

KATA LOGO Mathematik – Statistik – Roadmap: Von der Hypothese zum p-Wert

0.

Das eigentliche Forschungsziel ist: Beweis der eigenen Hypothese H_1

Dafür muss Nullhypothese H_0 falsifiziert werden können
 → **Achtung!** Es gibt einen Trend zur vorschnellen Ablehnung (α -Fehler).
 → Festlegung für die Wahrscheinlichkeit (WS), dass Forscher genau diesen α -Fehler machen (siehe Punkt 3).

1.

Formulierung der inhaltlichen Hypothese H_0

Entscheidung: Zweiseitige / einseitige / einfache / zusammengesetzte / spezifische / unspezifische

Beispiel: Münzwurf zweiseitiger Hypothesentest

H_0	H_1
Nullhypothese	Gegenhypothese
Annahme über die Wahrscheinlichkeits- Verteilung der Zufallsvariablen ZV (Normalverteilung ...)	
Dies ist die Behauptung!	
Parametrische Verfahren: H_0 macht Aussage über ≥ 1 Parameter der Verteilung, z. B. p und/oder μ .	
Nichtparametrische Verfahren: H_0 macht keine Aussage über Verteilung.	
Formulierung je nach Interessenlage.	

Gruppe I behauptet: $p > p_0 \Rightarrow H_0 : p \leq p_0$	Gruppe I behauptet also: $H_1 : p > p_0$
Gruppe II behauptet: $p < p_0 \Rightarrow H_0 : p \geq p_0$	Gruppe II behauptet also: $H_1 : p < p_0$
z. B. $P(X = \text{Kopf}) = 0,5$	
Ungerichtet: "Es besteht kein Unterschied "	Ungerichtet: "Es besteht ein Unterschied "
Gerichtet: "Median ist <i>nicht</i> < oder sogar > als ..."	Gerichtet: "Median von Gruppe 1 ist < als ...".
Verteilung ist ...	
2 Merkmale haben einen Zusammenhang / keinen Zusammenhang (letzteres oft H_0).	
Gruppen unterscheiden sich durch Merkmale.	
Merkmale haben Parameter ...	
Inhaltliche Hypothese in statistische Hypothese übersetzen	
Für parametrische Fragestellungen	
<ul style="list-style-type: none"> • einseitige Frage: $H_0 : \vartheta \leq \vartheta_0$ gegen $H_1 : \vartheta > \vartheta_0$ • einseitige Frage: $H_0 : \vartheta \geq \vartheta_0$ gegen $H_1 : \vartheta < \vartheta_0$ • zweiseitige Frage: $H_0 : \vartheta = \vartheta_0$ 	
Bestimmen des Annahme- und Verwerfungsbereichs durch Festlegen des Signifikanzniveaus	
Annahme- und Verwerfungsbereich sind für die Interessengruppen unterschiedlich	
Signifikanzniveau (5 %) ist komplementär zur Sicherheitswahrscheinlichkeit (95 %)	
Sicherheits- oder Vertrauenswahrscheinlichkeit: $1 - \alpha$ (bei 0,95 = $1 - 0,05$)	

2.

3.

Annahme- und Verwerfungsbereich kann mit σ -Umgebung festgelegt werden
→ Bei 95 %: $\mu - 1,96 \sigma$ und $\mu + 1,96 \sigma$

4.

Bestimmen des Testverfahrens

Zunächst Einteilung der Variablen in Skalenniveaus

1. Nominalskaliert mit > 2 Kategorien
2. Nominalskaliert mit 2 Kategorien
3. Ordinalskaliert
4. Intervallskaliert und nicht normalverteilt
5. Intervallskaliert und normalverteilt

5.

Bestimmung der Güte des gewählten Tests

Güte 1: Teststärke = Trennschärfe = $T = \text{power} = 1 - \beta$
Mit welcher WS entscheidet Test zugunsten H_1 (falls richtig)?

Güte 2: β = Wahrscheinlichkeit, dass ein bestehender Unterschied **nicht** erkannt wird.

Güte 3: $1 - \beta$ = Wahrscheinlichkeit, dass ein bestehender Unterschied aufgezeigt wird. Dies ist die eigentliche Teststärke.

Güte Kriterium Nr. 1 eines Tests: Objektivität = Ist Testergebnis unabhängig von jeglichen Einflüssen ?

Güte Kriterium Nr. 2 eines Tests: Reliabilität = Zuverlässigkeit, wie genau misst der Test, was er misst ?

Güte Kriterium Nr. 3 eines Tests: Validität = Grad der Gültigkeit: Misst der Test, was er messen soll ?

Gütefunktion g : Für parametrische Tests und bei festem Stichprobenumfang n (z. B. 36) und SN α (5%).
Ordnet jedem möglichen Parameterwert u die Wahrscheinlichkeit für Ablehnung von H_0 zu. Man berechnet die Gütefunktion also nur für den Ablehnbereich. Als Variablen bei z. B. der Hypergeometrischen Verteilung errechnet man nur die Güte von N (alle Werte) und K , aber nicht für n oder k (die beiden letzteren werden zufällig gegeben).
 $u \rightarrow g(u) = P(H_0 \text{ wird abgelehnt} \mid u \text{ ist der wahre Wert des unbekanntes Parameters}).$

6.

