

# Kapitel 2.7

## Likelihood-basiertes Entscheiden

Dr. Andrea Wiencierz

Institut für Statistik, LMU München

7. Juli 2014

# Wdh. datengestütztes Entscheidungsproblem

- die Komponenten eines datengestützten Entscheidungsproblems sind
  - datenfreies Entscheidungsproblem:

$$(\mathbb{A}, \Theta, l(\cdot)) \quad \text{oder} \quad (\mathbb{A}, \Theta, u(\cdot))$$

- statistisches Modell (Informationsstruktur):

$$(\mathcal{X}, \sigma(\mathcal{X}), (P_\theta)_{\theta \in \Theta}) \quad \text{oder} \quad \mathcal{X} \ni X \sim P \in \mathcal{P} = \{P_\theta : \theta \in \Theta\}$$

i.d.R. betrachten wir  $X \in \mathcal{X} \subset \mathbb{R}^n$  mit  $n \in \mathbb{N}$

# Wdh. datengestütztes Entscheidungsproblem

- die Komponenten eines datengestützten Entscheidungsproblems sind
  - datenfreies Entscheidungsproblem:

$$(\mathbb{A}, \Theta, l(\cdot)) \quad \text{oder} \quad (\mathbb{A}, \Theta, u(\cdot))$$

- statistisches Modell (Informationsstruktur):

$$(\mathcal{X}, \sigma(\mathcal{X}), (P_\theta)_{\theta \in \Theta}) \quad \text{oder} \quad \mathcal{X} \ni X \sim P \in \mathcal{P} = \{P_\theta : \theta \in \Theta\}$$

i.d.R. betrachten wir  $X \in \mathcal{X} \subset \mathbb{R}^n$  mit  $n \in \mathbb{N}$

- klassisches datenbasiertes Entscheiden:

Betrachte Entscheidungsfunktionen  $d : \mathcal{X} \rightarrow \mathbb{A}$ , die durch den erwarteten Verlust ( $R$ ) oder Nutzen ( $U$ ) über alle möglichen Beobachtungen evaluiert werden, und suche die diesbezügliche optimale Entscheidungsfunktion  $d^*$ .

# Wdh. datengestütztes Entscheidungsproblem

- die Komponenten eines datengestützten Entscheidungsproblems sind
  - datenfreies Entscheidungsproblem:

$$(\mathbb{A}, \Theta, l(\cdot)) \quad \text{oder} \quad (\mathbb{A}, \Theta, u(\cdot))$$

- statistisches Modell (Informationsstruktur):

$$(\mathcal{X}, \sigma(\mathcal{X}), (P_\theta)_{\theta \in \Theta}) \quad \text{oder} \quad \mathcal{X} \ni X \sim P \in \mathcal{P} = \{P_\theta : \theta \in \Theta\}$$

i.d.R. betrachten wir  $X \in \mathcal{X} \subset \mathbb{R}^n$  mit  $n \in \mathbb{N}$

- klassisches datenbasiertes Entscheiden:

Betrachte Entscheidungsfunktionen  $d : \mathcal{X} \rightarrow \mathbb{A}$ , die durch den erwarteten Verlust ( $R$ ) oder Nutzen ( $U$ ) über alle möglichen Beobachtungen evaluiert werden, und suche die diesbezügliche optimale Entscheidungsfunktion  $d^*$ .

- konditionales Entscheiden:

Suche die für die beobachtete Stichprobe  $X = x$  optimale Entscheidung  $a^*$ .

## 2.7 Likelihood-basiertes Entscheiden als konditionales, datenbasiertes Entscheiden

### 2.7.1 Grundlagen zu Likelihood-Funktionen

### 2.7.2 Likelihood-basiertes Entscheiden

### 2.7.3 Statistische Schätzprobleme im Kontext der Likelihood-basierten Entscheidungstheorie

# Das Likelihood-Prinzip

- gegeben ein statistisches Modell  $(\mathcal{X}, \sigma(\mathcal{X}), (P_\theta)_{\theta \in \Theta})$  und eine beobachtete Stichprobe  $X = x \in \mathcal{X}$  ist die Likelihood-Funktion  $L$  definiert als

$$L : \Theta \rightarrow \mathbb{R}_{\geq 0}, \quad \theta \mapsto L(\theta) = P_\theta(\{X = x\})$$

- betrachtet man als  $\mathcal{P} = (P_\theta)_{\theta \in \Theta}$  eine Klasse stetiger Wsk.-Verteilungen, wird  $L$  häufig durch die zu  $P_\theta$  zugehörige Dichte  $f(\cdot; \theta)$  approximiert, d.h. dann ist  $L(\theta) = f(x; \theta)$  für alle  $\theta \in \Theta$

