

## 4.2 Methoden um Tests zu finden: Likelihood Quotienten Tests (LRT)

Falls  $X_1, \dots, X_n$  iid aus  $f(x|\theta)$ , so gilt für die Likelihood Funktion

$$L(\theta|\mathbf{x}) = f(\mathbf{x}|\theta) = \prod_{i=1}^n f(x_i|\theta).$$

Falls  $L(\theta'|\mathbf{x}) > L(\theta''|\mathbf{x})$ , für  $\theta', \theta'' \in \Theta$ , ist es plausibler, dass  $\theta'$  und nicht  $\theta''$  der wahre Wert des Parameters  $\theta$  ist, gegeben die vorliegenden Beobachtungen  $\mathbf{x}$ .

**Definition 4.2.1:** Die **(LRT) Statistik** für den Test

$$H_0 : \theta \in \Theta_0 \quad \text{gegen} \quad H_1 : \theta \in \Theta_0^c,$$

mit einer Untermenge  $\Theta_0$  des Parameterraums  $\Theta$  und ihrem Komplement  $\Theta_0^c$ , ist

$$\lambda(\mathbf{x}) = \frac{\sup_{\theta \in \Theta_0} L(\theta|\mathbf{x})}{\sup_{\theta \in \Theta} L(\theta|\mathbf{x})} \in [0, 1].$$

Ein LRT ist ein Test mit Verwerfungsbereich  $R$  der Form

$$R = \{\mathbf{x} : \lambda(\mathbf{x}) \leq c\}$$

für eine beliebige Zahl  $0 \leq c \leq 1$ . Ist  $\lambda(\mathbf{x})$  klein, so ist dies ein Hinweis **gegen**  $H_0$ . Ist hingegen  $\lambda(\mathbf{x})$  groß, dann spricht dies **für**  $H_0$ .

Sei  $\hat{\theta} = \hat{\theta}(\mathbf{x})$  der MLE von  $\theta$  und sei  $\hat{\theta}_0 = \hat{\theta}_0(\mathbf{x})$  der MLE von  $\theta$  unter dem eingeschränkten Parameterbereich  $\Theta_0$ . Damit ist die LRT Statistik gleich

$$\lambda(\mathbf{x}) = \frac{L(\hat{\theta}_0|\mathbf{x})}{L(\hat{\theta}|\mathbf{x})}.$$

**Beispiel 4.2.1: (Normal LRT)** Seien  $X_1, \dots, X_n$  iid Normal( $\theta, 1$ ). Betrachte den zweiseitigen Test

$$H_0 : \theta = \theta_0 \quad \text{gegen} \quad H_1 : \theta \neq \theta_0 .$$

Da unter  $H_0$  nur 1 Wert spezifiziert ist, gilt  $\Theta_0 = \{\theta_0\}$  und

$$\sup_{\theta \in \Theta_0} L(\theta | \mathbf{x}) = L(\theta_0 | \mathbf{x}) .$$

Der uneingeschränkte MLE von  $\theta$  ist  $\bar{X}$  (bereits gezeigt), womit folgt, dass

$$\sup_{\theta \in \Theta} L(\theta | \mathbf{x}) = L(\bar{x} | \mathbf{x}) .$$

Somit resultiert

$$\lambda(\mathbf{x}) = \frac{L(\theta_0 | \mathbf{x})}{L(\bar{x} | \mathbf{x})} .$$

Die LRT Statistik vereinfacht sich zu

$$\begin{aligned}\lambda(\mathbf{x}) &= \frac{(2\pi)^{-n/2} \exp \left[ -\frac{1}{2} \sum_{i=1}^n (x_i - \theta_0)^2 \right]}{(2\pi)^{-n/2} \exp \left[ -\frac{1}{2} \sum_{i=1}^n (x_i - \bar{x})^2 \right]} \\ &= \exp \left\{ \frac{1}{2} \left[ -\sum_{i=1}^n (x_i - \theta_0)^2 + \sum_{i=1}^n (x_i - \bar{x})^2 \right] \right\} \\ &= \exp \left\{ -\frac{n}{2} (\bar{x} - \theta_0)^2 \right\},\end{aligned}$$

denn

$$\sum_{i=1}^n (x_i - \theta_0)^2 = \sum_{i=1}^n (x_i - \bar{x} + \bar{x} - \theta_0)^2 = \sum_{i=1}^n (x_i - \bar{x})^2 + n(\bar{x} - \theta_0)^2.$$

