



# Inhalt

Roger Wolf

- 1 Einführung und Grundlagen  
Wahrscheinlichkeit, Statistik, Werkzeuge der statistischen Datenanalyse, ...
  - 2 Monte Carlo Methode als numerisches Hilfsmittel  
Numerische Integration, Simulation komplexer Zusammenhänge, ...
  - 3 Parameterschätzung mit Hilfe der Maximum Likelihood Methode  
Likelihood vs. Wahrscheinlichkeit, Maximum Likelihood als Optimierungsproblem, ...
  - 4 Parameterschätzung mit Hilfe der  $\chi^2$ -Methode  
Ableitung aus Maximum Likelihood Methode, Optimierungsverfahren im allg., ...
  - 5 Hypothesentests in der modernen Physik  
Begriffe des Hypothesentests, Beispiele, Anwendungen in der Physik, ...
- 

Ralf Ulrich

- 6 Kollaboratives Arbeiten und moderne Softwarewerkzeuge
- 7 High-Performance Computing: optimales Zusammenspiel von Hard- und Software

# Literaturempfehlungen

---

- **Einführende Literatur zu Statistik und Numerik:**
  - G. Cowan, *Statistical data analysis*, Oxford (1997) ([KIT-Bibliothek](#)).
  - G. Bohm, G. Zech, *Einführung in Statistik und Messwertanalyse für Physiker*, DESY (2006) ([eBook](#) deutsch, [eBook](#) english).
  - V. Blobel, E. Lormann, *Statistische und numerische Methoden der Datenanalyse*, DESY (2012) ([Webseite](#)).
  - R. J. Barlow, *Statistics: A Guide to the use of statistical methods in the physical sciences*, Wiley (1989) ([KIT-Bibliothek](#)).
  - W. H. Press, S. A. Teukolsky, W. T. Vetterling, B. P. Flannery, *Numerical recipes*, Cambridge Univ. Press (2007) ([Webseite](#)).
- Skriptensammlung von Prof. G. Quast ([Link](#)):

# 6 Hypothesentests in der modernen Physik

---

## 6.1 Grundlagen und Begriffe

Wir klären zunächst grundsätzlich, worum es bei einem Hypothesentest geht und fassen alle wesentlichen Aspekte an einem Beispiel zusammen.



# Hypothesentests

---

- Was eine statistische Hypothese haben wir bereits in [VL-03 Folie 12](#) geklärt.
- Hypothesentests dienen dazu, eine Hypothese mit gegebener Stichprobenverteilung einer Teststatistik  $t(\vec{x})$  auf ihre Vereinbarkeit mit dem Ergebnis einer Stichprobe (=Messung) hin zu überprüfen.
- Die zu testende Hypothese wird im Allgemeinen als Nullhypothese ( $H_0$ ) bezeichnet. Unwahrscheinliche Ausgänge der Stichprobe werden zur Widerlegung der Nullhypothese herangezogen, sofern sie „signifikant“ sind.
- „Signifikant“ bedeutet, dass die Abweichung der Stichprobe von der Erwartung der Hypothese im Rahmen des Fürwahrhaltens des Testenden nicht mehr durch den Zufallsfehler (d.h. die Varianz von  $t(\vec{x})$ ) erklärt werden kann.
- **NB:** Alternativ kann die Nullhypothese gegen eine oder mehrere alternative Hypothesen  $H_i$  getestet werden.

# Beispiele

---

- Hypothesentests sind das Hauptanwendungsgebiet der Statistik. Die Anwendungen sind sehr vielfältig und müssen ggf. von Fall zu Fall sorgfältig mathematisch formuliert werden.
- **Beispiele:**
  - Können zwei Stichproben bezüglich des betrachteten Parameters aus der selben Grundgesamtheit stammen (z.B.  $H_0: \mu_1 = \mu_2$ )?

# Beispiele

---

- Hypothesentests sind das Hauptanwendungsgebiet der Statistik. Die Anwendungen sind sehr vielfältig und müssen ggf. von Fall zu Fall sorgfältig mathematisch formuliert werden.
- **Beispiele:**
  - Können zwei Stichproben bezüglich des betrachteten Parameters aus der selben Grundgesamtheit stammen (z.B.  $H_0: \mu_1 = \mu_2$ )?
  - Entspricht die Energiedeposition des Teilchens in Blei eher der Erwartung für ein Pion oder für ein Elektron?

# Beispiele

---

- Hypothesentests sind das Hauptanwendungsgebiet der Statistik. Die Anwendungen sind sehr vielfältig und müssen ggf. von Fall zu Fall sorgfältig mathematisch formuliert werden.
- **Beispiele:**
  - Können zwei Stichproben bezüglich des betrachteten Parameters aus der selben Grundgesamtheit stammen (z.B.  $H_0: \mu_1 = \mu_2$ )?
  - Entspricht die Energiedeposition des Teilchens in Blei eher der Erwartung für ein Pion oder für ein Elektron?
  - Gibt es ein neues Signal auf einem bekannten Untergrund?



# Beispiele

---

- Hypothesentests sind das Hauptanwendungsgebiet der Statistik. Die Anwendungen sind sehr vielfältig und müssen ggf. von Fall zu Fall sorgfältig mathematisch formuliert werden.
- **Beispiele:**
  - Können zwei Stichproben bezüglich des betrachteten Parameters aus der selben Grundgesamtheit stammen (z.B.  $H_0: \mu_1 = \mu_2$ )?
  - Entspricht die Energiedeposition des Teilchens in Blei eher der Erwartung für ein Pion oder für ein Elektron?
  - Gibt es ein neues Signal auf einem bekannten Untergrund?
  - Ist der Spin des beobachteten Teilchens 0 oder 1?

# Beispiele

---

- Hypothesentests sind das Hauptanwendungsgebiet der Statistik. Die Anwendungen sind sehr vielfältig und müssen ggf. von Fall zu Fall sorgfältig mathematisch formuliert werden.
- **Beispiele:**
  - Können zwei Stichproben bezüglich des betrachteten Parameters aus der selben Grundgesamtheit stammen (z.B.  $H_0: \mu_1 = \mu_2$ )?
  - Entspricht die Energiedeposition des Teilchens in Blei eher der Erwartung für ein Pion oder für ein Elektron?
  - Gibt es ein neues Signal auf einem bekannten Untergrund?
  - Ist der Spin des beobachteten Teilchens 0 oder 1?
  - Verdienen Frauen weniger als Männer bei gleicher Qualifikation?

# Beispiele

---

- Hypothesentests sind das Hauptanwendungsgebiet der Statistik. Die Anwendungen sind sehr vielfältig und müssen ggf. von Fall zu Fall sorgfältig mathematisch formuliert werden.
- **Beispiele:**
  - Können zwei Stichproben bezüglich des betrachteten Parameters aus der selben Grundgesamtheit stammen (z.B.  $H_0: \mu_1 = \mu_2$ )?
  - Entspricht die Energiedeposition des Teilchens in Blei eher der Erwartung für ein Pion oder für ein Elektron?
  - Gibt es ein neues Signal auf einem bekannten Untergrund?
  - Ist der Spin des beobachteten Teilchens 0 oder 1?
  - Verdienen Frauen weniger als Männer bei gleicher Qualifikation?
  - Ist das Medikament wirksam oder nicht?

# Beispiele

---

- Hypothesentests sind das Hauptanwendungsgebiet der Statistik. Die Anwendungen sind sehr vielfältig und müssen ggf. von Fall zu Fall sorgfältig mathematisch formuliert werden.
- **Beispiele:**
  - Können zwei Stichproben bezüglich des betrachteten Parameters aus der selben Grundgesamtheit stammen (z.B.  $H_0: \mu_1 = \mu_2$ )?
  - Entspricht die Energiedeposition des Teilchens in Blei eher der Erwartung für ein Pion oder für ein Elektron?
  - Gibt es ein neues Signal auf einem bekannten Untergrund?
  - Ist der Spin des beobachteten Teilchens 0 oder 1?
  - Verdienen Frauen weniger als Männer bei gleicher Qualifikation?
  - Ist das Medikament wirksam oder nicht?
  - Ist der Patient krank oder nicht?

# Anforderung an die Hypothese

---

- Die zu testende Hypothese muss so formuliert sein, dass sie überprüfbar (d.h. „falsifizierbar“) ist.
- Die Annahme der Gültigkeit der Hypothese muss die Bestimmung einer Stichprobenverteilung erlauben. Die Stichprobenverteilung wird in diesem Fall auch als **Testverteilung** bezeichnet.

# Testverteilung

---

- Um eine Testverteilung  $f(t|\theta = \theta_0)$  angeben zu können, muss bei Parametertests der zu untersuchende Parameter  $\theta$  zunächst auf einen Wert  $\theta = \theta_0$  festgelegt werden.

# Testverteilung

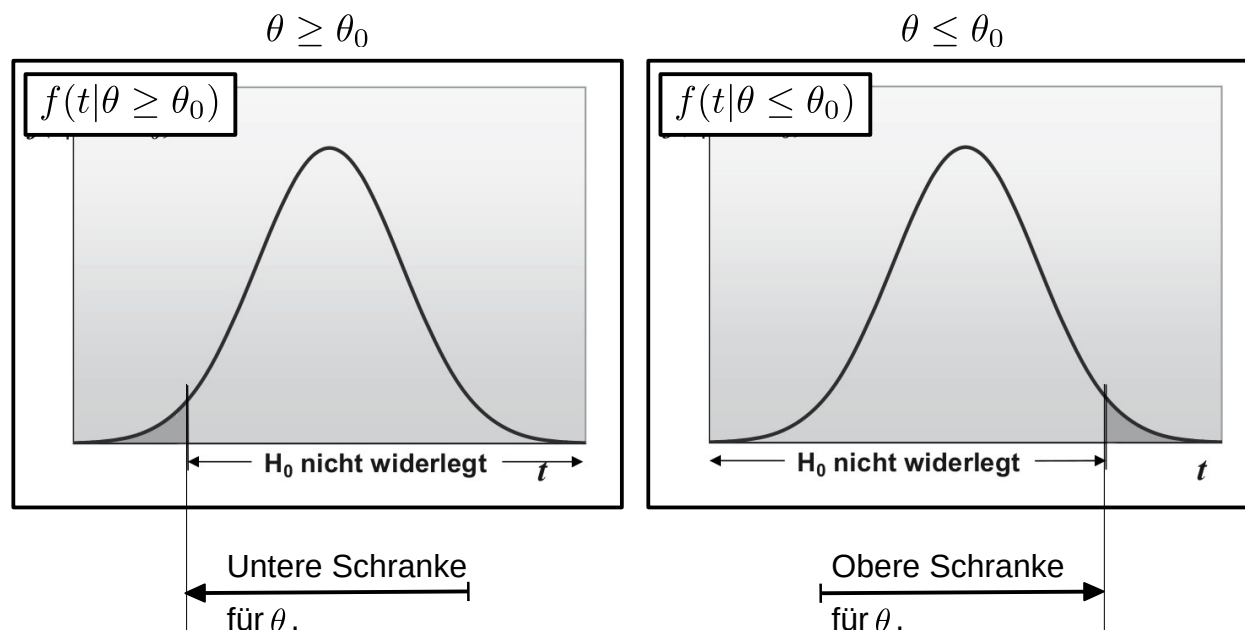
---

- Um eine Testverteilung  $f(t|\theta = \theta_0)$  angeben zu können, muss bei Parametertests der zu untersuchende Parameter  $\theta$  zunächst auf einen Wert  $\theta = \theta_0$  festgelegt werden.
- Die Testverteilung wird unter Annahme von  $H_0$  entweder analytisch oder mit Hilfe eines **Ensemble Tests** ermittelt.

# Testverteilung

- Um eine Testverteilung  $f(t|\theta = \theta_0)$  angeben zu können, muss bei Parametertests der zu untersuchende Parameter  $\theta$  zunächst auf einen Wert  $\theta = \theta_0$  festgelegt werden.
- Die Testverteilung wird unter Annahme von  $H_0$  entweder analytisch oder mit Hilfe eines **Ensemble Tests** ermittelt.
- Der konkrete Test erfolgt dann als (als einmalige Auswertung von  $t(\vec{x})$ ) auf einer Stichprobe, entweder als:

## Bereichshypothese:






# Testverteilung

- Um eine Testverteilung  $f(t|\theta = \theta_0)$  angeben zu können, muss bei Parametertests der zu untersuchende Parameter  $\theta$  zunächst auf einen Wert  $\theta = \theta_0$  festgelegt werden.
- Die Testverteilung wird unter Annahme von  $H_0$  entweder analytisch oder mit Hilfe eines **Ensemble Tests** ermittelt.
- Der konkrete Test erfolgt dann als (als einmalige Auswertung von  $t(\vec{x})$ ) auf einer Stichprobe, oder als:

**Punkthypothese:**

$$\theta = \theta_0$$




# Testverteilung

- Um eine Testverteilung  $f(t|\theta = \theta_0)$  angeben zu können, muss bei Parametertests der zu untersuchende Parameter  $\theta$  zunächst auf einen Wert  $\theta = \theta_0$  festgelegt werden.
- Die Testverteilung wird unter Annahme von  $H_0$  entweder analytisch oder mit Hilfe eines **Ensemble Tests** ermittelt.
- Der konkrete Test erfolgt dann als (als einmalige Auswertung von  $t(\vec{x})$ ) auf einer Stichprobe, oder als:

**Punkthypothese:**

$$\theta = \theta_0$$



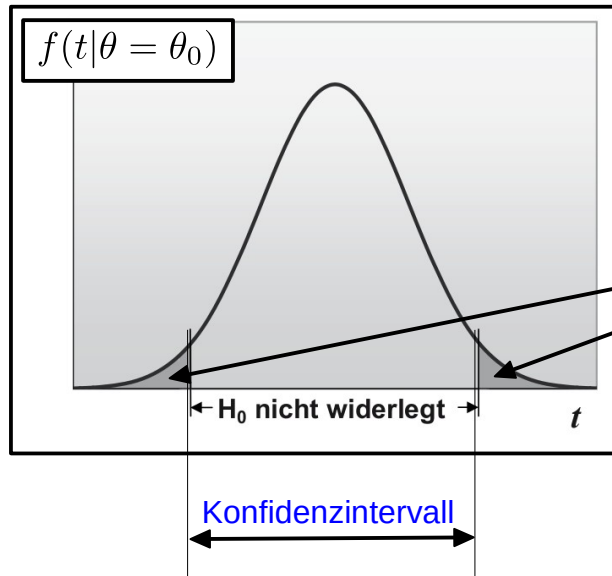
Testverteilung, die bei vorgegebenem  $\theta_0$  abgeleitet werden kann

# Testverteilung

- Um eine Testverteilung  $f(t|\theta = \theta_0)$  angeben zu können, muss bei Parametertests der zu untersuchende Parameter  $\theta$  zunächst auf einen Wert  $\theta = \theta_0$  festgelegt werden.
- Die Testverteilung wird unter Annahme von  $H_0$  entweder analytisch oder mit Hilfe eines **Ensemble Tests** ermittelt.
- Der konkrete Test erfolgt dann als (als einmalige Auswertung von  $t(\vec{x})$ ) auf einer Stichprobe, oder als:

**Punkthypothese:**

$$\theta = \theta_0$$




Der dunkelgraue Bereich kann bei Durchführung des Tests (mit vorgegebener Irrtumswahrscheinlichkeit) ausgeschlossen werden.