# Das Likelihood-Prinzip

- gegeben ein statistisches Modell  $(\mathcal{X}, \sigma(\mathcal{X}), (P_\theta)_{\theta \in \Theta})$  und eine beobachtete Stichprobe  $X = x \in \mathcal{X}$  ist die Likelihood-Funktion  $L$  definiert als

$$L : \Theta \rightarrow \mathbb{R}_{\geq 0}, \quad \theta \mapsto L(\theta) = P_\theta(\{X = x\})$$

- betrachtet man als  $\mathcal{P} = (P_\theta)_{\theta \in \Theta}$  eine Klasse stetiger Wsk.-Verteilungen, wird  $L$  häufig durch die zu  $P_\theta$  zugehörige Dichte  $f(\cdot; \theta)$  approximiert, d.h. dann ist  $L(\theta) = f(x; \theta)$  für alle  $\theta \in \Theta$
- das Likelihood-Prinzip:  
Seien  $x, y \in \mathcal{X}$  zwei beobachtete Stichproben mit  $L(\theta; x) = c L(\theta; y)$ , für ein  $c \in \mathbb{R}_{>0}$ , so sollen die von  $x$  bzw.  $y$  abgeleiteten Schlüsse über  $\theta$  gleich sein.
- daraus folgt:  
Die Likelihood-Funktion enthält die gesamte relevante Information über  $\theta$  aus der beobachteten Stichprobe.
- für eine vertiefte Betrachtung siehe auch [Casella and Berger \(2002, 6.3\)](#) oder [Rüger \(1999, 2.3\)](#)

## Beispiel 1 – Binomialverteilung

- Beobachtungen sind binomialverteilt mit Wsk.  $\theta \in [0, 1]$ , d.h.  $X \sim \mathcal{B}(\theta, n)$
- die Wsk.-Funktion ist für jedes  $x \in \mathcal{X} = \{0, \dots, n\}$  gegeben durch

$$P_{\theta}(\{X = x\}) = \binom{n}{x} \theta^x (1 - \theta)^{n-x}$$




## Beispiel 1 – Binomialverteilung

- Beobachtungen sind binomialverteilt mit Wsk.  $\theta \in [0, 1]$ , d.h.  $X \sim \mathcal{B}(\theta, n)$
- die Wsk.-Funktion ist für jedes  $x \in \mathcal{X} = \{0, \dots, n\}$  gegeben durch

$$P_{\theta}(\{X = x\}) = \binom{n}{x} \theta^x (1 - \theta)^{n-x}$$

- z.B.  $\theta = 0.7$  und  $n = 10$




Wsk.-Masse der  $\mathcal{B}(0.7, 10)$ -Verteilung

## Beispiel 1 – Likelihood-Funktionen

- sei nun  $X \sim \mathcal{B}(0.7, n)$ , betrachte 3 Realisierungen von Stichproben mit
  - $n_1 = 10$  Beobachtungen, davon 10 Erfolge
  - $n_2 = 50$  Beobachtungen, davon 33 Erfolge
  - $n_3 = 100$  Beobachtungen, davon 67 Erfolge

## Beispiel 1 – Likelihood-Funktionen


- sei nun  $X \sim \mathcal{B}(0.7, n)$ , betrachte 3 Realisierungen von Stichproben mit
  - $n_1 = 10$  Beobachtungen, davon 10 Erfolge
  - $n_2 = 50$  Beobachtungen, davon 33 Erfolge
  - $n_3 = 100$  Beobachtungen, davon 67 Erfolge



Likelihood-Funktionen  $L$  für  $n_1 = 10$ ,  $n_2 = 50$  und  $n_3 = 100$

## Beispiel 1 – Likelihood-Funktionen


- sei nun  $X \sim \mathcal{B}(0.7, n)$ , betrachte 3 Realisierungen von Stichproben mit
  - $n_1 = 10$  Beobachtungen, davon 10 Erfolge
  - $n_2 = 50$  Beobachtungen, davon 33 Erfolge
  - $n_3 = 100$  Beobachtungen, davon 67 Erfolge
- normierte Likelihood  $lik : \Theta \rightarrow [0, 1]$ ,  $\theta \mapsto lik(\theta) = \frac{L(\theta)}{\sup_{\theta' \in \Theta} L(\theta')}$



normierte Likelihood-Funktionen  $lik$  für  
 $n_1 = 10$ ,  $n_2 = 50$  und  $n_3 = 100$

## Beispiel 1 – Likelihood-Funktionen

- sei nun  $X \sim \mathcal{B}(0.7, n)$ , betrachte 3 Realisierungen von Stichproben mit
  - $n_1 = 10$  Beobachtungen, davon 10 Erfolge
  - $n_2 = 50$  Beobachtungen, davon 33 Erfolge
  - $n_3 = 100$  Beobachtungen, davon 67 Erfolge
- normierte Likelihood  $lik : \Theta \rightarrow [0, 1]$ ,  $\theta \mapsto lik(\theta) = \frac{L(\theta)}{\sup_{\theta' \in \Theta} L(\theta')}$



normierte Likelihood-Funktionen  $lik$  für  
 $n_1 = 10$ ,  $n_2 = 50$  und  $n_3 = 100$

