

- Die grundsätzliche Frage beim Testproblem ist zu beurteilen, welche von zwei sich widersprechenden Hypothesen wahr ist.
- Etwa  
 $H : p = p_0$  gegen  $K : p = p_1$   
oder  
 $H_0 : p \leq p_0$  gegen  $H_1 : p > p_0$
- Problem: Egal, wie wir uns entscheiden, können wir zwei Fehler begehen, nämlich
- den Fehler 1. Art:  $H_0$  ist wahr und wird verworfen
- den Fehler 2. Art:  $H_0$  ist falsch und wird angenommen.

- Offensichtlich ist es unmöglich, beide Fehler gleichzeitig in den Griff zu bekommen.
- Versucht man beispielsweise den Fehler erster Art kleinzuhalten, indem man das Ablehnen von  $H_0$  erschwert, so vergrößert dies unausweichlich die Chancen auf einen Fehler zweiter Art.
- In der Statistik hat sich nun eingebürgert, nach einem Test zu suchen, bei dem der Fehler 1. Art kleiner ist als ein vorgegebenes *Signifikanzniveau*  $\alpha$ .
- Typische Werte für  $\alpha$  sind 5%, 2,5%, 1% oder 0,5%.
- Die Wahl des Werts für  $\alpha$  hängt natürlich von der jeweiligen Situation ab: je gravierendere Folgen ein Irrtum hätte, desto kleiner sollten wir  $\alpha$  wählen.
- In unserem Beispiel hat ein Fehler 1. Art keine desaströsen Auswirkungen und wir wählen  $\alpha = 5\%$ .

- Das folgende Testverfahren liegt nahe:
- Wir schätzen  $p$  aus den Daten mithilfe des naiven Schätzers  $\hat{p}$ .
- Wenn  $\hat{p}$  so aussieht, wie wir es unter  $H_0$  vermuten würden (also z.B. nicht zu weit entfernt von  $1/2$  liegt, wenn  $H : p = 1/2$ ), so nehmen wir  $H_0$  an, sonst  $H_1$ .
- Hierbei tolerieren wir eine Wahrscheinlichkeit von  $\alpha$  für einen Fehler 1. Art. Genauer sieht das Testverfahren so aus:
- Schätze  $p$  durch  $\hat{p}$
- Bestimme eine Schranke  $\Gamma$  für  $p$
- Akzeptiere  $H_0$ , falls  $\hat{p} < \Gamma$  und verwerfe  $H_0$  andernfalls.
- Der Wert für die Schranke  $\Gamma = \Gamma(\alpha)$  berechnet sich dabei so, dass die Wahrscheinlichkeit für einen Fehler 1. Art höchstens gleich  $\alpha$  ist.

Formal:

## Definition

Zu testen sei die Hypothese  $H \subset \Theta$  gegen die Alternative  $K \neq \emptyset$ .  
Ein Test ist eine Abbildung

$$\phi : \{0, 1\}^n \rightarrow \{0, 1\}.$$

$\phi(x) = 0$  soll bedeuten, dass wir uns für  $H$  entscheiden, während  $\phi(x) = 1$  bedeutet, wir entscheiden uns für  $K$  (wir lehnen die Hypothese ab). Ein Test ist vollständig festgelegt durch das Gebiet  $R \subseteq \Theta$ , auf dem wir die Hypothese verwerfen ( $R$  ist das Verwerfungsgebiet von  $\phi$ ), d.h.  $\phi(x) = 1 \Leftrightarrow x \in R$ .

Neben gewöhnlichen Tests betrachten wir auch randomisierte Tests:

## Definition

Ein randomisierter Test ist eine Abbildung.

$$\phi : \{0, 1\}^n \rightarrow [0, 1].$$

$\phi(x)$  ist die Wahrscheinlichkeit  $H$  abzulehnen.