## Was nun?

Vorgehen:

- (1) Bestimme zuerst  $\lambda(\mathbf{x})$ .
- (2) Vereinfache die Beschreibung des kritischen Bereichs (falls möglich) auf einen Ausdruck der auf einer einfacheren Statistik beruht.

In unserem Fall ist  $\lambda(\mathbf{x})$  klein (und wir verwerfen  $H_0$ ) falls

$$\begin{aligned}\lambda(\mathbf{x}) = \exp \left\{ -\frac{n}{2}(\bar{x} - \theta_0)^2 \right\} &\leq c \\ (\bar{x} - \theta_0)^2 &\geq -\frac{2}{n} \log(c) \\ |\bar{x} - \theta_0| &\geq \sqrt{-\frac{2}{n} \log(c)} =: c^* \quad 0 \leq c^*,\end{aligned}$$

also wenn  $|\bar{x} - \theta_0|$  groß ist.

Der Verwerfungsbereich  $\{\mathbf{x} : \lambda(\mathbf{x}) \leq c\}$  ist somit äquivalent mit

$$\{\mathbf{x} : |\bar{x} - \theta_0| \geq c^*\}.$$

Wie wählt man  $c^*$ ? Nimm  $c^*$  derart, dass beispielsweise gilt

$$P(H_0 \text{ verwerfen} | H_0 \text{ richtig}) = \alpha = 0.05$$

(Wahrscheinlichkeit für **Fehler erster Art**, type I error probability,  $\alpha$ ).

Allgemein gilt

$$Z = \frac{\bar{X} - \theta}{1/\sqrt{n}} \sim \text{Normal}(0, 1)$$

aber wahrer Wert von  $\theta$  ist unbekannt.

Unter  $H_0$  jedoch folgt dafür


$$Z_0 = \frac{\bar{X} - \theta_0}{1/\sqrt{n}} \sim \text{Normal}(0, 1)$$

und damit ist

$$\lambda(\mathbf{x}) = \exp \left\{ -\frac{n}{2}(\bar{x} - \theta_0)^2 \right\} = \exp \left( -\frac{1}{2}z_0^2 \right) .$$

Die Entscheidung ist äquivalent mit der Entscheidung bzgl.

$$-2 \log \lambda(\mathbf{X}) = Z_0^2 \sim \chi_1^2 .$$





**Beispiel 4.2.2** Seien  $X_1, \dots, X_n$  iid Exponential( $1, \theta$ ), d.h. aus einer Population mit Dichte

$$f(x|\theta) = \exp(-(x - \theta))I_{[\theta, \infty)}(x), \quad \theta \in \mathbb{R}.$$

Betrachte den **einseitigen Test**

$$H_0 : \theta \leq \theta_0 \quad \text{gegen} \quad H_1 : \theta > \theta_0,$$

wobei  $\theta_0$  frei gewählt ist.

Als Likelihood Funktion resultiert mit  $x_{(1)} := \min_i(x_i)$

$$L(\theta|\mathbf{x}) = \begin{cases} \exp(-n(\bar{x} - \theta)) & \text{für } \theta \leq x_{(1)} \\ 0 & \text{sonst.} \end{cases}$$

$L(\theta|\mathbf{x})$  ist monoton wachsend in  $\theta$  auf dem Bereich  $\theta \leq x_{(1)}$ .