## Beispiel 2 – Normalverteilung

- Beobachtungen sind i.i.d. normalverteilt mit Erwartungswert  $\mu \in \mathbb{R}$  und Varianz  $\sigma^2 \in \mathbb{R}_{>0}$ , d.h.  $X_i \sim \mathcal{N}(\mu, \sigma^2)$  und  $(\mu, \sigma^2)^\top = \theta$
- die Dichtefunktion ist für jedes  $x \in \mathcal{X} = \mathbb{R}^n$  gegeben durch


$$f(x; \theta) = \left( \frac{1}{\sqrt{2\pi\sigma^2}} \right)^n \exp \left\{ -\frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \mu)^2 \right\}$$

## Beispiel 2 – Normalverteilung

- Beobachtungen sind i.i.d. normalverteilt mit Erwartungswert  $\mu \in \mathbb{R}$  und Varianz  $\sigma^2 \in \mathbb{R}_{>0}$ , d.h.  $X_i \sim \mathcal{N}(\mu, \sigma^2)$  und  $(\mu, \sigma^2)^\top = \theta$
- die Dichtefunktion ist für jedes  $x \in \mathcal{X} = \mathbb{R}^n$  gegeben durch

$$f(x; \theta) = \left( \frac{1}{\sqrt{2\pi\sigma^2}} \right)^n \exp \left\{ -\frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \mu)^2 \right\}$$

- z.B. Standard-Normalverteilung, d.h.  $\mu = 0$  und  $\sigma^2 = 1$  für  $n = 1$



Dichtefunktion der  $\mathcal{N}(0, 1)$ -Verteilung

## Beispiel 2 – Likelihood-Funktionen für $\mu$

- sei  $X = (X_1, \dots, X_n)$  mit  $X_i \sim \mathcal{N}(0, 1)$  für alle  $i \in \{1, \dots, n\}$
- betrachte 3 Realisierungen von Stichproben mit  $n_1 = 10$ ,  $n_2 = 50$  und  $n_3 = 100$  Beobachtungen



## Beispiel 2 – Likelihood-Funktionen für $\mu$


- sei  $X = (X_1, \dots, X_n)$  mit  $X_i \sim \mathcal{N}(0, 1)$  für alle  $i \in \{1, \dots, n\}$
- betrachte 3 Realisierungen von Stichproben mit  $n_1 = 10$ ,  $n_2 = 50$  und  $n_3 = 100$  Beobachtungen
- ist  $\sigma^2 = 1$  bekannt, ergibt sich die Likelihood-Funktion für  $\mu$  als

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

## Beispiel 2 – Likelihood-Funktionen für $\mu$

- sei  $X = (X_1, \dots, X_n)$  mit  $X_i \sim \mathcal{N}(0, 1)$  für alle  $i \in \{1, \dots, n\}$
- betrachte 3 Realisierungen von Stichproben mit  $n_1 = 10$ ,  $n_2 = 50$  und  $n_3 = 100$  Beobachtungen
- ist  $\sigma^2 = 1$  bekannt, ergibt sich die Likelihood-Funktion für  $\mu$  als

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



normierte Likelihood-Funktionen  $lik(\mu)$  für

$n_1 = 10$ ,  $n_2 = 50$  und  $n_3 = 100$

## Beispiel 2 – Likelihood-Funktionen für $\sigma^2$

- sei  $X = (X_1, \dots, X_n)$  mit  $X_i \sim \mathcal{N}(0, 1)$  für alle  $i \in \{1, \dots, n\}$
- betrachte 3 Realisierungen von Stichproben mit  $n_1 = 10$ ,  $n_2 = 50$  und  $n_3 = 100$  Beobachtungen

## Beispiel 2 – Likelihood-Funktionen für $\sigma^2$


- sei  $X = (X_1, \dots, X_n)$  mit  $X_i \sim \mathcal{N}(0, 1)$  für alle  $i \in \{1, \dots, n\}$
- betrachte 3 Realisierungen von Stichproben mit  $n_1 = 10$ ,  $n_2 = 50$  und  $n_3 = 100$  Beobachtungen
- ist  $\mu = 0$  bekannt, ergibt sich die Likelihood-Funktion für  $\sigma^2$  als

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

## Beispiel 2 – Likelihood-Funktionen für $\sigma^2$

- sei  $X = (X_1, \dots, X_n)$  mit  $X_i \sim \mathcal{N}(0, 1)$  für alle  $i \in \{1, \dots, n\}$
- betrachte 3 Realisierungen von Stichproben mit  $n_1 = 10$ ,  $n_2 = 50$  und  $n_3 = 100$  Beobachtungen
- ist  $\mu = 0$  bekannt, ergibt sich die Likelihood-Funktion für  $\sigma^2$  als