# Testverteilung

- Um eine Testverteilung  $f(t|\theta = \theta_0)$  angeben zu können, muss bei Parametertests der zu untersuchende Parameter  $\theta$  zunächst auf einen Wert  $\theta = \theta_0$  festgelegt werden.
- Die Testverteilung wird unter Annahme von  $H_0$  entweder analytisch oder mit Hilfe eines **Ensemble Tests** ermittelt.
- Der konkrete Test erfolgt dann als (als einmalige Auswertung von  $t(\vec{x})$ ) auf einer Stichprobe, oder als:

**Punkthypothese:**

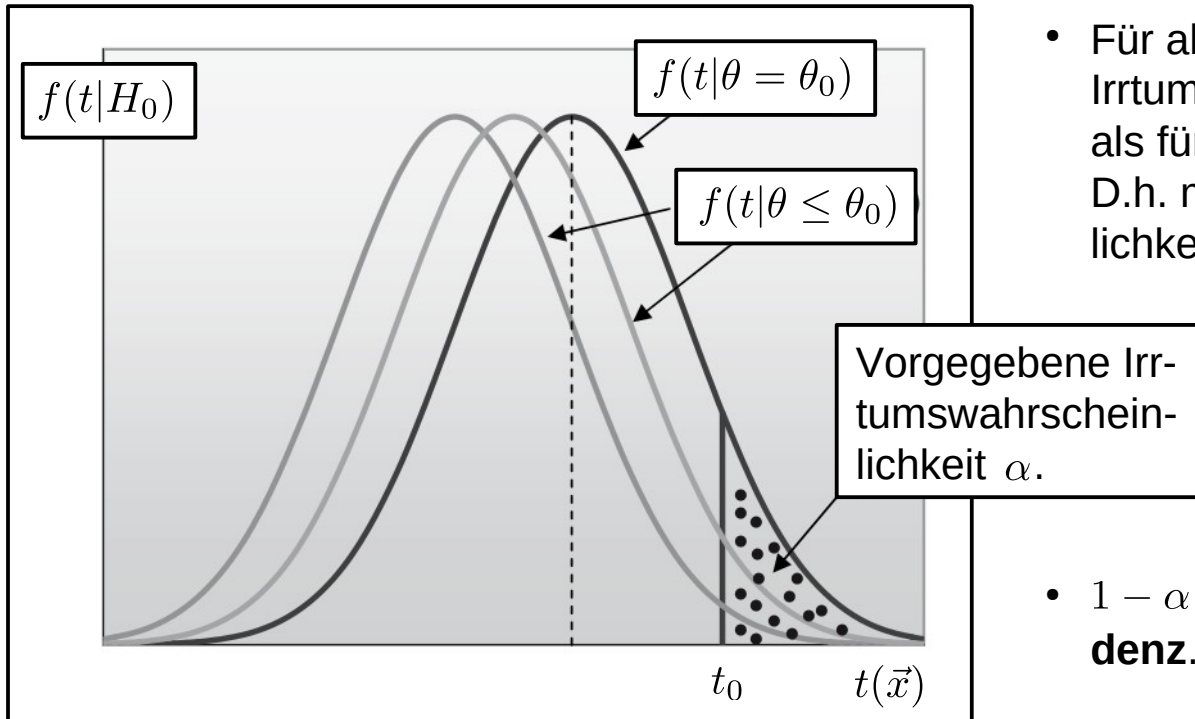
$$\theta = \theta_0$$



Das könnte das einmalige Ergebnis des Hypothesentests sein.

# Irrtumswahrscheinlichkeit und Konfidenz

- Die Irrtumswahrscheinlichkeit wird vor der Anwendung des Tests festgelegt und definiert ab welchem Wert von  $t(\vec{x})$  der Test verworfen wird. Hier am Beispiel einer **oberen Schranke**:

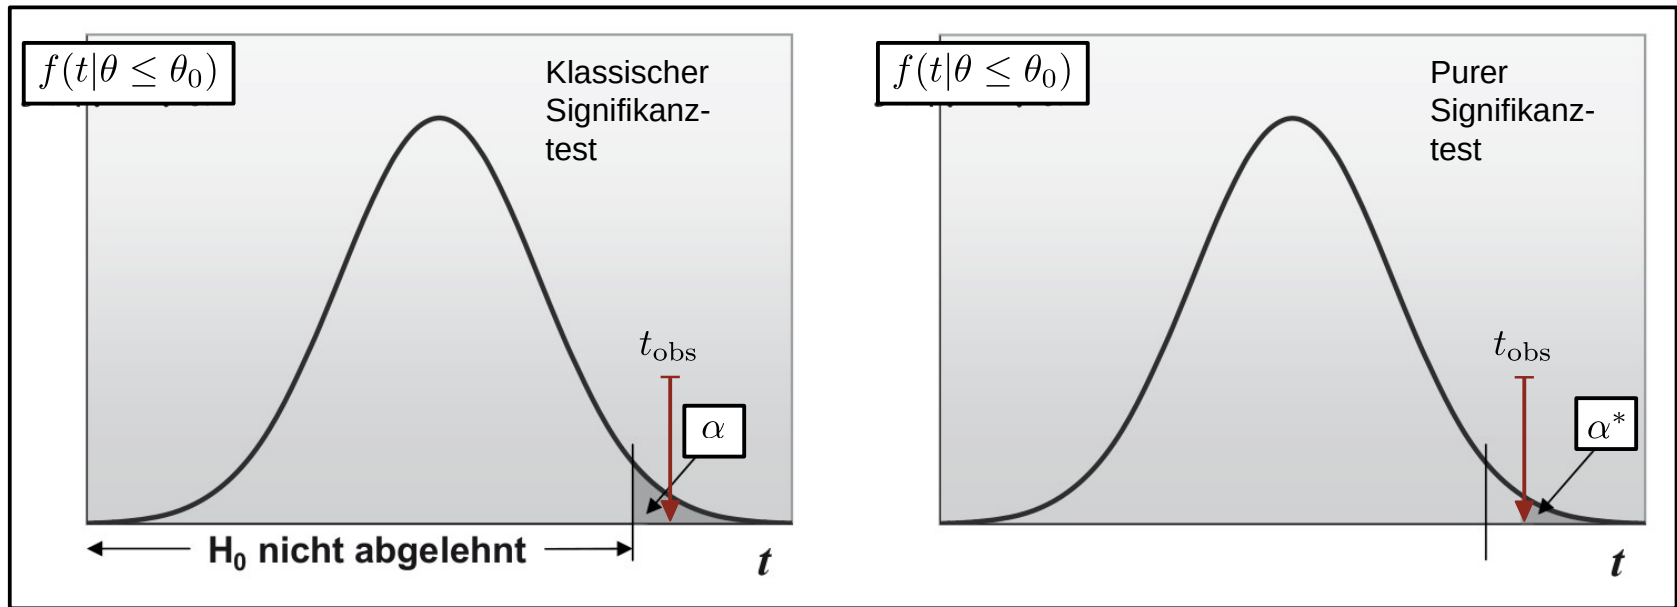


- Für alle Werte  $\theta \leq \theta_0$  ist die Irrtumswahrscheinlichkeit kleiner als für den vorgegebenen Wert  $\theta_0$ . D.h. mit einer Irrtumswahrscheinlichkeit  $\leq \alpha$  ist  $\theta \leq \theta_0$ .
- $1 - \alpha$  bezeichnet man als **Konfidenz**.
- In der frequentistischen Wahrscheinlichkeitsinterpretation entspricht ein solcher Scan von  $\theta$  der **Neymankonstruktion**.

# Klassischer vs. purer Signifikanztest

- Beim klassischen Signifikanztest wird das Signifikanzniveau (d.h. der Parameterbereich ab dem  $H_0$  verworfen wird) a priori festgelegt. Nach dem Test fällt die Entscheidung.
- Es gibt jedoch auch Fälle, bei denen der Signifikanzwert (zusätzlich) angegeben wird und die Interpretation so dem Statistikanwender überlassen bleibt:

↓ Einmalige Auswertung auf Stichprobe



$H_0$  abgelehnt bei  $\alpha = 0.05$

$H_0$  abgelehnt bei  $\alpha^* < \alpha = 0.05$

# Zusammenfassung: Klassischer Signifikanztest


---

- Der klassische Signifikanztest besteht aus den folgenden grundlegenden Schritten:
  - Formulierung der  $H_0$ -Hypothese mit  $\theta = \theta_0$ .

# Zusammenfassung: Klassischer Signifikanztest

---


- Der klassische Signifikanztest besteht aus den folgenden grundlegenden Schritten:
  - Formulierung der  $H_0$ -Hypothese mit  $\theta = \theta_0$ .
  - Wahl einer geeigneten Teststatistik  $t$  und Bestimmung der Testverteilung  $f(t|\theta = \theta_0)$ .






# Zusammenfassung: Klassischer Signifikanztest

- Der klassische Signifikanztest besteht aus den folgenden grundlegenden Schritten:
  - Formulierung der  $H_0$ -Hypothese mit  $\theta = \theta_0$ .
  - Wahl einer geeigneten Teststatistik  $t$  und Bestimmung der Testverteilung  $f(t|\theta = \theta_0)$ .
  - Wahl der Irrtumswahrscheinlichkeit  $\alpha$  und des Ablehnungsbereichs (hier am Bsp. der oberen Schranke).




# Zusammenfassung: Klassischer Signifikanztest

- Der klassische Signifikanztest besteht aus den folgenden grundlegenden Schritten:
  - Formulierung der  $H_0$ -Hypothese mit  $\theta = \theta_0$ .
  - Wahl einer geeigneten Teststatistik  $t$  und Bestimmung der Testverteilung  $f(t|\theta = \theta_0)$ .
  - Wahl der Irrtumswahrscheinlichkeit  $\alpha$  und des Ablehnungsbereichs (hier am Bsp. der oberen Schranke).
  - Stichprobenziehung (=Messung) und Berechnung des realisierten Wertes der Teststatistik  $t_{\text{obs}}$ .



# Zusammenfassung: Klassischer Signifikanztest

- Der klassische Signifikanztest besteht aus den folgenden grundlegenden Schritten:
  - Formulierung der  $H_0$ -Hypothese mit  $\theta = \theta_0$ .
  - Wahl einer geeigneten Teststatistik  $t$  und Bestimmung der Testverteilung  $f(t|\theta = \theta_0)$ .
  - Wahl der Irrtumswahrscheinlichkeit  $\alpha$  und des Ablehnungsbereichs (hier am Bsp. der oberen Schranke).
  - Stichprobenziehung (=Messung) und Berechnung des realisierten Wertes der Teststatistik  $t_{\text{obs}}$ .
  - Testentscheidung und ggf. Ablehnung von  $H_0$ .



# Beispiel aus der klassischen Statistik

---

- **Hypothese:** Männer in den Niederlanden sind größer als der „Durchschnitts“-Europäer. Das arithmetische Mittel der Körpergrößen in Europa liegt bei  $\mu_0 = 174$  cm mit einer Standardabweichung von  $\sigma_0 = \pm 10$  cm.

# Beispiel aus der klassischen Statistik

---

- **Hypothese:** Männer in den Niederlanden sind größer als der „Durchschnitts“-Europäer. Das arithmetische Mittel der Körpergrößen in Europa liegt bei  $\mu_0 = 174$  cm mit einer Standardabweichung von  $\sigma_0 = \pm 10$  cm.
  