⇒ uneingeschränkte Maximum von  $L(\theta|\mathbf{x})$  ist in  $\theta = x_{(1)}$  mit


$$L(x_{(1)}|\mathbf{x}) = \exp(-n(\bar{x} - x_{(1)}))$$

⇒ eingeschränkte Maximum von  $L(\theta|x)$  unter  $H_0 : \theta \leq \theta_0$  ist

$$\max_{\theta \leq \theta_0} L(\theta|\mathbf{x}) = \begin{cases} L(\theta_0|\mathbf{x}) & \text{falls } \theta_0 < x_{(1)} \\ L(x_{(1)}|\mathbf{x}) & \text{falls } x_{(1)} \leq \theta_0. \end{cases}$$

Als LRT Statistik folgt

$$\lambda(\mathbf{x}) = \frac{L(\min(x_{(1)}, \theta_0)|\mathbf{x})}{L(x_{(1)}|\mathbf{x})} = \begin{cases} 1 & \text{für } x_{(1)} \leq \theta_0 \\ \exp(-n(x_{(1)} - \theta_0)) & \text{für } x_{(1)} > \theta_0 \end{cases}$$



Für  $x_{(1)} > \theta_0$  verwerfen wir  $H_0$  falls  $\lambda(\mathbf{x}) \leq c$ , d.h. falls

$$\exp(-n(x_{(1)} - \theta_0)) \leq c.$$

Der entsprechende Verwerfungsbereich

$$\left\{ \mathbf{x} : x_{(1)} \geq \theta_0 - \frac{1}{n} \log(c) \right\}$$

hängt von der Stichprobe nur über die suffiziente Statistik  $X_{(1)}$  ab.

In beiden Beispielen hatten wir

$$\begin{array}{ll} X_i \stackrel{iid}{\sim} \text{Normal}(\theta, 1) & \lambda(\mathbf{x}) = \lambda^*(\bar{x}) \\ X_i \stackrel{iid}{\sim} \text{Exponential}(1, \theta) & \lambda(\mathbf{x}) = \lambda^*(x_{(1)}), \end{array}$$

d.h. die LRT Statistiken hingen nur von den suffizienten Statistiken ab.

**Gilt dies allgemein?**

**Satz 4.2.1:** Ist  $T(\mathbf{X})$  eine suffiziente Statistik für  $\theta$ , und sind  $\lambda^*(t)$  sowie  $\lambda(\mathbf{x})$  die LRT Statistiken basierend auf  $T$  und auf  $\mathbf{X}$ , dann gilt für jedes  $\mathbf{x}$  aus dem Stichprobenraum

$$\lambda^*(T(\mathbf{x})) = \lambda(\mathbf{x}).$$

ad (2) “Vereinfachte Beschreibung des kritischen Bereichs”: das vereinfachte  $\lambda(\mathbf{x})$  sollte nur noch von  $T(\mathbf{x})$  abhängen.

**Beispiel 4.2.3:** Seien  $X_1, \dots, X_n$  iid Normal( $\mu, \sigma^2$ ) mit  $\sigma^2$  unbekannt: Teste

$$H_0 : \mu \leq \mu_0 \quad \text{gegen} \quad H_1 : \mu > \mu_0 .$$

In diesem Zusammenhang nennt man  $\sigma^2$  einen **nuisance parameter** (ist lästig und bringt nur Ärger, Störparameter).

Wir brauchen

$$\lambda(\mathbf{x}) = \frac{\sup_{\mu \leq \mu_0, \sigma^2} L(\mu, \sigma^2 | \mathbf{x})}{\sup_{\mu \in \mathbb{R}, \sigma^2} L(\mu, \sigma^2 | \mathbf{x})} .$$

Wie bereits gezeigt ergeben sich ohne Restriktion  $\hat{\mu} = \bar{x}$  und  $\hat{\sigma}^2 = \frac{1}{n} \sum_i (x_i - \bar{x})^2$ .