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



normierte Likelihood-Funktionen  $lik(\sigma^2)$  für


$n_1 = 10$ ,  $n_2 = 50$  und  $n_3 = 100$

## Beispiel 2 – bivariate Likelihood-Funktion

- sei  $X = (X_1, \dots, X_n)$  mit  $X_i \sim \mathcal{N}(0, 1)$  für alle  $i \in \{1, \dots, n\}$
- betrachte nur die Stichprobenrealisierung mit  $n_2 = 50$  Beobachtungen

## Beispiel 2 – bivariate Likelihood-Funktion


- sei  $X = (X_1, \dots, X_n)$  mit  $X_i \sim \mathcal{N}(0, 1)$  für alle  $i \in \{1, \dots, n\}$
- betrachte nur die Stichprobenrealisierung mit  $n_2 = 50$  Beobachtungen
- bivariate Likelihood-Funktion für  $\theta = (\mu, \sigma^2)^T$



normierte Likelihood-Funktion  $lik(\mu, \sigma^2)$  für  
 $n_2 = 50$

## Beispiel 2 – bivariate Likelihood-Funktion

- sei  $X = (X_1, \dots, X_n)$  mit  $X_i \sim \mathcal{N}(0, 1)$  für alle  $i \in \{1, \dots, n\}$
- betrachte nur die Stichprobenrealisierung mit  $n_2 = 50$  Beobachtungen
- bivariate Likelihood-Funktion für  $\theta = (\mu, \sigma^2)^T$



normierte Likelihood-Funktion  $lik(\mu, \sigma^2)$  für  
 $n_2 = 50$



## 2.7 Likelihood-basiertes Entscheiden als konditionales, datenbasiertes Entscheiden

2.7.1 Grundlagen zu Likelihood-Funktionen

**2.7.2 Likelihood-basiertes Entscheiden**

2.7.3 Statistische Schätzprobleme im Kontext der Likelihood-basierten Entscheidungstheorie

# Illustrationsbeispiel – Investitionsproblem

- datenfreies Problem  $(\mathbb{A}, \Theta, u(\cdot))$
- statistisches Modell  $(\mathcal{X}, \sigma(\mathcal{X}), (P_\theta)_{\theta \in \Theta})$

$a_1$	Investition tätigen
$a_2$	Investition nicht tätigen

$\theta_1$	Besserung der Konjunktur
$\theta_2$	Stagnation
$\theta_3$	Konjunktur fällt

$u(a_i, \theta_j)$	$\theta_1$	$\theta_2$	$\theta_3$
$a_1$	10 000	2 000	-15 000
$a_2$	1 000	1 000	0

$x_1$	Konjunktur wird voraussichtlich steigen
$x_2$	Stagnation wird erwartet
$x_3$	Konjunktur wird voraussichtlich fallen

$P_{\theta_i}(\{X = x_i\})$	$x_1$	$x_2$	$x_3$
$\theta_1$	0.6	0.3	0.1
$\theta_2$	0.2	0.4	0.4
$\theta_3$	0.1	0.4	0.5

# Illustrationsbeispiel – Investitionsproblem

- datenfreies Problem  $(\mathbb{A}, \Theta, u(\cdot))$
- statistisches Modell  $(\mathcal{X}, \sigma(\mathcal{X}), (P_\theta)_{\theta \in \Theta})$

$a_1$	Investition tätigen
$a_2$	Investition nicht tätigen

$\theta_1$	Besserung der Konjunktur
$\theta_2$	Stagnation
$\theta_3$	Konjunktur fällt

$u(a_i, \theta_j)$	$\theta_1$	$\theta_2$	$\theta_3$
$a_1$	10 000	2 000	-15 000
$a_2$	1 000	1 000	0

$x_1$	Konjunktur wird voraussichtlich steigen
$x_2$	Stagnation wird erwartet
$x_3$	Konjunktur wird voraussichtlich fallen

$P_{\theta_i}(\{X = x_i\})$	$x_1$	$x_2$	$x_3$
$\theta_1$	0.6	0.3	0.1
$\theta_2$	0.2	0.4	0.4
$\theta_3$	0.1	0.4	0.5

- nehmen wir an, dass  $X = x_1$  beobachtet wurde, dann nimmt die Likelihood-Funktion  $L$  folgende Werte an:

$$L(\theta_1) = P_{\theta_1}(\{X = x_1\}) = 0.6, \quad L(\theta_2) = 0.2 \quad \text{und} \quad L(\theta_3) = 0.1$$

# Illustrationsbeispiel – Investitionsproblem

- datenfreies Problem ( $\mathbb{A}, \Theta, u(\cdot)$ )
- statistisches Modell  $(\mathcal{X}, \sigma(\mathcal{X}), (P_\theta)_{\theta \in \Theta})$