- $H_0: \mu \leq \mu_0 = 174$  cm mit:  $\sigma = \sigma_0$  (d.h. „Niederländer sind gleichgroß oder kleiner als Durchschnitts-Europäer“)

# Beispiel aus der klassischen Statistik

- **Hypothese:** Männer in den Niederlanden sind größer als der „Durchschnitts“-Europäer. Das arithmetische Mittel der Körpergrößen in Europa liegt bei  $\mu_0 = 174$  cm mit einer Standardabweichung von  $\sigma_0 = \pm 10$  cm.
- $H_0: \mu \leq \mu_0 = 174$  cm mit:  $\sigma = \sigma_0$  (d.h. „Niederländer sind gleichgroß oder kleiner als Durchschnitts-Europäer“)


- Teststatistik:

$$t(\mu) = \frac{\bar{x} - \mu_0}{\sigma_0 / \sqrt{n}} \propto \varphi(\mu, 0, 1)$$

$\mu = \bar{x}$  : Mittelwert der Stichprobe

$n$  : Länge der Stichprobe

$\varphi(\mu, 0, 1)$  : Normalverteilung



# Beispiel aus der klassischen Statistik

- **Hypothese:** Männer in den Niederlanden sind größer als der „Durchschnitts“-Europäer. Das arithmetische Mittel der Körpergrößen in Europa liegt bei  $\mu_0 = 174$  cm mit einer Standardabweichung von  $\sigma_0 = \pm 10$  cm.
- $H_0: \mu \leq \mu_0 = 174$  cm mit:  $\sigma = \sigma_0$  (d.h. „Niederländer sind gleichgroß oder kleiner als Durchschnitts-Europäer“)


- Teststatistik:

$$t(\mu) = \frac{\bar{x} - \mu_0}{\sigma_0 / \sqrt{n}} \propto \varphi(\mu, 0, 1)$$

$\mu = \bar{x}$  : Mittelwert der Stichprobe

$n$  : Länge der Stichprobe

$\varphi(\mu, 0, 1)$  : Normalverteilung




- Irrtumswahrscheinlichkeit:

$$\alpha = 0,05 \quad t = 1.645^1$$

<sup>1</sup> bei Standardnormalverteilung entspricht  $t = 1.645$  dem Signifikanzniveau für  $\alpha = 0.05$ .

# Irrtumswahrscheinlichkeiten & Signifikanzniveaus


- Als Referenz für die weitere Vorlesung finden Sie hier eine Zuordnung regelmäßig verwendeter Irrtumswahrscheinlichkeiten  $\alpha$  zu Signifikanzniveaus der Standardnormalverteilung  $\varphi(x, 0, 1)$ .



$\alpha$	Signifikanzniveau $z$	
	Einseitig	Zweiseitig
0.317	0.782	1
0.1	1.285	1.645
0.05	1.645	1.960
0.045	1.695	2
0.010	2.325	2.580
0.003	—	3
$5.7 \times 10^{-7}$	—	5

**NB:** Die  $\pm 1\sigma$  und  $\pm 2\sigma$  Fehlerbalken, die Sie kennen entsprechen den zweiseitigen Signifikanzniveaus von  $z = 1, 2$ .

$$\mu \pm \sigma_{0.68} \text{ @ } 68\% \text{ CL}$$





# Beispiel aus der klassischen Statistik

---

- Es wurden drei unabhängige Tests mit wachsendem Umfang durchgeführt:
- Auswertung und Entscheidung:

$$\bar{x}_1 = 176 \text{ cm}; \quad n_1 = 36$$

$$\bar{x}_2 = 175 \text{ cm}; \quad n_2 = 100$$

$$\bar{x}_3 = 175 \text{ cm}; \quad n_3 = 400$$

# Beispiel aus der klassischen Statistik

- Es wurden drei unabhängige Tests mit wachsendem Umfang durchgeführt:
- Auswertung und Entscheidung:

$$\bar{x}_1 = 176 \text{ cm}; \quad n_1 = 36$$

$$\bar{x}_2 = 175 \text{ cm}; \quad n_2 = 100$$


$$\bar{x}_3 = 175 \text{ cm}; \quad n_3 = 400$$

$$t = \frac{2 \text{ cm}}{10 \text{ cm}/\sqrt{36}} = 1.2 < 1.654$$



$H_0$

kann nicht ausgeschlossen werden



# Beispiel aus der klassischen Statistik

- Es wurden drei unabhängige Tests mit wachsendem Umfang durchgeführt:
- Auswertung und Entscheidung:

$$\bar{x}_1 = 176 \text{ cm}; \quad n_1 = 36$$

$$t = \frac{2 \text{ cm}}{10 \text{ cm}/\sqrt{36}} = 1.2 < 1.654$$



$H_0$

kann nicht ausgeschlossen werden

$$\bar{x}_2 = 175 \text{ cm}; \quad n_2 = 100$$


$$t = \frac{1 \text{ cm}}{10 \text{ cm}/\sqrt{100}} = 1 < 1.654$$



$H_0$

kann nicht ausgeschlossen werden

$$\bar{x}_3 = 175 \text{ cm}; \quad n_3 = 400$$



# Beispiel aus der klassischen Statistik

- Es wurden drei unabhängige Tests mit wachsendem Umfang durchgeführt:
- Auswertung und Entscheidung:

$$\bar{x}_1 = 176 \text{ cm}; \quad n_1 = 36$$

$$t = \frac{2 \text{ cm}}{10 \text{ cm}/\sqrt{36}} = 1.2 < 1.654$$



$H_0$

kann nicht ausgeschlossen werden

$$\bar{x}_2 = 175 \text{ cm}; \quad n_2 = 100$$

$$t = \frac{1 \text{ cm}}{10 \text{ cm}/\sqrt{100}} = 1 < 1.654$$



$H_0$

kann nicht ausgeschlossen werden


$$\bar{x}_3 = 175 \text{ cm}; \quad n_3 = 400$$

$$t = \frac{1 \text{ cm}}{10 \text{ cm}/\sqrt{400}} = 2 > 1.654$$



$H_0$

kann ausgeschlossen werden



# Beispiel aus der klassischen Statistik

---

- Es wurden drei unabhängige Tests mit wachsendem Umfang durchgeführt:
- Auswertung und Entscheidung:

$$\bar{x}_1 = 176 \text{ cm}; \quad n_1 = 36$$

$$\bar{x}_2 = 175 \text{ cm}; \quad n_2 = 100$$

$$\bar{x}_3 = 175 \text{ cm}; \quad n_3 = 400$$

 $H_0$ 

kann nicht ausgeschlossen werden

 $H_0$ 

kann nicht ausgeschlossen werden

 $H_0$ 

kann ausgeschlossen werden

# Anmerkungen zu Hypothesentests

---

- Das Beispiel veranschaulicht die wichtigsten Punkte, die bei der Verwendung von Hypothesentests zu beachten sind:
  - Beim einfachen Hypothesentest ist die Hypothese als „Gegenhypothese“ zu formulieren (im Bsp.:  $H_0: \mu \leq \mu_0 = 174 \text{ cm}$  mit:  $\sigma = \sigma_0$ ). Für die Hypothese selbst ist keine Testfunktion angebbbar.
  - Nicht-Widerlegung ist (statistisch) schwächer, als Widerlegung (im Bsp. folgt auf zweimalige Nicht-Widerlegung eine Widerlegung).
  - Die Widerlegung von  $H_0$  hängt von der Vorgabe von  $\alpha$  ab. („Wer das Risiko auf sich nimmt, mit größerer Wahrscheinlichkeit  $H_0$  irrtümlich zu verwerfen verwirft schneller“.)
  - Dabei ist zu beachten, dass die Irrtumswahrscheinlichkeit nur die Wahrscheinlichkeit abbildet  $H_0$  irrtümlich zu *verwerfen*. Über die irrtümliche *Annahme* von  $H_0$  wird zunächst keine Aussage getroffen.
- Ein Hypothesentest erfordert also eine klare Fragestellung und ein klares Bewußtsein der (meist semantischen) Schwächen und Fehlerquellen.

# 6 Hypothesentests in der modernen Physik

---

## 6.2 Fehler 1. und 2. Art

Für die folgende Diskussion legen wir die Befüllung von Bierflaschen zugrunde. Die Flaschen sollen mit einer Irrtumswahrscheinlichkeit von  $\alpha = 0.05$  nicht mit mehr als 500 ml Bier befüllt sein (obere Schranke mit 95% Konfidenz). Die Befüllung *einer* Flasche erfolgt mit einer Varianz von  $\sigma_0 = \pm 10$  ml. Regelmäßige Stichproben der Länge  $n$  sollen die Qualität der Befüllung sicherstellen.



# Fehler 1. & 2. Art

- Für die Beurteilung eines Hypothesentests ist mehr als eine Irrtumswahrscheinlichkeit von Relevanz:

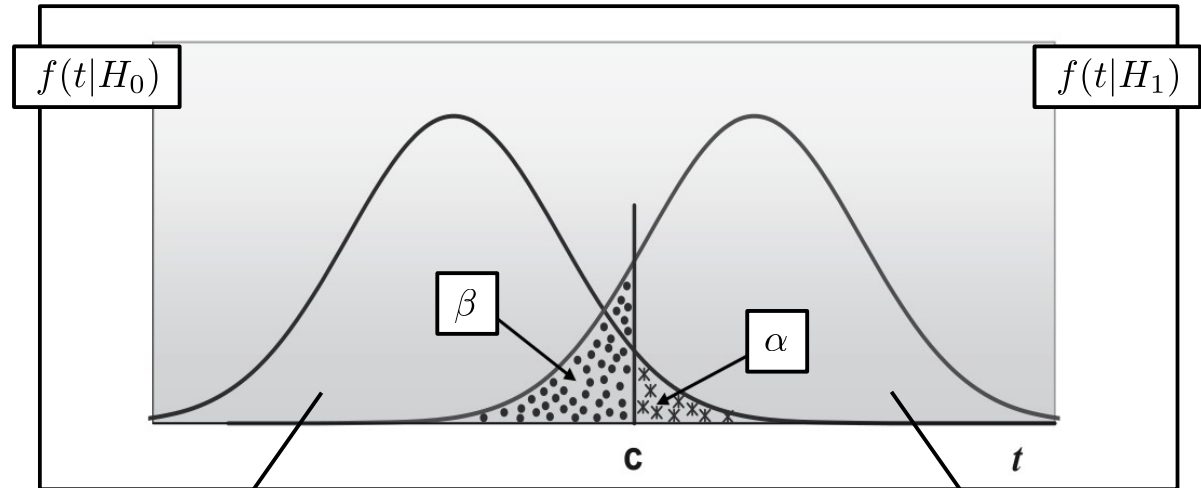
Wir formulieren das Beispiel als „Zwei Hypothesen Test“:  $H_0 : \mu \leq c$   $H_1 : \mu > c$

$\alpha$  : Fehler 1. Art

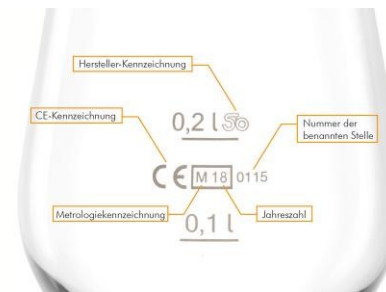
$\beta$  : Fehler 2. Art

$c$  : Kritischer Wert

Der a priori festgelegte kritische Wert entscheidet über die Annahme von  $H_0$  oder  $H_1$ .



Füllmenge unter  
Maximalwert ( $H_0$ )



Füllmenge über  
Maximalwert ( $H_1$ )



# Fehler 1. & 2. Art

- Für die Beurteilung eines Hypothesentests ist mehr als eine Irrtumswahrscheinlichkeit von Relevanz:


Wir formulieren das Beispiel als „Zwei Hypothesen Test“:  $H_0 : \mu \leq c$     $H_1 : \mu > c$

$\alpha$  : Fehler 1. Art

$\beta$  : Fehler 2. Art

$c$  : Kritischer Wert

Der a priori festgelegte kritische Wert entscheidet über die Annahme von  $H_0$  oder  $H_1$ .



	$H_0$ angenommen $H_1$ abgelehnt	$H_1$ angenommen $H_0$ abgelehnt
$H_0$ wahr $H_1$ falsch	richtige Entscheidung ( $1 - \alpha$ )	Fehler 1. Art, $\alpha$
$H_1$ wahr $H_0$ falsch	Fehler 2. Art, $\beta$	richtige Entscheidung ( $1 - \beta$ )

# Operationscharakteristik & Trennschärfe

---

- Bei vorgegebenem  $\alpha$  sind  $\beta$  und  $c$  festgelegt.
- Für den häufigen Fall zweier Hypothesen  $H_0$  und  $H_1$  mit den Parametern  $\mu_0$  und  $\mu_1$  gilt für  $\beta$  ceteris paribus (c.p.) d.h. wenn die jeweils anderen Variablen konstant gehalten werden:
  - $\beta(\alpha)$  (c.p.) (je kleiner  $\alpha$  desto größer  $\beta$ ).
  - $\beta(\mu_1 - \mu_0)$  (c.p.) (je größer die Differenz  $\mu_1 - \mu_0$  desto kleiner  $\beta$ ).
  - $\beta(n)$  (c.p.) (je größer  $n$ , desto kleiner  $\beta$ ).
- Die Abhängigkeit  $\beta(\alpha, \mu_1 - \mu_0, n)$  bezeichnet man als **Operationscharakteristik**.
- Die Funktion  $1 - \beta(\alpha, \mu_1 - \mu_0, n)$  bezeichnet man als **Ergänzung zu 1** oder **Gütefunktion**. Der Funktionswert bei vorgegebenem  $\mu_1$  heißt **Trennschärfe**.
- Ist z.B.  $\alpha$  vorgegeben, dann wird man aus allen möglichen Testverfahren dasjenige mit dem kleinsten  $\beta$  (d.h. der größten Trennschärfe) auswählen.

