
Statistik


Gregor Dürrenberger
Forschungstiftung Mobilkommunikation

Hypothesentest

- Vergleich von zwei Datensätzen (z.B. vor Experiment, nach Experiment; Vieltelefonierer, Wenigtelefonierer)
- **Signifikanz**: können Unterschiede durch Zufall erklärt werden?
- **Effektstärke**: sind Unterschiede relevant?
- **Power**: Wie gross ist die Wahrscheinlichkeit, dass ich einen bestimmten Unterschied überhaupt nachweisen kann?


Wahrscheinlichkeitsdichtefunktion

- Verglichen werden die Mittelwerte der Datensätze (Stichproben)
- **Annahme:** Mittelwerte von Stichproben einer Population streuen um den wahren Mittelwert
 - Streuung ist Normalverteilt
 - Je grösser Stichprobe, desto kleiner Streuung



Signifikanz

- Mittelwerte im Zentrum sind viel häufiger als Mittelwerte am Rand
- **Konsequenz:** Ein Mittelwert am Rand gehört nur mit kleiner Wahrscheinlichkeit zur Population
- **Signifikanz:** Wahrscheinlichkeit, ab der ein Mittelwert als nicht mehr zur Population gehörend betrachtet wird



α -Fehler


- Signifikanzniveau α legt fest, wann ein **Unterschied** als **zufällig**, wann als gesetzmässig gilt
- Ist α gross, besteht die Gefahr, dass ein Mittelwert fälschlicherweise als nicht zur Population gehörend klassiert wird (sog. **α -Fehler**)
- Wahl eines kleinen Signifikanzniveaus ($\alpha \leq 0.05$) gewährleistet, dass diese Fehlklassifikation selten vorkommt (in maximal 5% der Fälle)
 - ➔ Ist ein (Mittel)Wert signifikant, gehört er mit Wahrscheinlichkeit $p \geq 0.95$ **nicht** zur Population

Effektgrösse

- Signifikanz sagt nichts aus über die Relevanz eines Unterschieds der Mittelwerte
 - Bei sehr grossen Stichproben ist die Wahrscheinlichkeitsverteilung der Mittelwerte schmal. Schon kleine Unterschiede können signifikant werden.
- **Effektgrösse**: In einer Untersuchung muss deshalb zum Voraus bestimmt werden, ab wann ein Unterschied als relevant gelten soll.
- Statistisch: Festlegen der minimalen Differenz der Mittelwerte (μ_0 und μ_1)

β -Fehler

- μ_0 sei bekannt, μ_1 festgelegt. Wenn Signifikanzniveau α hoch, werden die Mittelwerte der zweiten Population die unwahrscheinlicher sind als β als der ersten zugehörig angesehen
- **Konsequenz:** Je kleiner α , desto grösser Risiko für Fehlklassifikation eines Mittelwertes der zweiten Verteilung
- Dies ist der **β -Fehler**

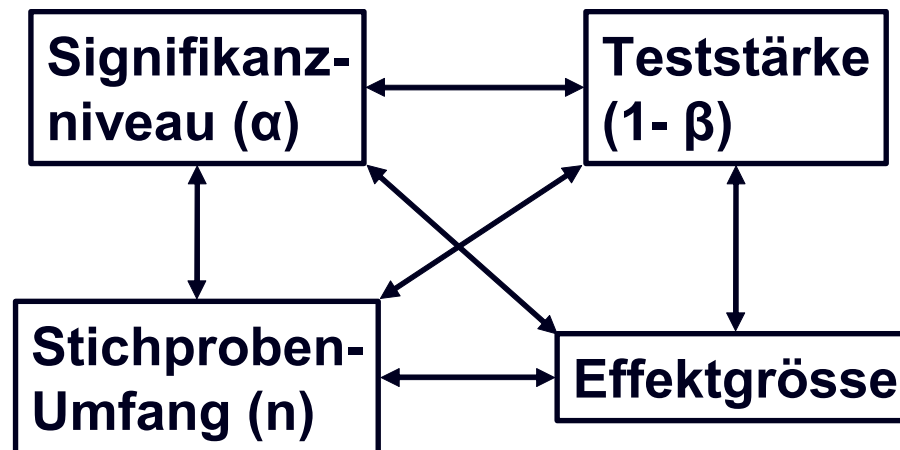


Zusammenhang α -Fehler und β -Fehler

- Wenn Signifikanzniveau reduziert wird, können zuvor erkannte **Unterschiede übersehen** werden, und umgekehrt.
- Wird die Stichprobengrösse erhöht, sinkt das Risiko von Fehlklassifikationen (β -Fehler)
- Der statistische Nachweis eines Unterschieds kann bei gegebener Effektgrösse und festgelegtem Signifikanzniveau über die Stichprobengrösse optimiert werden (**Powerberechnung**)