$a_1$	Investition tätigen
$a_2$	Investition nicht tätigen

$\theta_1$	Besserung der Konjunktur
$\theta_2$	Stagnation
$\theta_3$	Konjunktur fällt

$u(a_i, \theta_j)$	$\theta_1$	$\theta_2$	$\theta_3$
$a_1$	10 000	2 000	-15 000
$a_2$	1 000	1 000	0

$x_1$	Konjunktur wird voraussichtlich steigen
$x_2$	Stagnation wird erwartet
$x_3$	Konjunktur wird voraussichtlich fallen

$P_{\theta_i}(\{X = x_i\})$	$x_1$	$x_2$	$x_3$
$\theta_1$	0.6	0.3	0.1
$\theta_2$	0.2	0.4	0.4
$\theta_3$	0.1	0.4	0.5

- nehmen wir an, dass  $X = x_1$  beobachtet wurde, dann nimmt die Likelihood-Funktion  $L$  folgende Werte an:

$$L(\theta_1) = P_{\theta_1}(\{X = x_1\}) = 0.6, \quad L(\theta_2) = 0.2 \quad \text{und} \quad L(\theta_3) = 0.1$$

- normierte Likelihood:  $lik(\theta_1) = 1, \quad lik(\theta_2) = \frac{1}{3} \quad \text{und} \quad lik(\theta_3) = \frac{1}{6}$

# Maximum-Likelihood-Aktionen

- Sei ein datengestütztes Entscheidungsproblem in Nutzenform  $((\mathbb{A}, \Theta, u(\cdot)), (\mathcal{X}, \sigma(\mathcal{X}), (P_\theta)_{\theta \in \Theta}))$ , eine Realisierung  $X = x$  des Informationsbeschaffungsexperiments und die dadurch induzierte (normierte) Likelihood-Funktion  $lik$  gegeben.

# Maximum-Likelihood-Aktionen

- Sei ein datengestütztes Entscheidungsproblem in Nutzenform  $((\mathbb{A}, \Theta, u(\cdot)), (\mathcal{X}, \sigma(\mathcal{X}), (P_\theta)_{\theta \in \Theta}))$ , eine Realisierung  $X = x$  des Informationsbeschaffungsexperiments und die dadurch induzierte (normierte) Likelihood-Funktion  $lik$  gegeben.
- Das Entscheidungskriterium

$$\Phi_{ML} : \mathbb{A} \rightarrow \mathbb{R}, \quad a \mapsto \Phi_{ML}(a) = u(a, \hat{\theta})$$

mit

$$\hat{\theta} = \arg \max_{\theta \in \Theta} lik(\theta)$$

heißt Maximum-Likelihood-Entscheidungskriterium.

# Maximum-Likelihood-Aktionen

- Sei ein datengestütztes Entscheidungsproblem in Nutzenform  $((\mathbb{A}, \Theta, u(\cdot)), (\mathcal{X}, \sigma(\mathcal{X}), (P_\theta)_{\theta \in \Theta}))$ , eine Realisierung  $X = x$  des Informationsbeschaffungsexperiments und die dadurch induzierte (normierte) Likelihood-Funktion  $lik$  gegeben.
- Das Entscheidungskriterium

$$\Phi_{ML} : \mathbb{A} \rightarrow \mathbb{R}, \quad a \mapsto \Phi_{ML}(a) = u(a, \hat{\theta})$$

mit

$$\hat{\theta} = \arg \max_{\theta \in \Theta} lik(\theta)$$

heißt Maximum-Likelihood-Entscheidungskriterium.

Eine Aktion  $a^*$ , für die gilt  $\Phi_{ML}(a^*) = \sup_{a \in \mathbb{A}} \Phi_{ML}(a)$ , heißt Maximum-Likelihood-Aktion.

# Maximum-Likelihood-Aktionen

- Sei ein datengestütztes Entscheidungsproblem in Nutzenform  $((\mathbb{A}, \Theta, u(\cdot)), (\mathcal{X}, \sigma(\mathcal{X}), (P_\theta)_{\theta \in \Theta}))$ , eine Realisierung  $X = x$  des Informationsbeschaffungsexperiments und die dadurch induzierte (normierte) Likelihood-Funktion  $lik$  gegeben.
- Das Entscheidungskriterium

$$\Phi_{ML} : \mathbb{A} \rightarrow \mathbb{R}, \quad a \mapsto \Phi_{ML}(a) = u(a, \hat{\theta})$$

mit

$$\hat{\theta} = \arg \max_{\theta \in \Theta} lik(\theta)$$

heißt Maximum-Likelihood-Entscheidungskriterium.

Eine Aktion  $a^*$ , für die gilt  $\Phi_{ML}(a^*) = \sup_{a \in \mathbb{A}} \Phi_{ML}(a)$ , heißt Maximum-Likelihood-Aktion.