Ziehen der Stichprobe (z. B. Münzwurf mit $p = 0,5$ und SN = 5 %)

	Zeigt sich hier vermuteter Zusammenhang? Wenn nicht → Kein Signifikanztest	
	Kann man annehmen, dass dieser Zusammenhang auch in Ω besteht? Wenn ja → Signifikanztest	
7.	Klassifikation der Daten: Verhältnis-, Intervall-, Ordinal-, Nominalskala	
	Voraussetzung für parametrische Tests: Normalverteilung der Daten	
	Voraussetzung vorhanden? Stichworte: Restfehler und Homogenität der Varianzen	Voraussetzung nicht vorhanden? 1. Daten-Transformationen 2. Nicht-parametrische Tests 3. Computerintensive Methoden
8.	Zusammenfassung der Daten	
	Graphisch	In Zahlen
	Stem-and-Leaf Histogramm Summenkurven Box-and-Whiskers	Lage- und Streuungsparameter Konfidenzintervalle Bootstrap
9.	Teststatistik berechnen und zu Prüfgröße (optimalen Stichprobenumfang) standardisieren	
	Art des Tests hängt von Stichprobengröße n und jeweils aufgestellter H_0 ab	
a.	Für das Münzbeispiel: EW $\mu = n \cdot p$. Bei 36 Würfeln ist $\mu = 36 \cdot 0,5 = 18$	
b.	Für das Münzbeispiel: STA $\sigma = \sqrt{n \cdot p \cdot (1-p)} = \sqrt{9} = 3$. (Laplace ist in etwa erfüllt: $\sigma > 3$)	
c.	Für das Münzbeispiel: Für Abdeckung einer 95 % Wahrscheinlichkeit steht in Tabellen für die σ -Umgebung: $z = 1,96$	
d.	Für das Münzbeispiel: Umgebung festlegen: $\mu - 1,96 \cdot 3$ und $\mu + 1,96 \cdot 3 \rightarrow X = 12,12$ und $X = 23,88$	
e.	Für das Münzbeispiel: Entscheidungsregel aufstellen: Verwirf Annahme, dass Erfolgswahrscheinlichkeit $P = 0,5$ ist, wenn die Anzahl der Wappen $X < 13$ oder $X > 23$ ist.	

10.

Liegt Stichprobenergebnis (= Testgröße) also im Annahmehbereich, wird nicht die Hypothese bestätigt, sondern man entscheidet sich durch die vorher festgelegte Entscheidungsregel, sie weiter als richtig anzusehen.	
Ist diese $WS < 0,05$ →	
abzulesen an Verteilung der Testgröße →	
wenn kein Zusammenhang in Ω →	
Testentscheidung	
Man will immer die Nullhypothese ablehnen, also man will verwerfen! Ist sie hier (zu $\alpha = 0,05$) abzulehnen?	
Bei Ablehnung der Nullhypothese: Ergebnis ist signifikant!	
<ul style="list-style-type: none"> • Stichprobenergebnis: Ist im Annahmehbereich • Wenn H_0 nicht zum SN $\alpha = 0,05$ abgelehnt werden kann, ist H_0 korrekt • Ist H_0 korrekt, wird aber abgelehnt: → α-Fehler • α-Fehler gibt die WS für H_0-Ablehnung an • WS für einen α-Fehler ist höchstens α (0,05) • Kontrolle des α-Fehlers durch Oberschranke α • Wenn WS für α-Fehler geringer, steigt WS für β-Fehler <div style="text-align: right; border: 1px solid black; padding: 2px; width: 30px; margin: 0 auto;">2.</div>	<ul style="list-style-type: none"> • Stichprobenergebnis: Ist im Verwerfungsbereich • H_0 ist zum SN α abzulehnen • Wenn H_0 abgelehnt wurde, kann nicht zu 100% auf H_1 geschlossen werden, da Ablehnung zu 5% • H_1 (für z. B. $p > 0,5$) ist korrekt • Ist H_1 korrekt, H_0 wurde aber nicht abgelehnt → β-Fehler! • Wenn WS für α-Fehler geringer, steigt WS für β-Fehler <div style="text-align: right; border: 1px solid black; padding: 2px; width: 30px; margin: 0 auto;">1.</div>
Bei $\alpha = 0,05$ ist $WS = 0,95$ für die richtige Entscheidung H_0 abzulehnen.	β -Fehler ist kein eigentlicher Fehler, da der Test in diesem Fall keine Aussage macht. Trotzdem möchte man ihn vermeiden.
Zu gegebenem α ist eine Nullhypothese genau dann abzulehnen. wenn $p \leq \alpha$ gilt.	

11.

Testen von Hypothesen (Sind Ergebnisse zufälliger Natur oder nicht?)

a.

Assoziationen zwischen ≥ 2 Variablen

Unterteilung in abhängige und unabhängige Variablen ist sinnvoll: Regression	Unterteilung in abhängige und unabhängige Variablen ist nicht sinnvoll: Korrelation
---	--

b.