# Operationscharakteristik – am Beispiel –

---

- In unserem Beispiel testen wir die Füllhöhe durch, ziehen einer Stichprobe der Länge  $n = 10$  und anschließende Mittelwertbildung:

$$\mu = \bar{x} = \frac{1}{10} \sum_{i=1}^{10} x_i$$

- Wir können davon ausgehen, dass die gewählte Teststatistik  $\mu$  normalverteilt ist. Für die Wurzel der Varianz von  $\mu$  gilt:

$$\sigma_{\mu} = \frac{\sigma_0}{\sqrt{10}} = \frac{10 \text{ ml}}{\sqrt{10}} \approx 3.16 \text{ ml}$$

- Die Füllhöhe wird mit einer Irrtumswahrscheinlichkeit von  $\alpha = 0.05$  beanstandet falls

$$\mu > c \equiv 500 \text{ ml} + 1.645 \sigma_{\mu} = 500 \text{ ml} + (1.645 \cdot 3.16) \text{ ml} \approx 505 \text{ ml}$$

(siehe [Folie 11](#))

# Operationscharakteristik – am Beispiel –

---

- In unserem Beispiel testen wir die Füllhöhe durch, ziehen einer Stichprobe der Länge  $n = 10$  und anschließende Mittelwertbildung:

$$\mu = \bar{x} = \frac{1}{10} \sum_{i=1}^{10} x_i$$

- Wir können davon ausgehen, dass die gewählte Teststatistik  $\mu$  normalverteilt ist. Für die Wurzel der Varianz von  $\mu$  gilt:

$$\sigma_{\mu} = \frac{\sigma_0}{\sqrt{10}} = \frac{10 \text{ ml}}{\sqrt{10}} \approx 3.16 \text{ ml}$$

- Die Füllhöhe wird mit einer Irrtumswahrscheinlichkeit von  $\alpha = 0.05$  beanstandet falls

$$\mu > c \equiv 500 \text{ ml} + 1.645 \sigma_{\mu} = 500 \text{ ml} + (1.645 \cdot 3.16) \text{ ml} \approx 505 \text{ ml}$$

(siehe [Folie 11](#))


- Falls die Flaschen wirklich mit  $\mu_0 = 500 \text{ ml}$  befüllt sind, wird der Füllstand mit einer Wahrscheinlichkeit von  $\alpha = 0.05$  irrtümlich beanstandet. Wie groß ist die Wahrscheinlichkeit für Nicht-Beanstandung, falls die Füllhöhe tatsächlich höher oder niedriger ist?

# Operationscharakteristik – am Beispiel –


- Unter Variation der Hypothese  $H_1$  erhält man die Operationscharakteristik aus:

$$\beta(\mu|H_1) = \int_{-\infty}^{c(\alpha)} \varphi(x, \mu, \sigma_\mu) dx$$

Operationscharakteristik:



Gütefunktion:

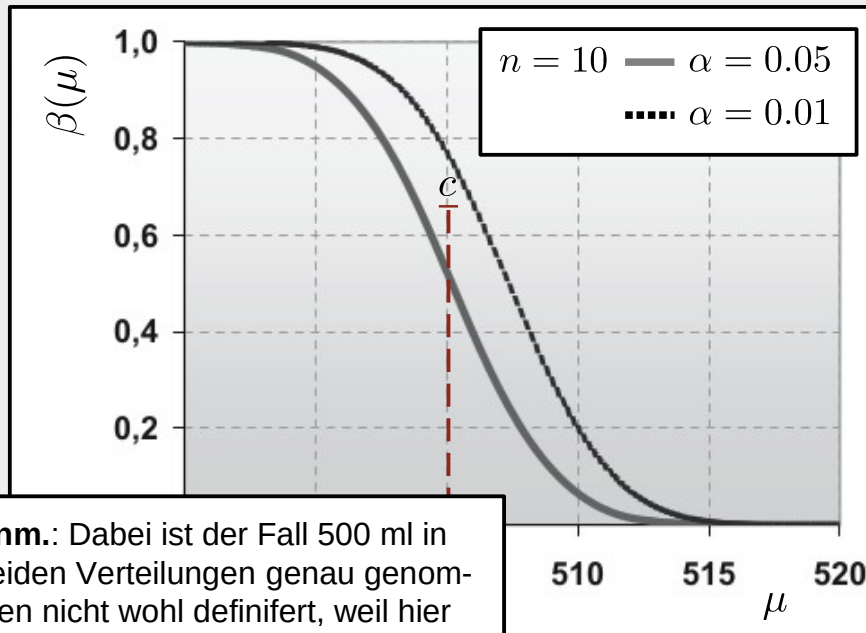


# Operationscharakteristik – am Beispiel –

- Unter Variation der Hypothese  $H_1$  erhält man die Operationscharakteristik aus:


$$\beta(\mu|H_1) = \int_{-\infty}^{c(\alpha)} \varphi(x, \mu, \sigma_\mu) dx$$

Operationscharakteristik:



**Anm.:** Dabei ist der Fall 500 ml in beiden Verteilungen genau genommen nicht wohl definiert, weil hier kein Fehler in der Befüllung vorliegt.

Gütefunktion:




# Operationscharakteristik – am Beispiel –

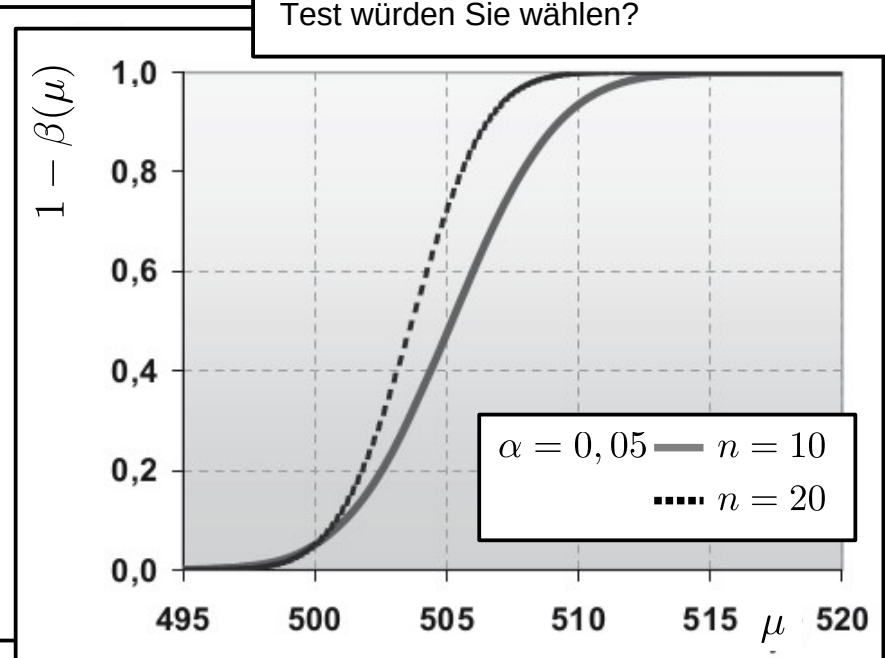
- Unter Variation der Hypothese  $H_1$  erhält man die Operationscharakteristik aus:

$$\beta(\mu|H_1) = \int_{-\infty}^{c(\alpha)} \varphi(x, \mu, \sigma_\mu) dx$$

Operationscharakteristik:



Gütefunktion:



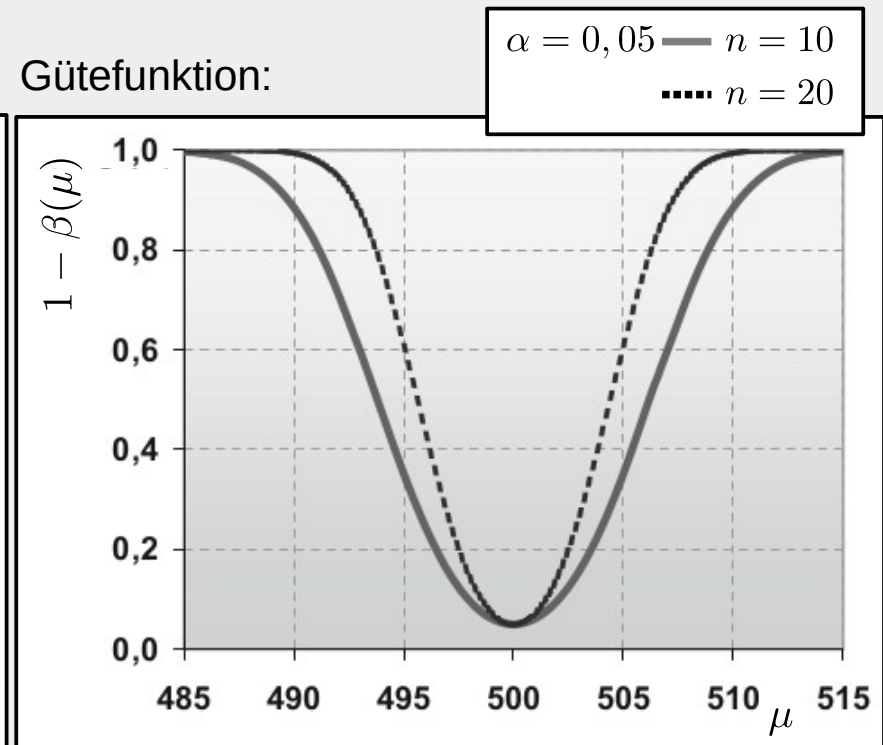
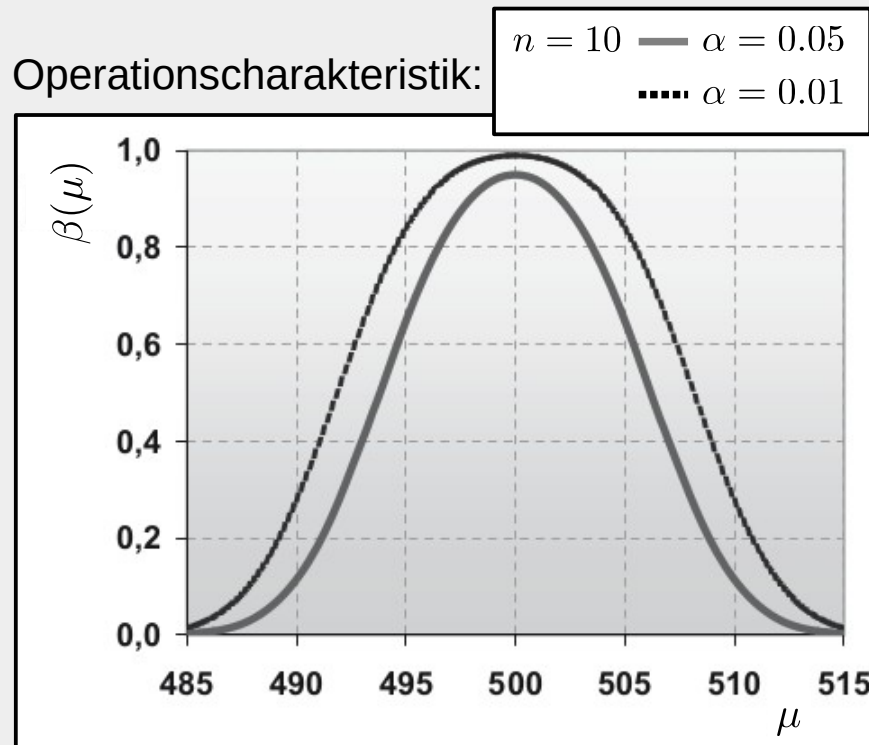
Sie sehen hier zwei Tests unterschiedlicher Stichprobenlänge für  $\alpha = 0.05$ . Welchen Test würden Sie wählen?

# Operationscharakteristik – am Beispiel –

Anm.: Hier sehen Sie das Beispiel eines zweiseitigen Hypothesentests (vgl. Folie 6).