- Liegt ein Entscheidungsproblem in Verlustform vor, werden  $\Phi_{ML}$  und  $a^*$  analog definiert.



# Maximum-Likelihood-Entscheidungskriterium

- $\Phi_{ML}$  ordnet jeder Handlungsalternative  $a \in \mathbb{A}$  die ML-Schätzung des Nutzens bzw. Verlustes von  $a$  zu

# Maximum-Likelihood-Entscheidungskriterium

- $\Phi_{ML}$  ordnet jeder Handlungsalternative  $a \in \mathbb{A}$  die ML-Schätzung des Nutzens bzw. Verlustes von  $a$  zu
- Sei  $\hat{\theta}$  der ML-Schätzer für  $\theta \in \Theta$ , dann ist für jede Funktion  $g : \Theta \rightarrow \mathcal{G}$  der ML-Schätzer von  $g(\theta)$  durch  $g(\hat{\theta})$  gegeben.

# Maximum-Likelihood-Entscheidungskriterium

- $\Phi_{ML}$  ordnet jeder Handlungsalternative  $a \in \mathbb{A}$  die ML-Schätzung des Nutzens bzw. Verlustes von  $a$  zu
- Sei  $\hat{\theta}$  der ML-Schätzer für  $\theta \in \Theta$ , dann ist für jede Funktion  $g : \Theta \rightarrow \mathcal{G}$  der ML-Schätzer von  $g(\theta)$  durch  $g(\hat{\theta})$  gegeben.

Die (normierte) Likelihood-Funktion  $lik_g$  für den transformierten Parameter  $g(\theta)$  ist für jedes  $\gamma \in \mathcal{G}$  definiert als

$$lik_g(\gamma) = \sup_{\theta \in \Theta : g(\theta) = \gamma} lik(\theta)$$

(Siehe z.B. Casella and Berger, 2002, 7.2.2 .)

- $lik_g$  wird auch als Profile-Likelihood-Funktion für  $g(\theta)$  bezeichnet

# Maximum-Likelihood-Entscheidungskriterium

- $\Phi_{ML}$  ordnet jeder Handlungsalternative  $a \in \mathbb{A}$  die ML-Schätzung des Nutzens bzw. Verlustes von  $a$  zu
- Sei  $\hat{\theta}$  der ML-Schätzer für  $\theta \in \Theta$ , dann ist für jede Funktion  $g : \Theta \rightarrow \mathcal{G}$  der ML-Schätzer von  $g(\theta)$  durch  $g(\hat{\theta})$  gegeben.

Die (normierte) Likelihood-Funktion  $lik_g$  für den transformierten Parameter  $g(\theta)$  ist für jedes  $\gamma \in \mathcal{G}$  definiert als

$$lik_g(\gamma) = \sup_{\theta \in \Theta : g(\theta) = \gamma} lik(\theta)$$

(Siehe z.B. Casella and Berger, 2002, 7.2.2 .)

- $lik_g$  wird auch als Profile-Likelihood-Funktion für  $g(\theta)$  bezeichnet
- im Kontext der Entscheidungstheorie entspricht  $g$  für jede Aktion  $a \in \mathbb{A}$  der aktionsspezifischen Nutzenfunktion  $u_a = u(a, \cdot)$  bzw. Verlustfunktion  $l_a = l(a, \cdot)$

# ML-Aktion im Investitionsproblem bei $X = x_1$

- Profile-Likelihood-Funktion für  $u_{a_1}$ :

$$lik_{u_{a_1}}(v) = \sup_{\theta \in \Theta : u_{a_1}(\theta) = v} lik(\theta), \quad \text{für } v \in \{-15\,000, 2\,000, 10\,000\}$$

# ML-Aktion im Investitionsproblem bei $X = x_1$

- Profile-Likelihood-Funktion für  $u_{a_1}$ :

$$lik_{u_{a_1}}(v) = \sup_{\theta \in \Theta : u_{a_1}(\theta) = v} lik(\theta), \quad \text{für } v \in \{-15\,000, 2\,000, 10\,000\}$$

$$lik_{u_{a_1}}(-15\,000) = \sup_{\theta \in \Theta : u_{a_1}(\theta) = -15\,000} lik(\theta) = lik(\theta_3) = \frac{1}{6},$$

# ML-Aktion im Investitionsproblem bei $X = x_1$

- Profile-Likelihood-Funktion für  $u_{a_1}$ :

$$lik_{u_{a_1}}(v) = \sup_{\theta \in \Theta : u_{a_1}(\theta) = v} lik(\theta), \quad \text{für } v \in \{-15\,000, 2\,000, 10\,000\}$$

$$lik_{u_{a_1}}(-15\,000) = \sup_{\theta \in \Theta : u_{a_1}(\theta) = -15\,000} lik(\theta) = lik(\theta_3) = \frac{1}{6},$$

$$lik_{u_{a_1}}(2\,000) = lik(\theta_2) = \frac{1}{3} \quad \text{und} \quad lik_{u_{a_1}}(10\,000) = lik(\theta_1) = 1$$

