn  $H_0$  wahr wäre, daher ist  $H_1$  wahrscheinlicher."
- → Jedes 20. mal liegt man damit daneben, da die Zahlen zufällig auftraten

$$\text{Teststatistik (grob)} = \frac{\text{Varianz erklart durch Modell}}{\text{Varianz nicht erklart durch Modell}}$$


- auch Prüfgröße, Testgröße oder Prüffunktion
- Teststatistiken messen, wie gut das Modell zu den Daten passt
- Verschiedene Teststatistiken existieren ( $t$ ,  $F$ ,  $\chi^2$ )
- Gegeben ein zur Hypothese passendes Modell, sagt eine signifikante Teststatistik dass es unwahrscheinlich wäre, dass das Modell so gut zu den Daten passen würde, wenn die Nullhypothese wahr wäre.
  - Man testet also eigentlich die statistische Wahrscheinlichkeit von  $H_0$
- **One Tailed Tests:** gerichtete Hypothesen (5% Wahrscheinlichkeit)
- **Two Tailed Tests:** ungerichtete Hypothesen (je 2.5% Wahrscheinlichkeit)

- Fehler Erster Art:
  - Effekt fälschlicherweise bestätigt
  - $\alpha$ -level
  - bspw. 5% akzeptabel
- Fehler Zweiter Art:
  - Effekt fälschlicherweise übersehen
  - $\beta$ -level
  - bis 20% akzeptabel (Cohen 1992)
- indirekt proportionaler Zusammenhang vorhanden aber nicht genau bestimmbar

# Typ 1 und Typ 2 Fehler

		Wirklichkeit	
		H <sub>0</sub> ist wahr	H <sub>1</sub> ist wahr
Entscheidung des Tests	für H <sub>0</sub>	Spezifität True Positive Wahrscheinlichkeit: $1 - \alpha$	<b>Fehler 2. Art</b> False Negative Wahrscheinlichkeit: $\beta$
	für H <sub>1</sub>	<b>Fehler 1. Art</b> False Positive Wahrscheinlichkeit: $\alpha$	Sensitivität, Trennschärfe True Negative Wahrscheinlichkeit: $1 - \beta$

- Standardisierte Maße für Einfluss einzelner Variablen auf andere
- Pearson's  $r$  Korrelationskoeffizient
  - 0.1 : Schwach (1% der Variation)
  - 0.3 : Mittel (9% der Variation)
  - 0.5 : Stark (25% der Variation)
- Cohen's  $d$
- Quotenverhältnis (Odds Ratio)
- ...dazu später mehr



- Hypothese
- Stichprobe
- Passendes (fitting) Modell finden, welches Effekt der Hypothese beschreibt
- Mit Konfidenzintervall Vorhersagepräzision des Modells berechnen
- Teststatistik/Prüfzahl des Modells berechnen
- Fehler erster und zweiter Art der Teststatistik untersuchen
- Teststatistik signifikant (Effekt mathematisch unwahrscheinlich)  
→ Effekt/Zusammenhang trat wahrscheinlich auf
- Teststatistik nicht signifikant (Effekt mathematisch wahrscheinlich)  
→ Effekt/Zusammenhang zu klein um gemessen zu werden
- Effektstärke berechnen