- Unter Variation der Hypothese  $H_1$  erhält man die Operationscharakteristik aus:

$$\beta(\mu|H_1) = \int_{-\infty}^{c(\alpha)} \varphi(x, \mu, \sigma_\mu) dx$$





# Effizienz und Reinheit

---

- Bei Klassifikationsproblemen werden Ereignisse oftmals entweder einem Typ-0 oder einem Typ-1 zugeordnet.
- In diesem einfachen Fall besteht die folgende Relation zwischen dem Fehler 1. und 2. Art und den häufig verwendeten Begriffen **Effizienz** und **Reinheit**:

$$\epsilon = \frac{\text{Richtig erkannte Ereignisse vom Typ-0}}{\text{Alle Ereignisse vom Typ-0}} = 1 - \alpha \quad (\text{Effizienz})$$

$$\rho = \frac{(1 - \alpha) N_0}{(1 - \alpha) N_0 + \beta N_1} \quad (\text{Reinheit})$$

$\alpha$  : Fehler 1. Art

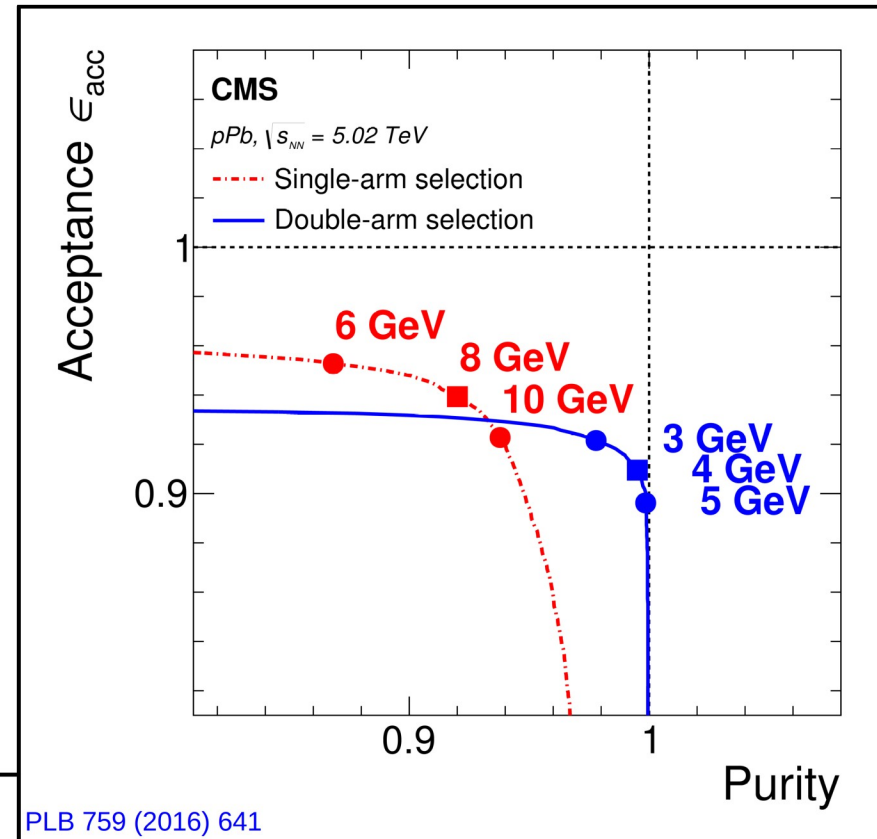


$\beta$  : Fehler 2. Art

$N_0$  : Wahre Anzahl der Ereignisse vom Typ-0

$N_1$  : Wahre Anzahl der Ereignisse vom Typ-1

# ROC Kurve




- In solchen Fällen, in denen sich Effizienz und Reinheit definieren lassen, wird die Gütefunktion eines Tests auch durch die Kurve der *Receiver Operating Characteristic* (**ROC**) angegeben.



# ROC Kurve

- In solchen Fällen, in denen sich Effizienz und Reinheit definieren lassen, wird die Gütefunktion eines Tests auch durch die Kurve der *Receiver Operating Characteristic* (**ROC**) angegeben.

- Sie würden i.a. den Arbeitspunkt in der ROC Kurve wählen, der bei dieser Darstellung am weitesten oben rechts in der Kurve liegt.
- In Einzelfällen kann es auch von Vorteil sein von dieser Wahl abzuweichen, wenn Sie z.B. auf hohe Effizienz angewiesen sind, oder sich im Gegenzug niedrige Effizienz „leisten“ können
- Als Maß für die Trennschärfe eines Algorithmus gibt man in diesen einfachen Fällen oft das Integral unter der ROC Kurve an (*area under curve* **AUC**).



# 6 Hypothesentests in der modernen Physik

---

## 6.3 Klassische Beispiele und Anwendungen

Im Folgenden werden wir einige Beispiele für Hypothesentests explizit vorrechnen, anhand derer Sie ein Gefühl für die Vielfalt solcher Tests entwickeln können.



# Beispiel-1: Zweistichprobentest

---

- **Hypothese:** Hochschulabsolventinnen erhalten bei gleicher Varianz niedrigere Anfangsgehälter ( $\mu_1$ ) als Hochschulabsolventen ( $\mu_2$ ). Die Überprüfung erfolgt durch zwei Zufallsstichproben jeweils vom Umfang  $n_1, n_2 = 200$ .

# Beispiel-1: Zweistichprobentest

---

- **Hypothese:** Hochschulabsolventinnen erhalten bei gleicher Varianz niedrigere Anfangsgehälter ( $\mu_1$ ) als Hochschulabsolventen ( $\mu_2$ ). Die Überprüfung erfolgt durch zwei Zufallsstichproben jeweils vom Umfang  $n_1, n_2 = 200$ .
- $H_0$ : „Die Gehälter der Absolventinnen sind gleich oder höher“ ( $H_0: \mu_1 \geq \mu_2$ ).
- Teststatistik (Anm.: Streng formuliert für die Bestimmung einer unteren Schanke):

$$t = \frac{\bar{x}_1 - \bar{x}_2}{\sqrt{s^2 \left( \frac{1}{n_1} + \frac{1}{n_2} \right)}} \propto \varphi(x, 0, 1)$$

- Irrtumswahrscheinlichkeit:  $\alpha = 0.05$  entspricht: ( $z = -1.645$ ) (siehe [Folie 11](#))

# Beispiel-1: Zweistichprobentest

- **Hypothese:** Hochschulabsolventinnen erhalten bei gleicher Varianz niedrigere Anfangsgehälter ( $\mu_1$ ) als Hochschulabsolventen ( $\mu_2$ ). Die Überprüfung erfolgt durch zwei Zufallsstichproben jeweils vom Umfang  $n_1, n_2 = 200$ .
- $H_0$ : „Die Gehälter der Absolventinnen sind gleich oder höher“ ( $H_0: \mu_1 \geq \mu_2$ ).
- Teststatistik (Anm.: Streng formuliert für die Bestimmung einer unteren Schanke):

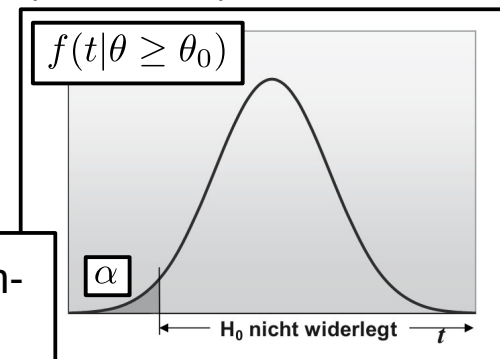
$$t = \frac{\bar{x}_1 - \bar{x}_2}{\sqrt{s^2 \left( \frac{1}{n_1} + \frac{1}{n_2} \right)}} \propto \varphi(x, 0, 1)$$

- Irrtumswahrscheinlichkeit:  $\alpha = 0.05$  entspricht: ( $z = -1.645$ ) (siehe Folie 11)
- Stichprobenergebnisse:  $\bar{x}_1 = 2\,200$        $\bar{x}_2 = 2\,300$   
 $s_1^2 = 700\,000$        $s_2^2 = 920\,000$

$$s^2 = \frac{199 \cdot 700\,000 + 199 \cdot 920\,000}{398} = 810\,000$$

$$t = \frac{2\,200 - 2\,300}{900 \cdot \frac{1}{10}} = -\frac{100}{90} = -1.11 > -1.645$$

(siehe Folie 5)



d.h.  $H_0$  kann durch diese Stichprobe nicht widerlegt werden.

## Beispiel-2: Varianzanalyse

---

- **Hypothese:** In einer Untersuchung zur Verkehrssituation in der Innenstadt geben zufällig Befragte ein Punkturteil ab (je höher, desto positiver). Die Untersuchung wird getrennt für Innenstadtbewohner ( $\mu_1, n_1 = 36$ ) und Pendler ( $\mu_2, n_2 = 41$ ) vorgenommen. Ist die Bewertung innerhalb beider Personengruppen gleich?
  - $H_0$ : „Beide Gruppen beurteilen die Verkehrssituation gleich“ ( $H_0: \mu_1 = \mu_2$ ).
  - Wir führen diesen Test zunächst als F-Test durch:

# Befragte:  $n = n_1 + n_2 = 77$    # Gruppen:  $r = 2$

$$\text{a) } t = \frac{\frac{1}{r-1} s_{\text{ext}}^2}{\frac{1}{n-r} s_{\text{int}}^2} = \frac{\frac{1}{r-1} \sum_{g=1}^r n_g (\bar{x}_g - \bar{x})^2}{\frac{1}{n-r} \sum_{g=1}^r \sum_{i=1}^{n_g} (x_{gi} - \bar{x}_g)^2} \propto f(x, r-1, n-r)$$

$s_{\text{ext}}^2$  : Varianz zwischen den Gruppen

$s_{\text{int}}^2$  : Varianz innerhalb der Gruppen



## Beispiel-2: Varianzanalyse

- **Hypothese:** In einer Untersuchung zur Verkehrssituation in der Innenstadt geben zufällig Befragte ein Punkturteil ab (je höher, desto positiver). Die Untersuchung wird getrennt für Innenstadtbewohner ( $\mu_1, n_1 = 36$ ) und Pendler ( $\mu_2, n_2 = 41$ ) vorgenommen. Ist die Bewertung innerhalb beider Personengruppen gleich?
  - $H_0$ : „Beide Gruppen beurteilen die Verkehrssituation gleich“ ( $H_0: \mu_1 = \mu_2$ ).
  - Wir führen diesen Test zunächst als F-Test durch:

# Befragte:  $n = n_1 + n_2 = 77$  # Gruppen:  $r = 2$

$$\text{a) } t = \frac{\frac{1}{r-1} s_{\text{ext}}^2}{\frac{1}{n-r} s_{\text{int}}^2} = \frac{\frac{1}{r-1} \sum_{g=1}^r n_g (\bar{x}_g - \bar{x})^2}{\frac{1}{n-r} \sum_{g=1}^r \sum_{i=1}^{n_g} (x_{gi} - \bar{x}_g)^2} \propto f(x, r-1, n-r)$$

$s_{\text{ext}}^2$  : Varianz zwischen den Gruppen

$s_{\text{int}}^2$  : Varianz innerhalb der Gruppen

NB: Dies ist ein Test auf  $s_{\text{ext}}^2 = s_{\text{int}}^2$ .

Diese Teststatistik folgt der **Fisher-Verteilung**, für den Quotienten zweier  $\chi^2$ -verteilter Zufallsgrößen:

- $r - 1$  entspricht den Freiheitsgraden der Verteilung im Zähler.
- $n - r$  entspricht den Freiheitsgraden der Verteilung im Nenner.
- Es handelt sich hierbei um einen **F-Test**.
- Die einfachste Art die CDF zu  $f(F)$  auszuwerten ist mit Hilfe von **scipy**. Alternativ können Sie die Werte aus **Tabellen** auslesen.

# Beispiel-2: Varianzanalyse

- Irrtumswahrscheinlichkeit:  $\alpha = 0.05$   $1 - F(3.968|1, 75) = 0.05$

Z.B. bestimmt mit:  
`scipy.stats.f.cdf(3.968, 1, 75)`.

- Stichprobenergebnisse:

$$\bar{x}_1 = 50 \quad \bar{x}_2 = 48.4 \quad \bar{x} = 49.15$$

$$s_1^2 = 8.4 \quad s_2^2 = 7.5$$

$$\text{a) } \sum_{g=1}^2 n_g (\bar{x}_g - \bar{x})^2 = 36 \cdot (50 - 49.15)^2 + 41 \cdot (48.4 - 49.15)^2 = 49.0725$$

$$\sum_{g=1}^2 \sum_{i=1}^{n_g} (x_{gi} - \bar{x}_g)^2 = \sum_{g=1}^2 (n_g - 1) \sigma_g^2 = 35 \cdot 8.4 + 40 \cdot 7.5 = 594$$

$$t = \frac{49.0725}{\frac{1}{75} \cdot 594} = 6.196 (> 3.968)$$

- Testentscheidung:  $H_0$  ist widerlegt ( $\alpha^* = 0.015$ ), die Verkehrssituation wird unterschiedlich bewertet.

## Beispiel-2 als Zweistichprobentest

---

- **Hypothese:** In einer Untersuchung zur Verkehrssituation in der Innenstadt geben zufällig Befragte ein Punkturteil ab (je höher, desto positiver). Die Untersuchung wird getrennt für Innenstadtbewohner ( $\mu_1, n_1 = 36$ ) und Pendler ( $\mu_2, n_2 = 41$ ) vorgenommen. Ist die Bewertung innerhalb beider Personengruppen gleich?
- $H_0$ : „Beide Gruppen beurteilen die Verkehrssituation gleich“ ( $H_0: \mu_1 = \mu_2$ ).
- Sie können den Test auch auf der Teststatistik von [Folie 29](#) durchführen:

$$\text{b) } t = \frac{|\bar{x}_1 - \bar{x}_2|}{\sqrt{s^2 \left( \frac{1}{n_1} + \frac{1}{n_2} \right)}} \propto \varphi(x, 0, 1)$$

**Anm.:** Achtung im Gegensatz zu Folie 29 steht hier ein Betragsstrich im Zähler. Wir führen nämlich einen zweiseitigen Test durch.

# Beispiel-2 als Zweistichprobentest

---

- Irrtumswahrscheinlichkeit:  $\alpha = 0.05$   $z = 1.96$  (diesesmal zweiseitig! Siehe [Folie 11](#))
- Stichprobenergebnisse:

$$\bar{x}_1 = 50 \quad \bar{x}_2 = 48.4 \quad \bar{x} = 49.15$$

$$s_1^2 = 8.4 \quad s_2^2 = 7.5$$

# Beispiel-2 als Zweistichprobentest

---

- Irrtumswahrscheinlichkeit:  $\alpha = 0.05$   $z = 1.96$  (diesesmal zweiseitig! Siehe [Folie 11](#))
- Stichprobenergebnisse:

$$\bar{x}_1 = 50 \quad \bar{x}_2 = 48.4 \quad \bar{x} = 49.15$$

$$s_1^2 = 8.4 \quad s_2^2 = 7.5$$

$$\text{b) } s^2 = \frac{35 \cdot 8.4 + 40 \cdot 7.5}{75} = 7.92$$

$$t = \frac{50 - 48.4}{\sqrt{7.92 \cdot \left(\frac{1}{36} + \frac{1}{41}\right)}} = 2.489 (> 1.96)$$

- Testentscheidung:  $H_0$  ist widerlegt ( $\alpha^* = 0.013$ ), die Verkehrssituation wird unterschiedlich bewertet.