Power

- **Power** (oder Teststärke $1-\beta$). Wahrscheinlichkeit, mit der ein Unterschied festgelegter Grösse (Effektgrösse) erkannt wird
- Üblich ist eine Power von **80%** (bzw. $\beta=4\alpha$)
- Power, Effektgrösse, Signifikanz und Stichprobenumfang sind gegenseitig abhängig



Zusammenhänge

- Kleines Signifikanzniveau, kleine Effektstärke
 - Grosser β -Fehler (Wahrscheinlichkeit von Fehlklassifikation der 2. Verteilung gross)
 - Kann durch grosse Stichprobe reduziert werden
- Kleines Signifikanzniveau, grosse Effektstärke
 - Kleine Wahrscheinlichkeit von Fehlklassifikation (β -Fehler)
 - Stichprobe kann klein gehalten werden
- Kleines Signifikanzniveau, grosse Stichprobe
 - Bei grosser Effektstärke kleiner β -Fehler
 - Kleine Effektstärke: bedeutsamer β -Fehler möglich

Hypothesentest

- Vergleich der Wahrscheinlichkeitsverteilungen einer Variable zwischen zwei Gruppen
- α -Fehler: Ablehnen einer **richtigen** Hypothese (falsch-**positiv**)
- β -Fehler: Annahme einer **falschen** Hypothese (falsch-**negativ**)
- In der Wissenschaft ist die interessierende Hypothese häufig die **Nullhypothese**: kein Unterschied

Hypothesentest: Allgemeine Darstellung

	Hypothese falsch (Zusammenhang existiert wirklich)	Hypothese richtig (Zusammenhang existiert nicht)
Effekt gefunden (Nullhypothese ab- lehnen)	Richtig-positiv ($1-\alpha$)	Falsch-positiv (α -Fehler)
kein Effekt gefunden (Nullhypothese an- nehmen)	Falsch-negativ (β -Fehler)	Richtig-negativ ($1-\beta$)

Beispiel 1: Diagnosetest

	Krank	Gesund
Test positiv	Richtig-positiv ($1-\alpha$)	Falsch-positiv (α -Fehler) Fehldiagnose
Test negativ	Falsch-negativ (β -Fehler) Nicht erkannt	Richtig-negativ ($1-\beta$)

- Ziel Screening-Tests: möglichst wenige falsch-negative (Krankheit nicht erkannt). Gewünscht ist **grosse Power**
- Man nimmt dafür in Kauf, dass viele Gesunde positiv getestet werden (→Zweittest für alle positiven Befunde)

Beispiel 2: Gerichtsurteil

	Täter	Unschuldig
Indizien griffig	Richtig-positiv ($1-\alpha$)	Falsch-positiv (α -Fehler)
Indizien nicht griffig	Falsch-negativ (β -Fehler)	Richtig-negativ ($1-\beta$)

- Ziel: wenig Falsch-positive (Unschuldige verurteilt). Hohe Ansprüche an **Signifikanz** Indizien (täterfreundlich)
- USA: möglichst wenige Falsch-negative (Täter nicht verurteilt). Ansprüche an Signifikanz Indizien tiefer (Tendenz zur Verurteilung von Unschuldigen)

Berechnung der Signifikanz (1)

- **Signifikanztest** mit Vierfeldertabelle zur Berechnung der Prüfgrösse X^2

	Erfolg	Misserfolg
Probe 1	a	b
Probe 2	g	h

$$X^2 = \frac{(a+b+g+h-1) \cdot (a \cdot h - g \cdot b)^2}{[(a+g) \cdot (b+h) \cdot (a+b) \cdot (g+h)]}$$

- Falls $X^2 > 3.84$ ist der Unterschied mit weniger als 5% Wahrscheinlichkeit zufällig (also signifikant; $p < 0.05$)
- Notwendige **Mindestgrösse** der Proben: 6 Fälle

Berechnung der Signifikanz (2)

- **Samples klein, Häufigkeitsverteilung unterschiedlich**
(Erfolg von Probe 1 über 3 mal grösser)