## ML-Aktion im Investitionsproblem bei $X = x_1$

- Profile-Likelihood-Funktion für  $u_{a_1}$ :

$$lik_{u_{a_1}}(v) = \sup_{\theta \in \Theta : u_{a_1}(\theta) = v} lik(\theta), \quad \text{für } v \in \{-15\,000, 2\,000, 10\,000\}$$

$$lik_{u_{a_1}}(-15\,000) = \sup_{\theta \in \Theta : u_{a_1}(\theta) = -15\,000} lik(\theta) = lik(\theta_3) = \frac{1}{6},$$

$$lik_{u_{a_1}}(2\,000) = lik(\theta_2) = \frac{1}{3} \quad \text{und} \quad lik_{u_{a_1}}(10\,000) = lik(\theta_1) = 1$$

- ML-Schätzer für  $u_{a_1}$  ist  $10\,000 = \Phi_{ML}(a_1)$
- Profile-Likelihood-Funktion  $lik_{u_{a_2}}$  für  $v \in \{0, 1\,000\}$ :



## ML-Aktion im Investitionsproblem bei $X = x_1$

- Profile-Likelihood-Funktion für  $u_{a_1}$ :

$$lik_{u_{a_1}}(v) = \sup_{\theta \in \Theta : u_{a_1}(\theta) = v} lik(\theta), \quad \text{für } v \in \{-15\,000, 2\,000, 10\,000\}$$

$$lik_{u_{a_1}}(-15\,000) = \sup_{\theta \in \Theta : u_{a_1}(\theta) = -15\,000} lik(\theta) = lik(\theta_3) = \frac{1}{6},$$

$$lik_{u_{a_1}}(2\,000) = lik(\theta_2) = \frac{1}{3} \quad \text{und} \quad lik_{u_{a_1}}(10\,000) = lik(\theta_1) = 1$$

- ML-Schätzer für  $u_{a_1}$  ist  $10\,000 = \Phi_{ML}(a_1)$
- Profile-Likelihood-Funktion  $lik_{u_{a_2}}$  für  $v \in \{0, 1\,000\}$ :

$$lik_{u_{a_2}}(0) = lik(\theta_3) = \frac{1}{6} \quad \text{und}$$

# ML-Aktion im Investitionsproblem bei $X = x_1$

- Profile-Likelihood-Funktion für  $u_{a_1}$ :

$$lik_{u_{a_1}}(v) = \sup_{\theta \in \Theta : u_{a_1}(\theta) = v} lik(\theta), \quad \text{für } v \in \{-15\,000, 2\,000, 10\,000\}$$

$$lik_{u_{a_1}}(-15\,000) = \sup_{\theta \in \Theta : u_{a_1}(\theta) = -15\,000} lik(\theta) = lik(\theta_3) = \frac{1}{6},$$

$$lik_{u_{a_1}}(2\,000) = lik(\theta_2) = \frac{1}{3} \quad \text{und} \quad lik_{u_{a_1}}(10\,000) = lik(\theta_1) = 1$$

- ML-Schätzer für  $u_{a_1}$  ist  $10\,000 = \Phi_{ML}(a_1)$
- Profile-Likelihood-Funktion  $lik_{u_{a_2}}$  für  $v \in \{0, 1\,000\}$ :

$$lik_{u_{a_2}}(0) = lik(\theta_3) = \frac{1}{6} \quad \text{und}$$

$$lik_{u_{a_2}}(1\,000) = \sup_{\theta \in \Theta : u_{a_2}(\theta) = 1\,000} lik(\theta) = \sup\{lik(\theta_1), lik(\theta_2)\} = 1$$

# ML-Aktion im Investitionsproblem bei $X = x_1$

- Profile-Likelihood-Funktion für  $u_{a_1}$ :

$$lik_{u_{a_1}}(v) = \sup_{\theta \in \Theta : u_{a_1}(\theta) = v} lik(\theta), \quad \text{für } v \in \{-15\,000, 2\,000, 10\,000\}$$

$$lik_{u_{a_1}}(-15\,000) = \sup_{\theta \in \Theta : u_{a_1}(\theta) = -15\,000} lik(\theta) = lik(\theta_3) = \frac{1}{6},$$

$$lik_{u_{a_1}}(2\,000) = lik(\theta_2) = \frac{1}{3} \quad \text{und} \quad lik_{u_{a_1}}(10\,000) = lik(\theta_1) = 1$$