# Beispiel-2 als Zweistichprobentest

---

- Irrtumswahrscheinlichkeit:  $\alpha = 0.05$   $z = 1.96$  (diesesmal zweiseitig! Siehe [Folie 11](#))

- Stichprobenergebnisse:


$$\bar{x}_1 = 50 \quad \bar{x}_2 = 48.4 \quad \bar{x} = 49.15$$

$$s_1^2 = 8.4 \quad s_2^2 = 7.5$$

- Testentscheidung:  $H_0$  ist widerlegt ( $\alpha^* = 0.013$ ), die Verkehrssituation wird unterschiedlich bewertet.

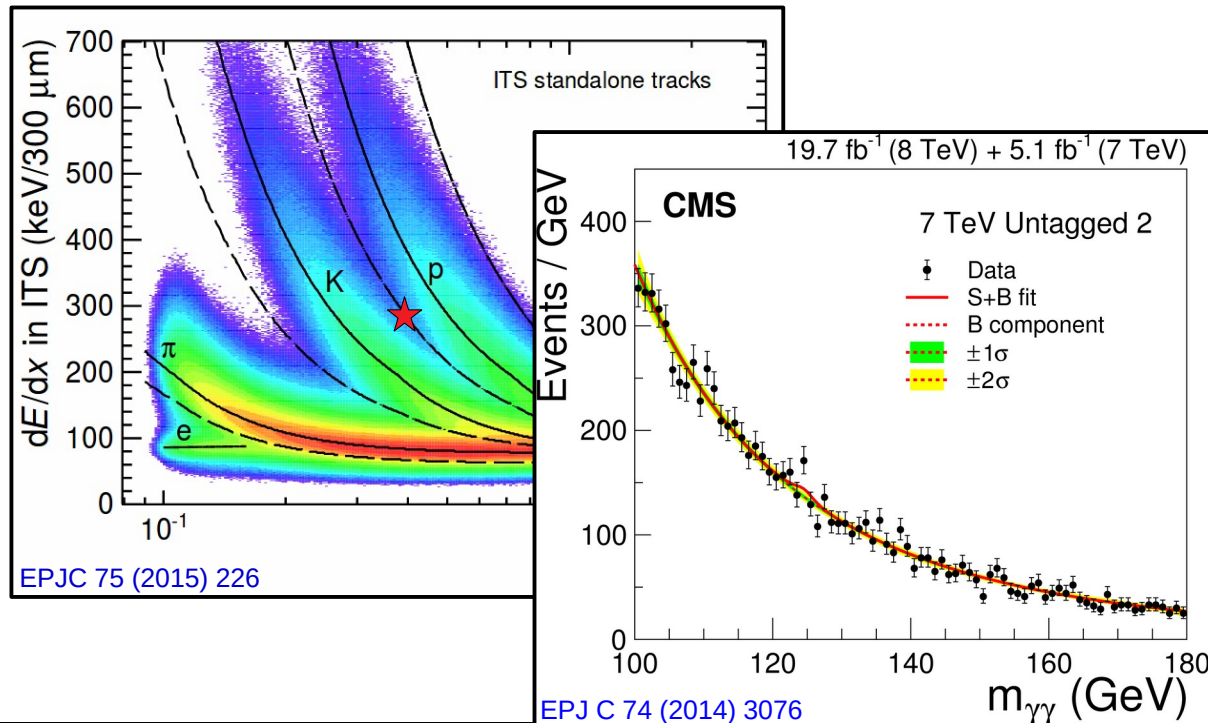
# Wichtigste Hypothesentests in der (Teilchen-)physik

- Ist die Energiedeposition eines Teilchens mit vorgegebenem Impuls in Materie kompatibel mit der Teilchenhypothese eines Elektrons, Pions, Kaons oder Protons?



# Wichtigste Hypothesentests in der (Teilchen-)physik




- Ist die Energiedeposition eines Teilchens mit vorgegebenem Impuls in Materie kompatibel mit der Teilchenhypothese eines Elektrons, Pions, Kaons oder Protons?
- Weisen die Daten auf die Existenz eines neues Teilchens hin?





# Wichtigste Hypothesentests in der (Teilchen-)physik

- Ist die Energiedeposition eines Teilchens mit vorgegebenem Impuls in Materie kompatibel mit der Teilchenhypothese eines Elektrons, Pions, Kaons oder Protons?
- Weisen die Daten auf die Existenz eines neues Teilchens hin?
- Sind zwei oder mehrere Messungen der vermeintlich gleichen physikalischen Größe miteinander kompatibel?




# Zweihypothesen Poisson Test

- Ein wichtiger Test in der Teilchenphysik, den wir im Folgenden eingehender diskutieren werden, ist der Zweihypothesen Test basierend auf der Poisson Zählstatistik, z.B.:
- Weisen die Daten auf die Existenz eines neues Teilchens hin?
- In diesem Fall haben wir zwei Hypothesen, z.B.:

$H_0$  : Etablierte Hypothese (nur Untergrund)

$H_1$  : Alternative Hypothese (zusätzliches Signal)



# Lemma von Neyman-Pearson (einfache Hypothesen)

Für den Test zweier einfacher Hypothesen  $H_0$  und  $H_1$  ist für den Likelihood-Quotienten

$$\lambda(\vec{x}) = \frac{\mathcal{L}(\vec{x}|H_0)}{\mathcal{L}(\vec{x}|H_1)}$$

$1 - \beta$  bei vorgegebenem  $\alpha$  maximal, d.h.  $\lambda(\vec{x})$  ist die Teststatistik mit der größten Trennschärfe. Der Likelihood-Quotient  $\lambda(\vec{x})$  ist äquivalent zur Differenz der Log-Likelihood:

$$q(\vec{x}) = -2 \ln \left( \frac{\mathcal{L}(\vec{x}|H_0)}{\mathcal{L}(\vec{x}|H_1)} \right) = -2 \left( \ln (\mathcal{L}(\vec{x}|H_0)) - \ln (\mathcal{L}(\vec{x}|H_1)) \right)$$

- Das Lemma von Neyman-Pearson gilt nur für einfache Hypothesen, es lässt sich jedoch auf zusammengesetzte Hypothesen verallgemeinern (siehe [Folie 38](#)).

# Lemma von Neyman-Pearson (zusammengesetzte Hyp.)

Für eine Verallgemeinerung des Lemmas von Neyman-Pearson bilden Sie den Likelihood-Quotienten aus

$$\lambda(\vec{x}, \{\theta_i\}) = \frac{\max_{\theta_i} (\mathcal{L}(\vec{x}, \{\theta_i\} | H_1))}{\max_{\theta'_i \in \Omega} (\mathcal{L}(\vec{x}, \{\theta'_i\} | H_0))},$$

wobei  $\theta'_i \in \Omega$  bedeutet, dass die Parameter  $\{\theta'_i\}$  mit  $H_0$  kompatibel sein müssen. Die Hypothese  $H_0$  wird mit der Irrtumswahrscheinlichkeit

$$\alpha = P(\lambda > \lambda_\alpha | H_0) = \int_{\lambda_\alpha}^{\infty} g(\lambda | H_0) d\lambda$$

verworfen.

# Beispiel CP-Eigenzustand des beobachteten Higgs Bosons

- Goldener Zerfallskanal für solche Messungen:  $H \rightarrow ZZ^* \rightarrow 4\ell$


$$P(Y_L^m(\theta, \varphi)) = (-1)^L \cdot Y_L^m(\theta, \varphi)$$

$$P(4\ell) = (-1)^L (-1)^2 (+1)^2 = (-1)^L$$

Paritätsoperator

Anteil der Ortswellenfunktion

Anteil der Spins im Endzustand



Charakterisierung der Zerfallsebenen des  $H \rightarrow ZZ^* \rightarrow 4\ell$  Zerfalls.

Wie Drehimpuls- & Spinkonfiguration Rückschlüsse auf den CP-Eigenzustand des Higgs Bosons zulassen:

$0^+$

$J^P = 0^+$

$$|0, 0\rangle = \sqrt{\frac{1}{3}}|1, -1\rangle \otimes |1, -1\rangle - \sqrt{\frac{1}{3}}|1, 0\rangle \otimes |1, 0\rangle + \sqrt{\frac{1}{3}}|1, -1\rangle \otimes |1, 1\rangle$$

$0^-$


$J^P = 0^-$

$L = 1$


$$|1, \pm 1\rangle = \sqrt{\frac{1}{2}}|1, \pm 1\rangle \otimes |1, 0\rangle - \sqrt{\frac{1}{2}}|1, 0\rangle \otimes |1, \pm 1\rangle$$

# Beispiel CP-Eigenzustand des beobachteten Higgs Bosons


- Goldener Zerfallskanal für solche Messungen:  $H \rightarrow ZZ^* \rightarrow 4\ell$



PRD 89 (2014) 092007



Test reiner Spin-Paritäts Hypothesen basierend auf  $\mathcal{O}(50)$  Ereignissen:



# Theorem von Wilks

Für Stichproben  $\{x_i\}$ ,  $i = 0, 1, \dots, n$  einer Zufallsvariablen  $x$  der Länge  $n \rightarrow \infty$  gilt: Wird die Grundgesamtheit der Zufallsvariablen  $x$  durch eine Wahrscheinlichkeitsdichte  $p(x, \{\theta_j\})$  beschrieben, und legt die Hypothese  $H_0$   $r = m_1 - m_0$  der Parameter  $\{\theta_j\}$  fest, so folgt die Testfunktion

$$q(\vec{x}, \vec{\theta}) = -2 \ln \left( \lambda(\vec{x}, \vec{\theta}) \right)$$

einer  $\chi^2$ -Verteilung mit  $r$  Freiheitsgraden. Dabei entspricht  $m_i$  der Anzahl der freien Parameter der Hypothese  $H_i$ .

Annals Math. Statist. 9 (1938) 1

- **Beispiel:** Zählexperiment mit einem Signal (s) zusätzlich zu bekanntem Untergrund (b)

$$q(\vec{x}, \theta) = -2 \ln \left( \frac{\mathcal{L}(\vec{x}|\theta s + b)}{\mathcal{L}(\vec{x}|b)} \right) \propto \chi^2(x', 1) \longleftarrow \chi^2\text{-Verteilung mit einem Freiheitsgrad}$$

- D.h. wenn Sie sich sicher sind, dass Ihre Stichprobe den Anforderungen von Wilks' Theorem entspricht, können Sie p-Werte und Irrtumswahrscheinlichkeiten analytisch, d.h. ohne die Auswertung von Pseudo-Experimenten bestimmen.

# Beispiel-1: Zählexperiment mit Poisson-Statistik

- **Hypothesentest:** Kleines Signal  $s$  auf bekanntem Untergrund  $b \gg s$ .

$$\mathcal{P}_0(n, b) = \frac{b^n}{n!} e^{-b} \quad ; \quad \mathcal{P}_1(n, s + b) = \frac{(s + b)^n}{n!} e^{-(s+b)} \quad n \equiv s + b : \text{beob. Ergebnisse}$$

$$\lambda = \frac{P_0(n, b)}{P_1(n, s + b)}$$

**Anm.:** Wir bestimmen  $s$  für  $H_1$   
a posteriori aus  $s \equiv n - b$ .

$$q = -2 \ln \left( \left( \frac{b}{s + b} \right)^n e^{-b+s+b} \right) = -2 \left( n \ln \left( \frac{b}{s + b} \right) + s \right) = 2 \left( \underbrace{(s + b)}_{n \equiv s + b} \ln \left( \frac{s}{b} + 1 \right) - s \right)$$

mit:  $s \ll b$

$$\ln(1 + x) = \sum_{\nu=1}^{\infty} \frac{(-1)^{\nu+1}}{\nu} x^{\nu} = \frac{s}{b} - \frac{1}{2} \frac{s^2}{b^2} + \mathcal{O} \left( (s/b)^3 \right) \quad \text{für } x = s/b \in (-1; 1]$$

$$q \approx 2 \left( (s + b) \left( \frac{s}{b} - \frac{1}{2} \frac{s^2}{b^2} \right) - s \right) = 2 \left( \frac{s^2}{b} + s - \frac{1}{2} \frac{s^3}{b^2} - \frac{1}{2} \frac{s^2}{b} - s \right) = \frac{s^2}{b} - \frac{1}{2} \frac{s^3}{b^2}$$



# Beispiel-1: Zählexperiment mit Poisson-Statistik

- Nach dem Theorem von Wilks gilt:

$$q = \chi^2(x, r = 1) \Big|_n = \frac{(n - \mu_0)^2}{\sigma_0^2}$$

(Siehe Folie 41)      (Siehe VL-01 Folie 35)

$$\sqrt{\frac{(n - \mu_0)^2}{\sigma_0^2}} = \boxed{\sqrt{q} \approx \frac{s}{\sqrt{b}}} \quad (\text{Signifikanz der Beobachtung})$$

(Siehe Folie 42)

- NB:** Man erkennt aus dieser Rechnung, dass die altbekannte Formel für die Berechnung der Signifikanz bei einem einfachen Zählexperiment

$$z = \frac{n - b}{\sqrt{b}}$$

nur näherungsweise gilt. Worin besteht diese Näherung?