- Natürlich will man zwei gegebene Tests der gleichen Hypothese und Alternative vergleichen.
- Dies geht einerseits über das **Niveau des Tests**

$$\max_{p \in H} P_p(x \in R)$$

- Dies möchte man i.a. durch die gegebene Schranke  $\alpha > 0$  kontrollieren.
- Sind zwei Tests zu einem Niveau  $\alpha$  vorgelegt, so bietet sich der Fehler zweiter Art als Vergleichskriterium an.
- Man definiert daher (äquivalent)

$$\beta(p) = P_p(x \in R).$$

als die **Macht eines Tests** mit Verwerfungsbereich  $R$  in  $p \in K$ .

- Wir werden nun eine Untersuchung der Güte der oben diskutierten Tests im einfachst möglichen Fall präsentieren, dem Fall, in dem sowohl die Hypothese  $H$  als auch die Alternative  $K$  aus einem einzigen Punkt bestehen.
- Im Fall einer Folge von i.i.d. Bernoulli Variablen mit unbekanntem Erfolgsparameter  $p$  testen wir also die einfache Hypothese

$$H : \{p = p_0\}$$

gegen die einfache Alternative

$$K : \{p = p_1\}.$$

- Da wir uns in diesem Fall auch mit randomisierten Tests befassen wollen, verallgemeinern wir die Begriffe des Niveaus und der Macht rasch auf diesen Fall: Für einen randomisierten  $\phi$  ist

$$E_H(\phi) = \sum_x \phi(x) P_H(x)$$

das Niveau des Tests.



$$E_K(\phi) = \sum_x \phi(x) P_K(x)$$

ist seine Macht.

- Bemerke, dass diese Definitionen konsistent sind mit den Definitionen für nicht-randomisierte Tests.

Wir interessieren uns nun dafür unter allen Tests  $\{\phi : E_H(\phi) \leq \alpha\}$  denjenigen Test  $\phi^*$  mit maximaler Macht zu finden.

## Definition

Ein Test  $\phi^*$  heißt Neyman-Pearson Test, falls es eine Konstante  $c^*$ ,  $0 \leq c^* \leq \infty$  gibt, so dass

- $\phi^*(x) = 1$  falls  $P_K(x) > c^* P_H(x)$
- $\phi^*(x) = 0$  falls  $P_K(x) < c^* P_H(x)$
- Auf  $\{P_K(x) = c^* P_H(x)\}$  darf der Test  $\phi^*$  beliebige Werte  $0 \leq \gamma(x) \leq 1$  annehmen.

## Definition

Wir werden im folgenden einen Test  $\phi_1$  *schärfer* nennen als einen Test  $\phi_2$ , falls

$$E_K(\phi_1) > E_K(\phi_2).$$

gilt, die Chance  $H$  zu verwerfen, wenn  $K$  vorliegt bei  $\phi_1$  somit größer ist als bei  $\phi_2$ .

## Satz (Neyman-Pearson Lemma)

In der Situation des  $n$ -fachen Münzwurfs mit Parameter  $p$  sei die Hypothese

$$H : \{p = p_0\}$$

gegen die Alternative

$$K : \{p = p_1\}$$

zu testen. Dann gilt

- Falls  $\phi^*$  ein Neyman-Pearson Test ist, dann ist  $\phi^*$  schärfer als jeder andere Test  $\phi$  mit

$$E_H(\phi) \leq E_H(\phi^*).$$

- Für jedes  $0 \leq \alpha \leq 1$  gibt es einen (randomisierten) Neyman-Pearson Test  $\phi^*$  zum Niveau  $\alpha$ , also mit  $E_H(\phi^*) = \alpha$ .

Für einseitige Test, d.h. Tests einer Hypothese  $H$  die komplett links (oder komplett rechts) von der Alternative  $K$  liegt, überträgt sich die Optimalität mit Hilfe des folgenden

## Lemma

Sei  $X$  Binomial-verteilt zu den Parametern  $n$  und  $p$  und  $x < n$ .

Dann ist

$$p \mapsto P_p(X \leq x)$$

stetig und strikt fallend in  $p$  und

$$P_0(X \leq x) = 1 \quad \text{und} \quad P_1(X \leq x) = 0.$$