Vergleich von 2 Durchschnittswerten (x quer und y quer)

1 Stichprobe und 1 bekannter Wert:	One-sample-t-Test und/oder Konfidenzintervall
2 gepaarte (= abhängige = verbundene) Stichprobenwerte:	Gepaarter t-Test Oft sind derselben Person 2 Werte zugeordnet → Differenzen bilden
2 unabhängige Stichproben:	Ungepaarter t-Test

c.

Vergleich von > 2 Durchschnittswerten: Varianzanalyse ANOVA

Unterschiede zwischen festen und zufälligen Effekten	
Bei 1 Faktor: Einfache ANOVA ? Entspricht das F-Test auf Lokationsunterschied?	Bei ≥ 2 Faktoren: a. 1 fester, 1 zufälliger Effekt: Geblockte ANOVA b. ≥ 2 feste Effekte: Mehrfaktorielle ANOVA

d.

Vergleich von beobachteten (Stichproben) und erwarteten absoluten Häufigkeiten

χ^2-Test
<ol style="list-style-type: none"> 1. Daten sind Zufallsdaten 2. Immer mit Tabelle mit absoluten Häufigkeiten 3. Diskrete Verteilungen 4. Es gibt nur endlich viele mögliche Ausprägungen der zu untersuchenden ZV (x_1, x_2, \dots, x_n)

12.

Entscheidungsfindung mittels p-Wert (Überschreitungs-Wahrscheinlichkeit)

a.

p-Wert: Grad der Unwahrscheinlichkeit. Wie glaubhaft ist ein solcher gemäß Daten extremer Versuchsausgang, wenn H_0 wahr ist? p-Wert zeigt WS für solche oder extremere Stichproben-Ergebnisse, wenn H_0 gilt. Teststatistik zugrundenehmen: $1 - S_{m-1}(TS) = z$. B. $1 - S_{35}(TS) \rightarrow$ ausrechnen mit Software R.

H_0 ablehnen oder nicht? Hoher p-Wert heißt immer: Nicht signifikant, also Werte sind Ergebnis des Zufalls. Vergleich von p-Wert zu Signifikanzniveau. Je kleiner p-Wert, desto stärker spricht er gegen H_0 . p-Wert = 0,01: So ein kleiner Wert könnte - falls H_0 gilt - durch Zufall auftreten, aber die WS dafür ist $\leq 0,01$.

p-Wert im Beispiel: $P(T \geq 2,92) \approx 1 - S_5(2,92) \approx 0,7123$ (falls H_0 gilt)
mit S_5 aus chi (χ)-Verteilung mit $5 = 6 - 1$ Freiheitsgraden

Bei (quantitativ) überzufällig starker Abweichung der Daten von H_0 -Gültigkeit (so dass es keine Zufallsstreuung mehr ist) testet man mit Hilfe des p-Werts.

p-Wert: Gibt die WS an, unter H_0 das beobachtete Stichprobenergebnis oder einen in Richtung der Alternativen extremeren Wert zu erhalten.

Je kleiner der p-Wert, desto unwahrscheinlicher ist das erhaltene Ergebnis, wenn H_0 wahr ist. Ist p-Wert kleiner oder gleich α , so wird H_0 verworfen. Bei $p = 0$, gilt H_0 nicht. Große Werte sagen nur was aus, wenn H_0 gilt.

Man nimmt den am wenigsten "plausiblen" Wert, z. B. Trefferzahl 0 bei $p > 0,4$ bei $n = 8$. Hier nimmt man $k = 0$ und setzt es z. B. in die Binomialverteilung ein.

p-Wert = 0,95 bedeutet: Zu 95 % ist sicher, dass Ergebnisse nicht zufällig sind. Zu 95 % sind Ergebnisse der Stichprobe auch Ergebnisse der Variablen.

p-Werte kann man unabhängig vom Signifikanzniveau ausrechnen (kleinstmögliche Obergrenze für WS für diesen oder einen noch unwahrscheinlicheren Wert - bei H_0)

b.

Entscheidungsfindung mittels Ablehnungsbereich	
Nur bei manchen Tests. Anwendung der <i>Testfunktion oder Teststatistik T</i> .	z. B. t-Test und χ^2 -Anpassungstest.
Prüfwert = Realisation einer Teststatistik anhand einer Stichprobe.	
H_0 wird abgelehnt $\Leftrightarrow T(D) \in A$. Mit einer vom Zufall abhängigen Zahl T (D), den Daten D und dem Ablehnungsbereich A.	
Aus den Daten D errechnet sich p-Wert	

Signifikanz: Kann das Muster in der Stichprobe erklärt werden durch ... ?		
	Zufall	System
Ja	Wenn ja, dann hätte Muster eine Wahrscheinlichkeit von $\leq 5\%$	Ein in den Daten sichtbares Muster ist signifikant , wenn ein System dahinter steckt und der Zufall zu $\geq 5\%$ ausgeschlossen werden konnte.
Nein	Wenn ein in den Daten sichtbares Muster nur schwer durch Zufall zu erklären ist, ist es signifikant	