# Beispiel-1: Zählexperiment mit Poisson-Statistik

- Nach dem Theorem von Wilks gilt:

$$q = \chi^2(x, r = 1) \Big|_n = \frac{(n - \mu_0)^2}{\sigma_0^2}$$

(Siehe Folie 41)      (Siehe VL-01 Folie 35)

$$\sqrt{\frac{(n - \mu_0)^2}{\sigma_0^2}} = \boxed{\sqrt{q} \approx \frac{s}{\sqrt{b}}} \quad (\text{Signifikanz der Beobachtung})$$

(Siehe Folie 42)

- NB:** Man erkennt aus dieser Rechnung, dass die altbekannte Formel für die Berechnung der Signifikanz bei einem einfachen Zählexperiment

$$z = \frac{n - b}{\sqrt{b}}$$

nur näherungsweise gilt. Worin besteht diese Näherung? – In der Annahme  $\sigma_0 = \sqrt{b}$ .

## Beispiel-2: Mittelwert normalverteilter Zufallsgrößen

---

- Wir berechnen den Likelihood-Quotienten aus dem Mittelwert  $\bar{x}$  einer Stichprobe normalverteilter  $\{x_i\}$  der Länge  $n$  und dem Erwartungswert  $\mu_0$  auf der Grundgesamtheit:

- Likelihood:

$$\mathcal{L}(\{x_i\}, \mu, \sigma) = \left( \frac{1}{\sqrt{2\pi\sigma^2}} \right)^n \exp \left( -\frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \mu)^2 \right)$$

- Likelihood-Quotient:

$$\lambda(\{x_i\}, \bar{x}, \mu_0, \sigma) = \frac{\mathcal{L}(\{x_i\}, \mu_0, \sigma)}{\mathcal{L}(\{x_i\}, \bar{x}, \sigma)} = \exp \left( -\frac{1}{2\sigma^2} \left( \sum_{i=1}^n (x_i - \mu_0)^2 - \sum_{i=1}^n (x_i - \bar{x})^2 \right) \right)$$

$$q(\{x_i\}, \bar{x}, \mu_0, \sigma) = -2 \ln(\lambda) = \frac{n}{\sigma^2} (\mu_0 - \bar{x})^2$$

## Beispiel-2: Mittelwert normalverteilter Zufallsgrößen

- Wir berechnen den Likelihood-Quotienten aus dem Mittelwert  $\bar{x}$  einer Stichprobe normalverteilter  $\{x_i\}$  der Länge  $n$  und dem Erwartungswert  $\mu_0$  auf der Grundgesamtheit:
- Likelihood:

$$\mathcal{L}(\{x_i\}, \mu, \sigma) = \left( \frac{1}{\sqrt{2\pi\sigma^2}} \right)^n \exp \left( -\frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \mu)^2 \right)$$

- Likelihood-Quotient:

$$\lambda(\{x_i\}, \bar{x}, \mu_0, \sigma) = \frac{\mathcal{L}(\{x_i\}, \mu_0, \sigma)}{\mathcal{L}(\{x_i\}, \bar{x}, \sigma)} = \exp \left( -\frac{1}{2\sigma^2} \left( \underbrace{\sum_{i=1}^n (x_i - \mu_0)^2 - \sum_{i=1}^n (x_i - \bar{x})^2}_{\text{(Nebenrechnung)}} \right) \right)$$

$$q(\{x_i\}, \bar{x}, \mu_0, \sigma) = -2 \ln(\lambda) = \frac{n}{\sigma^2} (\mu_0 - \bar{x})^2$$

$$\begin{aligned} \sum_{i=1}^n (x_i - \mu_0)^2 - \sum_{i=1}^n (x_i - \bar{x})^2 &= \left( \sum_{i,j=1}^n x_i x_j - 2 \underbrace{\sum_{i=1}^n x_i \mu_0 + n \mu_0^2}_{\equiv 2n\bar{x}\mu_0} \right) - \left( \sum_{i,j=1}^n x_i x_j - 2 \underbrace{\sum_{i=1}^n x_i \bar{x} + n\bar{x}^2}_{\equiv 2n\bar{x}^2} \right) \\ &= n\mu_0^2 + 2n\bar{x}\mu_0 - n\bar{x}^2 = n(\mu_0 - \bar{x})^2 \end{aligned}$$

## Beispiel-2: Mittelwert normalverteilter Zufallsgrößen

---

- Wir berechnen den Likelihood-Quotienten aus dem Mittelwert  $\bar{x}$  einer Stichprobe normalverteilter  $\{x_i\}$  der Länge  $n$  und dem Erwartungswert  $\mu_0$  auf der Grundgesamtheit:

- Likelihood:

$$\mathcal{L}(\{x_i\}, \mu, \sigma) = \left( \frac{1}{\sqrt{2\pi\sigma^2}} \right)^n \exp \left( -\frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \mu)^2 \right)$$

- Likelihood-Quotient:

$$\lambda(\{x_i\}, \bar{x}, \mu_0, \sigma) = \frac{\mathcal{L}(\{x_i\}, \mu_0, \sigma)}{\mathcal{L}(\{x_i\}, \bar{x}, \sigma)} = \exp \left( -\frac{1}{2\sigma^2} \left( \sum_{i=1}^n (x_i - \mu_0)^2 - \sum_{i=1}^n (x_i - \bar{x})^2 \right) \right)$$

$$q(\{x_i\}, \bar{x}, \mu_0, \sigma) = -2 \ln(\lambda) = \frac{n}{\sigma^2} (\mu_0 - \bar{x})^2$$

- Die Stichprobenverteilung für  $\bar{x}$  ist bekannt:  $g(\bar{x}) = \varphi(\bar{x}, \mu_0, \sigma/\sqrt{n})$ . Wir interessieren uns für die Stichprobenverteilung  $g(q)$ , die wir im folgenden durch Variablentransformation  $\bar{x} \rightarrow q(\bar{x})$  ermitteln.

## Beispiel-2: Mittelwert normalverteilter Zufallsgrößen

- **NB:** Der Wertebereich von  $g(q)$  wird zweimal überdeckt, einmal für  $\bar{x} > \mu_0$  und einmal für  $\bar{x} < \mu_0$ . Es gilt also:

$$g(q) = 2 \left| \frac{d\bar{x}}{dq} \right| g(\bar{x}) \quad ; \quad g(\bar{x}) = \varphi(\bar{x}, \mu_0, \sigma/\sqrt{n}) = \sqrt{\frac{n}{2\pi\sigma^2}} \exp\left(-\frac{n}{2\sigma^2} (\mu_0 - \bar{x})^2\right)$$

$$q(\bar{x}) = \frac{n}{\sigma^2} (\mu_0 - \bar{x})^2 \quad ; \quad \bar{x}(q) = \mu_0 - \sqrt{\frac{\sigma^2}{n}} q^{\frac{1}{2}} \quad ; \quad \left| \frac{d\bar{x}}{dq} \right| = \frac{1}{2} \sqrt{\frac{\sigma^2}{n}} q^{-\frac{1}{2}}$$

$$g(q) = 2 \frac{1}{2} \sqrt{\frac{\sigma^2}{n}} q^{-\frac{1}{2}} \cdot \sqrt{\frac{n}{2\pi\sigma^2}} \exp\left(-\frac{n}{2\sigma^2} (\bar{x} - \mu_0)^2\right) \Big|_{\bar{x}=\mu_0 - \sqrt{\frac{\sigma^2}{n}} q^{\frac{1}{2}}} = \frac{1}{\sqrt{2\pi}} q^{-\frac{1}{2}} \exp\left(-\frac{q}{2}\right)$$

## Beispiel-2: Mittelwert normalverteilter Zufallsgrößen

- NB:** Der Wertebereich von  $g(q)$  wird zweimal überdeckt, einmal für  $\bar{x} > \mu_0$  und einmal für  $\bar{x} < \mu_0$ . Es gilt also:

$$g(q) = 2 \left| \frac{d\bar{x}}{dq} \right| g(\bar{x}) \quad ; \quad g(\bar{x}) = \varphi(\bar{x}, \mu_0, \sigma/\sqrt{n}) = \sqrt{\frac{n}{2\pi\sigma^2}} \exp\left(-\frac{n}{2\sigma^2} (\mu_0 - \bar{x})^2\right)$$

$$q(\bar{x}) = \frac{n}{\sigma^2} (\mu_0 - \bar{x})^2 \quad ; \quad \bar{x}(q) = \mu_0 - \sqrt{\frac{\sigma^2}{n}} q^{\frac{1}{2}} \quad ; \quad \left| \frac{d\bar{x}}{dq} \right| = \frac{1}{2} \sqrt{\frac{\sigma^2}{n}} q^{-\frac{1}{2}}$$

$$g(q) = 2 \frac{1}{2} \sqrt{\frac{\sigma^2}{n}} q^{-\frac{1}{2}} \cdot \sqrt{\frac{n}{2\pi\sigma^2}} \exp\left(-\frac{n}{2\sigma^2} (\bar{x} - \mu_0)^2\right) \Big|_{\bar{x}=\mu_0-\sqrt{\frac{\sigma^2}{n}} q^{\frac{1}{2}}} = \frac{1}{\sqrt{2\pi}} q^{-\frac{1}{2}} \exp\left(-\frac{q}{2}\right)$$

Zu vergleichen mit:  $\chi^2(x, r = 1) = \frac{1}{2^{r/2}\Gamma(r/2)} x^{r/2-1} e^{-x/2} \Big|_{n=1}$

$$= \frac{1}{\sqrt{2\pi}} q^{-\frac{1}{2}} \exp\left(-\frac{q}{2}\right)$$

# Beispiel-2: Mittelwert normalverteilter Zufallsgrößen

- NB:** Der Wertebereich von  $g(q)$  wird zweimal überdeckt, einmal für  $\bar{x} > \mu_0$  und einmal für  $\bar{x} < \mu_0$ . Es gilt also:

$$g(q) = 2 \left| \frac{d\bar{x}}{dq} \right| g(\bar{x}) \quad ; \quad g(\bar{x}) = \varphi(\bar{x}, \mu_0, \sigma/\sqrt{n}) = \sqrt{\frac{n}{2\pi\sigma^2}} \exp\left(-\frac{n}{2\sigma^2} (\mu_0 - \bar{x})^2\right)$$

$$q(\bar{x}) = \frac{n}{\sigma^2} (\mu_0 - \bar{x})^2 \quad ; \quad \bar{x}(q) = \mu_0 - \sqrt{\frac{\sigma^2}{n}} q^{\frac{1}{2}} \quad ; \quad \left| \frac{d\bar{x}}{dq} \right| = \frac{1}{2} \sqrt{\frac{\sigma^2}{n}} q^{-\frac{1}{2}}$$

$$g(q) = 2 \frac{1}{2} \sqrt{\frac{\sigma^2}{n}} q^{-\frac{1}{2}} \cdot \sqrt{\frac{n}{2\pi\sigma^2}} \exp\left(-\frac{n}{2\sigma^2} (\bar{x} - \mu_0)^2\right) \Big|_{\bar{x}=\mu_0 - \sqrt{\frac{\sigma^2}{n}} q^{\frac{1}{2}}} = \frac{1}{\sqrt{2\pi}} q^{-\frac{1}{2}} \exp\left(-\frac{q}{2}\right)$$

Zu vergleichen mit:  $\chi^2(x, r = 1) = \frac{1}{2^{r/2} \Gamma(r/2)} x^{r/2-1} e^{-x/2} \Big|_{n=1}$

- In diesem Beispiel folgt  $g(q)$  der  $\chi^2$ -Verteilung für  $r = 1$  Freiheitsgrad für beliebige Werte von  $n$ .

$$= \frac{1}{\sqrt{2\pi}} q^{-\frac{1}{2}} \exp\left(-\frac{q}{2}\right)$$



# 6 Hypothesentests in der modernen Physik

## 6.4 Goodness-of-fit Tests

Eine spezielle Klasse von Hypothesentests sind Goodness-of-fit (GoF) Tests. Sie dienen dazu, zu überprüfen, ob ein statistisches Modell die Daten einer Messung hinreichend beschreiben kann.



# Goodness-of-fit (GoF) Test

- Mit Hilfe des Goodness-of-fit (GoF) Tests überprüfen Sie, ob und in wie weit Ihr Modell die Daten Ihrer Messung beschreiben kann.

Der Goodness-of-fit Test (GoF) basiert auf der Schätzfunktion  $t_{\text{GoF}}(\vec{x})$ . Die Einschätzung des Tests erfolgt auf Grundlage des  $p$ -Wertes ( $p$ -value) der Stichprobenverteilung  $g(t_{\text{GoF}}(\vec{x}))$

$$p = \int_{t_{\text{GoF}}^{\text{obs}}}^{\infty} g(t'_{\text{GoF}}) dt'_{\text{GoF}} \quad \text{mit } 0 \leq t_{\text{GoF}}(\vec{x}) < \infty$$

mit der Interpretation:

$t_{\text{GoF}}$  klein: Das Modell kann die Daten gut beschreiben

$t_{\text{GoF}}$  groß: Das Modell kann die Daten nicht gut beschreiben

Der  $p$ -Wert bezeichnet die Wahrscheinlichkeit einen Wert von  $t_{\text{GoF}} \geq t_{\text{GoF}}^{\text{obs}}$  zu erhalten, wenn das Modell wahr ist.

# Vorgehensweise beim GoF Test

---

- Die Berechnung des p-Wertes impliziert folgendes Vorgehen:
  - (Einmalige) Evaluation von  $t_{\text{GoF}}^{\text{obs}}$  auf Daten.
  - Bestimmung von  $g(t_{\text{GoF}}(\vec{x}))$  entweder analytisch oder durch vielfache Auswertung von  $t_{\text{GoF}}$  im Rahmen eines Ensemble Tests.
  - Bestimmung von  $p$ .
- **NB:** Diese Vorgehensweise ist die beste und sicherste, um ein Modell gegen eine Messung zu testen.
- In seltenen Fällen ist  $g(t_{\text{GoF}}(\vec{x}))$  analytisch bekannt, so z.B. beim  $\chi^2$ -Test nach Pearson, oder in Fällen in denen das Theorem von Wilks anwendbar ist. In diesen Fällen kann die Einschätzung auch direkt auf Grundlage von  $t_{\text{GoF}}^{\text{obs}}$  erfolgen.