	Erfolg	Misserfolg
Probe 1	9	198
Probe 2	1	80

	Erfolg	Misserfolg
Probe 1	4.3%	95.7%
Probe 2	1.2%	98.8%

- $\chi^2 = 1.68$
- Unterschied **nicht signifikant**
- mit 20% Wahrscheinlichkeit zufällig zu Stande gekommen ($p = 0.2$)

Berechnung der Signifikanz (3)

- Samples zehn mal grösser

	Erfolg	Misserfolg
Probe 1	90	1980
Probe 2	10	800

	Erfolg	Misserfolg
Probe 1	4.3%	95.7%
Probe 2	1.2%	98.8%

- $X^2 = 16.8$
- Unterschied wird **signifikant**
- mit weniger als 0.1% Wahrscheinlichkeit per Zufall zu Stande gekommen

Berechnung der Signifikanz (4)

- Samples zehn mal grösser, **Häufigkeitsverteilung ähnlich**

	Erfolg	Misserfolg
Probe 1	90	1980
Probe 2	50	760

	Erfolg	Misserfolg
Probe 1	4.3%	95.7%
Probe 2	6.2%	93.8%

- $\chi^2 = 4.2$
- Unterschied trotzdem noch **signifikant**
- mit 4% Wahrscheinlichkeit per Zufall zu Stande gekommen ($p = 0.04$)

Powerberechnung (1)

- Das Risiko, einen **Unterschied** zwischen zwei Messreihen zu **übersehen**
- Kann nur bestimmt werden, wenn die Effektgrösse bekannt (festgelegt) ist!
- Bei gegebenem Signifikanzniveau und Effektgrösse lässt sich die minimal notwendige Stichprobengrösse berechnen (**Powerberechnung**), um den spezifizierten Effekt mit Wahrscheinlichkeit $1-\beta$ nachzuweisen

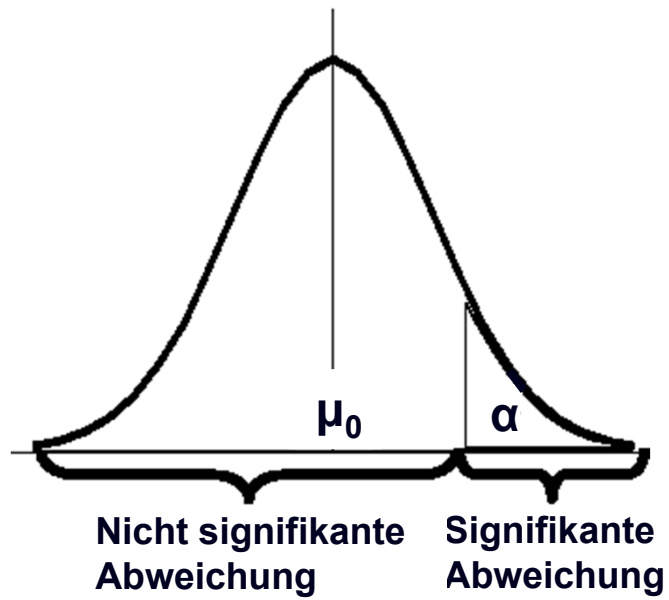
Powerberechnung (2)