Im eingeschränkten Parameterbereich  $\mu \leq \mu_0$  ( $\sigma^2 > 0$ ) maximieren wir

$$L(\mu, \sigma^2 | \mathbf{x}) = (2\pi\sigma^2)^{-n/2} \exp \left\{ -\frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \mu)^2 \right\}.$$

Nun ist

$$\frac{d}{d\mu} \sum_{i=1}^n (x_i - \mu)^2 = -2n(\bar{x} - \mu) = \begin{cases} < 0 & \text{für } \bar{x} > \mu \\ = 0 & \text{für } \bar{x} = \mu \\ > 0 & \text{für } \bar{x} < \mu \end{cases}$$

Die Minimalstelle von  $\sum_{i=1}^n (x_i - \hat{\mu}_0)^2$  über  $\mu \leq \mu_0$  ist somit

$$\hat{\mu}_0 = \min(\bar{x}, \mu_0).$$

Es kann nun gezeigt werden, dass  $L(\hat{\mu}_0, \hat{\sigma}^2 | \mathbf{x})$  maximal ist in

$$\hat{\sigma}_0^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \hat{\mu}_0)^2.$$

Zusammen ergibt sich

$$(\hat{\mu}_0, \hat{\sigma}_0^2) = \begin{cases} (\bar{x}, \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2) & \bar{x} \leq \mu_0 \\ (\mu_0, \frac{1}{n} \sum_{i=1}^n (x_i - \mu_0)^2) & \bar{x} > \mu_0. \end{cases}$$

Das führt zu

$$\lambda(\mathbf{x}) = \frac{L(\hat{\mu}_0, \hat{\sigma}_0^2 | \mathbf{x})}{L(\bar{x}, \hat{\sigma}^2 | \mathbf{x})} = \begin{cases} 1 & \text{für } \bar{x} \leq \mu_0 \text{ (spricht für } H_0) \\ \frac{L\left(\mu_0, \frac{1}{n} \sum_i (x_i - \mu_0)^2 \mid \mathbf{x}\right)}{L(\bar{x}, \hat{\sigma}^2 | \mathbf{x})} & \text{für } \bar{x} > \mu_0. \end{cases}$$



Für den Fall  $\bar{x} > \mu_0$  ist dies

$$\begin{aligned}
 \lambda(\mathbf{x}) &= \frac{(2\pi)^{-n/2} \left[ \frac{1}{n} \sum_i (x_i - \mu_0)^2 \right]^{-n/2} \exp \left\{ -\frac{1}{2} \frac{\sum_i (x_i - \mu_0)^2}{\frac{1}{n} \sum_i (x_i - \mu_0)^2} \right\}}{(2\pi)^{-n/2} \left[ \frac{1}{n} \sum_i (x_i - \bar{x})^2 \right]^{-n/2} \exp \left\{ -\frac{1}{2} \frac{\sum_i (x_i - \bar{x})^2}{\frac{1}{n} \sum_i (x_i - \bar{x})^2} \right\}} \\
 &= \left[ \frac{\sum_i (x_i - \mu_0)^2}{\sum_i (x_i - \bar{x})^2} \right]^{-n/2} = \left[ \frac{\sum_i (x_i - \bar{x})^2 + n(\bar{x} - \mu_0)^2}{\sum_i (x_i - \bar{x})^2} \right]^{-n/2} \\
 &= \left[ 1 + \frac{n(\bar{x} - \mu_0)^2}{\sum_i (x_i - \bar{x})^2} \right]^{-n/2} = \left[ 1 + (n-1)^{-1} \left( \frac{\bar{x} - \mu_0}{s/\sqrt{n}} \right)^2 \right]^{-n/2}.
 \end{aligned}$$

Der LRT verwirft  $H_0$  falls

$$\lambda(\mathbf{x}) \leq c \Leftrightarrow \left( \frac{\bar{x} - \mu_0}{s/\sqrt{n}} \right)^2 \geq (n-1)(c^{-2/n} - 1) \Leftrightarrow \frac{\bar{x} - \mu_0}{s/\sqrt{n}} \geq c^* > 0.$$