# Pearson ( $\chi^2$ )-Test

---

Die Pearson Teststatistik

$$t_{\chi^2} = \sum_{i \leq n} \frac{(f(x_i) - y_i)^2}{f(x_i)}$$

entspricht dem  $\chi^2$ -Wert für Poisson-verteilte Zufallsgrößen mit  $\sigma_i^2 = f(x_i)$ .

- Die  $f(x_i)$  entsprechen den Modellvorhersagen, die  $y_i$  den Messungen/Beobachtungen.
- $t_{\chi^2}$  folgt einer  $\chi^2$ -Verteilung, d.h.  $\frac{t_{\chi^2}}{n} \lesssim 1$  impliziert, dass das Modell die Daten beschreiben kann (siehe [VL-04 Folie 18](#)).
- **NB:** Dies ist nicht gleichbedeutend damit, dass das Modell der Wahrheit entspricht.
- Der Pearson Test kann einfach und schnell bei vielen Gelegenheiten angewandt werden.

# Beispiel-1: Test auf Unabhängigkeit

---

- **Hypothese:** Bei einer Umfrage zur Rentenreform soll in Abhängigkeit vom Alter die Zustimmung (-1 ablehnend, 0 neutral +1 zustimmend) erfasst werden. Man vermutet, dass das Alter einen Einfluss auf die Zustimmung hat.

- $H_0$ : „Die Häufigkeiten in der folgenden **Kontingenztabelle** der Grundgesamtheiten unterscheiden sich nicht von der Erwartung für statistische Unabhängigkeit“  
( $H_0 : p_{ij} = p_{ij}^e$ ).

- Testfunktion:

$$t_{\chi^2} = \sum_{i=1}^m \sum_{j=1}^k \frac{h_{ij} - h_{ij}^e}{h_{ij}^e} \propto \chi^2((m-1) \cdot (k-1)) = \chi^2(6)$$

- Irrtumswahrscheinlichkeit:  $\alpha = 0.05$  mit:  $\int_{-\infty}^{12.6} \chi^2(x, n=6) dx = 0.05$

# Beispiel-1: Test auf Unabhängigkeit

- Stichprobenergebnis (Befragung von 250 Personen):

Einstellung	Alter			
	- 20	21-40	41-65	66 und älter
-1	5	30	60	30
0	6	24	30	15
+1	9	26	10	5

$$\sum \chi^2 =$$

$h_{ij}$	$h_{ij}^e$	Alter			
		-20	21-40	41-65	66 und älter
$(h_{ij} - h_{ij}^e)^2$	$\frac{(h_{ij} - h_{ij}^e)^2}{h_{ij}^e}$				

# Beispiel-1: Test auf Unabhängigkeit

- Stichprobenergebnis (Befragung von 250 Personen):

Einstellung	Alter			
	- 20	21-40	41-65	66 und älter
-1	5	30	60	30
0	6	24	30	15
+1	9	26	10	5

$$\sum \chi^2 = 28$$

$h_{ij}$	$h_{ij}^e$
$(h_{ij} - h_{ij}^e)^2$	$\frac{(h_{ij} - h_{ij}^e)^2}{h_{ij}^e}$

Einstellung	Alter							
	-20		21-40		41-65		66 und älter	
-1	5	10	30	40	60	50	30	25
	25	2,5	100	2,5	100	2	25	1
0	6	6	24	24	30	30	15	15
	0	0	0	0	0	0	0	0
+1	9	4	26	16	10	20	5	10
	25	6,25	100	6,25	100	5	25	2,5

# Beispiel: Test auf Unabhängigkeit


---

- Testentscheidung:  $H_0$  ist widerlegt ( $\alpha^* = 0$ ).
- Es besteht also eine Korrelation zwischen Alter und Zustimmung zur Rentenreform. Welcher Art diese Korrelation ist und wie sie interpretierbar ist, sollte Bestandteil weiterer Untersuchungen sein.



# Beispiel-2: Anpassung eines Polynoms

- Anpassung eines Polynoms variierender Ordnung an eine randomisierte Verteilung mit dem zugrundeliegenden Verlauf  $f(x) = 30 - x - 5x^2$  :




(Vergleiche mit  
VL-04 Folie 18)

Ein lauffähiges ROOT macro finden Sie [hier](#).

# Beispiel-2: Anpassung eines Polynoms

- Anpassung eines Polynoms variierender Ordnung an eine randomisierte Verteilung mit dem zugrundeliegenden Verlauf  $f(x) = 30 - x - 5x^2$  :




(Vergleiche mit  
 VL-04 Folie 18)

Ein lauffähiges ROOT macro finden Sie [hier](#).

# Beispiel-2: Anpassung eines Polynoms


- Anpassung eines Polynoms variierender Ordnung an eine randomisierte Verteilung mit dem zugrundeliegenden Verlauf  $f(x) = 30 - x - 5x^2$  :



Ein lauffähiges ROOT macro finden Sie [hier](#).

# Beispiel-2: Anpassung eines Polynoms


- Anpassung eines Polynoms variierender Ordnung an eine randomisierte Verteilung mit dem zugrundeliegenden Verlauf  $f(x) = 30 - x - 5x^2$  :



Ein lauffähiges ROOT macro finden Sie [hier](#).

# Beispiel-2: Anpassung eines Polynoms

- Anpassung eines Polynoms variierender Ordnung an eine randomisierte Verteilung mit dem zugrundeliegenden Verlauf  $f(x) = 30 - x - 5x^2$  :



- Halten Sie bei Anpassungen die Anzahl nicht a priori motivierter Parameter so gering wie möglich.
- Werte von  $\chi^2 \ll 1$  können nicht nur auf überschätzte Unsicherheiten sondern auch auf „*overfitting*“ hindeuten.
- Beachten Sie: Bei guter Abdeckung Ihrer Unsicherheiten berühren ~32% der Datenpunkte die angepasste Kurve i.a. nicht mit ihren Fehlerbalken (siehe Folie 11).

Ein lauffähiges Root macro finden Sie [hier](#).

# Likelihood-Quotient


- Der sogenannte **saturierte Modelltest** erweitert den  $\chi^2$ -Test nach Pearson zu einem allgemeinen Likelihood basierten Test.
- Die Teststatistik ist der **Likelihood-Quotient**:

$$t_{\text{SAT}} = -2 \ln \left( \frac{\mathcal{L}(\text{data} |_{\text{test}})}{\mathcal{L}(\text{data} |_{\text{SAT}})} \right)$$

Zu testendes  
Modell

Modell mit ebenso vielen  
Parametern wie Messungen  
(sog. „saturiertes Modell“)

Im rechten Bsp. hätte das  
saturierte Modell 25 Parameter  
und würde so durch  
jeden Messpunkt gehen.



# Likelihood-Quotient

- Der sogenannte **saturierte Modelltest** erweitert den  $\chi^2$ -Test nach Pearson zu einem allgemeinen Likelihood basierten Test.
- Die Teststatistik ist der **Likelihood-Quotient**:

$$t_{\text{SAT}} = -2 \ln \left( \frac{\mathcal{L}(\text{data}|\text{test})}{\mathcal{L}(\text{data}|\text{SAT})} \right)$$

Evaluation der Likelihood unter Annahme normalverteilter Einzelereignisse:

$$\mathcal{L}(\text{data}|\text{test}) = \prod_{i=1}^n \frac{1}{\sqrt{2\pi\sigma_i}} e^{-(y_i - \mu_i)^2/2\sigma_i}$$

$$\mathcal{L}(\text{data}|\text{SAT}) = \prod_{i=1}^n \frac{1}{\sqrt{2\pi\sigma_i}}$$

$$t_{\text{SAT}} = -2 \ln \left( \frac{\mathcal{L}(\text{data}|\text{test})}{\mathcal{L}(\text{data}|\text{SAT})} \right) = \sum_{i=1}^n \frac{(y_i - \mu_i)^2}{\sigma_i}$$

- D.h. für Histogramme ohne weitere systematischen Unsicherheiten, für die die Unsicherheiten der Messpunkte normalverteilt sind erhält man  $t_{\text{SAT}} \rightarrow t_{\chi^2}$  zurück.


# Tests auf der CDF

---


- Die Teststatistik  $t_{\chi^2}$  ist nur sensitiv auf die Abstände der Erwartung von den Messpunkten, nicht auf deren „Richtung“. (Warum ist dies so?)
- Es kann somit vorkommen, dass Sie bin-korrelierte Trends nicht mit einem auf  $t_{\chi^2}$  oder  $t_{\text{SAT}}$  basierten Test erfassen.
- Dies können Sie mit Tests erreichen, die auf die kummulative (CDF) und die empirische (EDF) Verteilungsfunktion sensitiv sind. Wir diskutieren als Beispiel eines solchen Tests den [Kolmogorov-Smirnov-Test](#) (KS).



# Vergleich zweier Verteilungsfunktionen





# Vergleich zweier Verteilungsfunktionen



# Stat. Kompabilität und Trends

- Für dieses Bsp. wurden die Daten basierend auf einer Normalverteilung mit  $\mu = 5$  1000-mal zufällig *gesampled*. Der Vergleich erfolgt mit einem Modell mit  $\mu = 4.88$ .
- Wie Sie sehen, ist das Modell mit  $\mu = 4.88$  nach  $\chi^2$  mit den Daten kompatibel. Es liegt jedoch, wenn Sie genau hinsehen, auf der linken Flanke systematisch unter- und auf der rechten Flanke oberhalb der Daten.
- Diesen Trend erfassen Sie durch den Vergleich der CDF des Modells mit der EDF der Daten.




# Kolmogorov-Smirnov-Test

Der größte vertikale Abstand zweier kummulativer Verteilungsfunktionen  $F_0$  und  $F_n$

$$d_{KS} = \|F_n - F_0\|$$

ist die Teststatistik des Kolmogorov-Smirnov-Tests.

- Diesen Trend erfassen Sie durch den Vergleich der CDF des Modells mit der EDF der Daten.
- Den p-Wert für vorgegebene Werte von  $d_{KS}$  können Sie aus [Tabellen](#) auslesen.



# Kolmogorov-Smirnov-Test

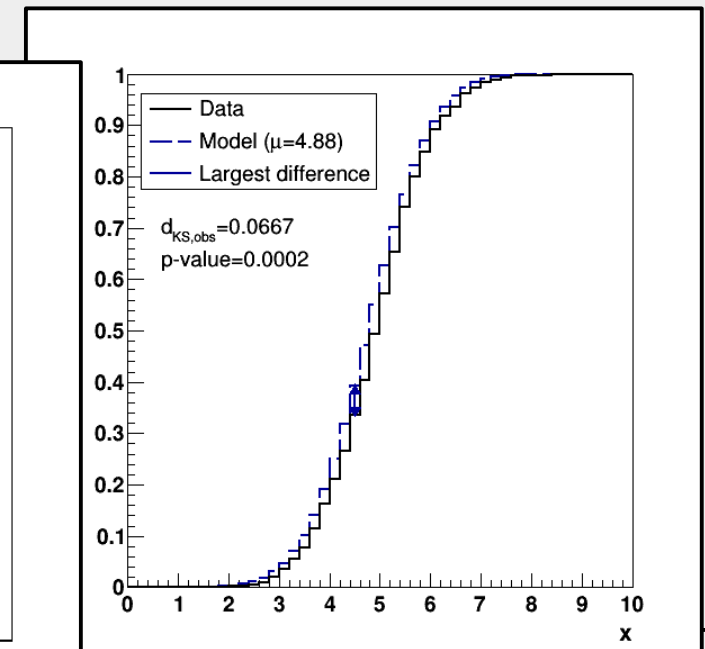

Der größte vertikale Abstand zweier kummulativer Verteilungsfunktionen  $F_0$  und  $F_n$

$$d_{KS} = \|F_n - F_0\|$$

ist die Teststatistik des Kolmogorov-Smirnov-Tests.

- Diesen Trend erfassen Sie mit der CDF des Modells mit dem Sie vergleichen
- Den p-Wert für vorgegebene  $d_{KS,obs}$  Sie aus **Tabellen** auslesen


Die sicherste Art einen p-Wert für einen beobachteten Wert  $d_{KS,obs}$  zu ermitteln, besteht aber auch hier wieder in einem Ensemble Test.



Ein lauffähiges Root macro finden Sie [hier](#).


# Kompatibilität: Higgs@CMS

EPJ C 74 (2014) 3076




Gezeigt sind hier die Run-1 Ergebnisse von CMS.


JHEP 05 (2014) 104




PRD 89 (2014) 092007



EPJ C 74 (2014) 3076





Coupling across production modes or decay channels:



EPJ C 75 (2015) 212

JHEP 01 (2014) 096



EPJ C 75 (2015) 212

- Event categories : 227
  - Nuisance parameters:  $\mathcal{O}(2500)$
  - 16 MB binary file of stat. model (~145 MB in human readable form).
- $\mu = \sigma/\sigma_{SM} = 1.00 \pm 0.14$   
 $p\text{-value} = 84\%$

# Zusammenfassung

---

- Grundlagen und Begriffe des Hypothesentests.
- Fehler 1. und 2. Art.
- Klassische Beispiele und Anwendungen.
- Goodness of fit (GoF) Test.