- Samples zehn mal grösser, Häufigkeitsverteilung ähnlich

	Erfolg	Misserfolg
Probe 1	90	1980
Probe 2	50	760

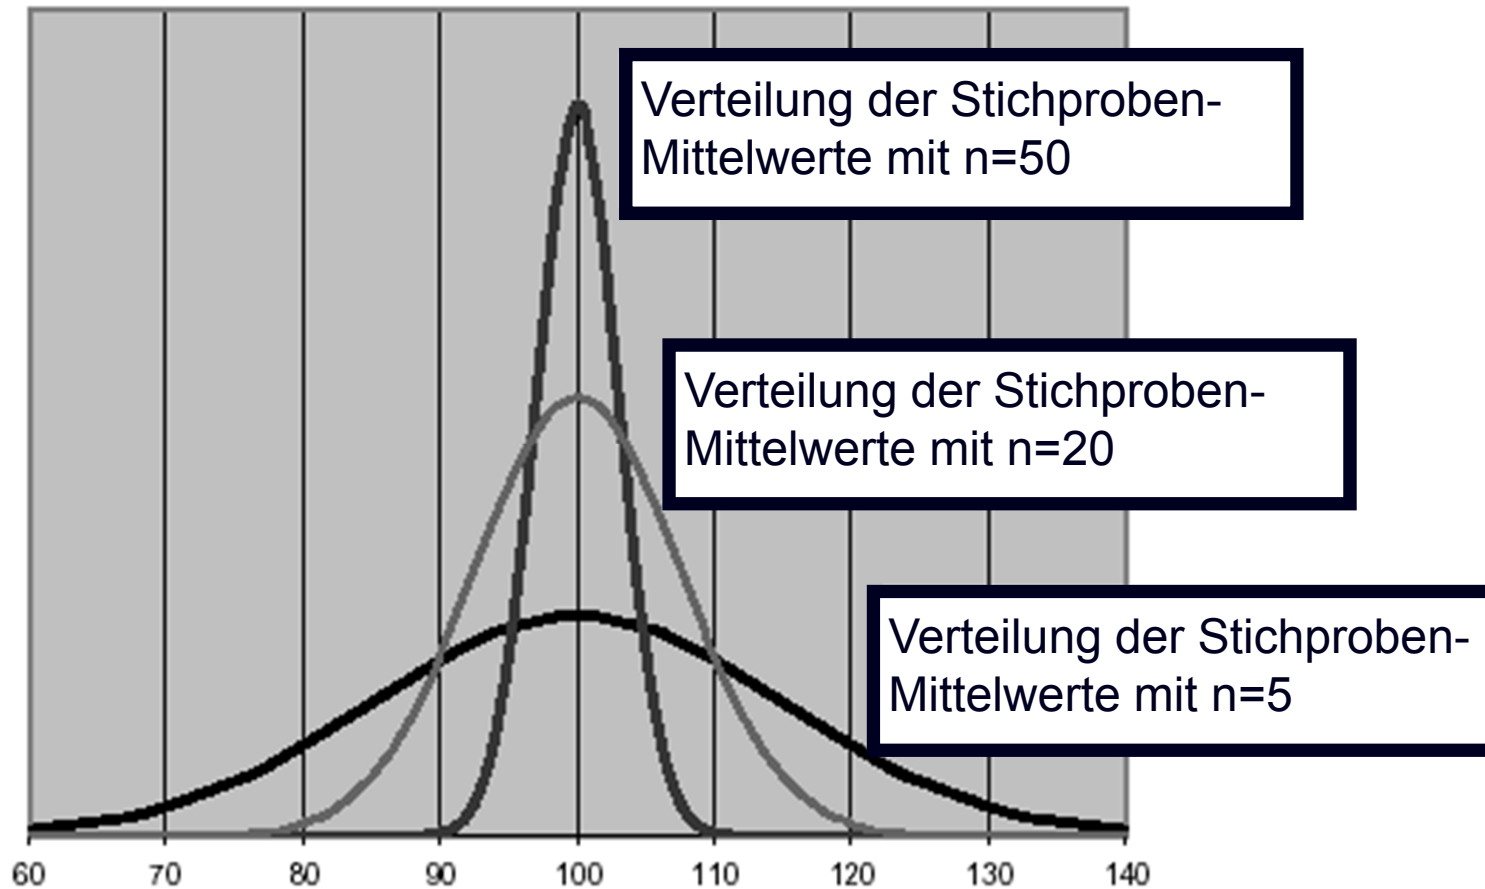
	Erfolg	Misserfolg
Probe 1	4.3%	95.7%
Probe 2	6.2%	93.8%

- $\chi^2 = 4.2$
- Unterschied trotzdem noch **signifikant**
- mit 4% Wahrscheinlichkeit per Zufall zu Stande gekommen ($p = 0.04$)





http://www.psych-methoden.uni-koeln.de/statistik_SS2005/vorlesung/vorlesung_2.pdf



				<u>METRISCH</u>				
<u>NOMINAL</u>		<u>ORDINAL</u>		nicht normalverteilt, aber ähnlich		normalverteilt		
unabhängig	abhängig	unabhängig	abhängig	unabhängig	abhängig	unabhängig	abhängig	
<u>χ^2</u> für: k x l - Felder 2 x 2 Felder	<u>χ^2</u> McNemar r-Test für: 2 x 2 Felder	<u>Mann-Whitney</u> <u>y</u>	<u>Wilcoxon</u> <u>n</u>	<u>Mann-Whitney</u> <u>y</u>	<u>Wilcoxon</u> <u>n</u>	<u>F-Test</u> (Varianzquotiententest) entscheidet über:		<u>t-Test</u> <u>t</u> für verbundene Stichproben
						Varianzhomogenität <u>t-Test</u>	Varianzheterogenität <u>Welch-Test</u>	
nichtparametrische Testverfahren						parametrische Testverfahren		