- ML-Schätzer für  $u_{a_1}$  ist  $10\,000 = \Phi_{ML}(a_1)$
- Profile-Likelihood-Funktion  $lik_{u_{a_2}}$  für  $v \in \{0, 1\,000\}$ :

$$lik_{u_{a_2}}(0) = lik(\theta_3) = \frac{1}{6} \quad \text{und}$$

$$lik_{u_{a_2}}(1\,000) = \sup_{\theta \in \Theta : u_{a_2}(\theta) = 1\,000} lik(\theta) = \sup\{lik(\theta_1), lik(\theta_2)\} = 1$$

- ML-Schätzer für  $u_{a_2}$  ist  $1\,000 = \Phi_{ML}(a_2)$

# ML-Aktion im Investitionsproblem bei $X = x_1$

- Profile-Likelihood-Funktion für  $u_{a_1}$ :

$$lik_{u_{a_1}}(v) = \sup_{\theta \in \Theta : u_{a_1}(\theta) = v} lik(\theta), \quad \text{für } v \in \{-15\,000, 2\,000, 10\,000\}$$

$$lik_{u_{a_1}}(-15\,000) = \sup_{\theta \in \Theta : u_{a_1}(\theta) = -15\,000} lik(\theta) = lik(\theta_3) = \frac{1}{6},$$

$$lik_{u_{a_1}}(2\,000) = lik(\theta_2) = \frac{1}{3} \quad \text{und} \quad lik_{u_{a_1}}(10\,000) = lik(\theta_1) = 1$$

- ML-Schätzer für  $u_{a_1}$  ist  $10\,000 = \Phi_{ML}(a_1)$
- Profile-Likelihood-Funktion  $lik_{u_{a_2}}$  für  $v \in \{0, 1\,000\}$ :

$$lik_{u_{a_2}}(0) = lik(\theta_3) = \frac{1}{6} \quad \text{und}$$

$$lik_{u_{a_2}}(1\,000) = \sup_{\theta \in \Theta : u_{a_2}(\theta) = 1\,000} lik(\theta) = \sup\{lik(\theta_1), lik(\theta_2)\} = 1$$

- ML-Schätzer für  $u_{a_2}$  ist  $1\,000 = \Phi_{ML}(a_2)$
- da  $\sup_{a \in \mathbb{A}} \Phi_{ML}(a) = \sup\{\Phi_{ML}(a_1), \Phi_{ML}(a_2)\} = \Phi_{ML}(a_1)$ , ist  $a^* = a_1$

# Likelihood-based Region Minimax-Aktionen

- Sei ein datengestütztes Entscheidungsproblem in Nutzenform  $((\mathbb{A}, \Theta, u(\cdot)), (\mathcal{X}, \sigma(\mathcal{X}), (P_\theta)_{\theta \in \Theta}))$ , eine Realisierung  $X = x$  des Informationsbeschaffungsexperiments und die dadurch induzierte (normierte) Likelihood-Funktion  $lik$  gegeben.

# Likelihood-based Region Minimax-Aktionen

- Sei ein datengestütztes Entscheidungsproblem in Nutzenform  $((\mathbb{A}, \Theta, u(\cdot)), (\mathcal{X}, \sigma(\mathcal{X}), (P_\theta)_{\theta \in \Theta}))$ , eine Realisierung  $X = x$  des Informationsbeschaffungsexperiments und die dadurch induzierte (normierte) Likelihood-Funktion  $lik$  gegeben.
- Das Entscheidungskriterium

$$\Phi_{LRM} : \mathbb{A} \rightarrow \mathbb{R}, \quad a \mapsto \Phi_{LRM}(a) = \inf_{\theta \in \mathcal{T}_{>\beta}} u(a, \theta),$$

wobei

$$\mathcal{T}_{>\beta} = \{\theta \in \Theta : lik(\theta) > \beta\}, \quad \text{für ein } \beta \in (0, 1),$$

heißt Likelihood-based Region Minimax-Entscheidungskriterium.

# Likelihood-based Region Minimax-Aktionen

- Sei ein datengestütztes Entscheidungsproblem in Nutzenform  $((\mathbb{A}, \Theta, u(\cdot)), (\mathcal{X}, \sigma(\mathcal{X}), (P_\theta)_{\theta \in \Theta}))$ , eine Realisierung  $X = x$  des Informationsbeschaffungsexperiments und die dadurch induzierte (normierte) Likelihood-Funktion  $lik$  gegeben.
- Das Entscheidungskriterium

$$\Phi_{LRM} : \mathbb{A} \rightarrow \mathbb{R}, \quad a \mapsto \Phi_{LRM}(a) = \inf_{\theta \in \mathcal{T}_{>\beta}} u(a, \theta),$$

wobei

$$\mathcal{T}_{>\beta} = \{\theta \in \Theta : lik(\theta) > \beta\}, \quad \text{für ein } \beta \in (0, 1),$$

heißt Likelihood-based Region Minimax-Entscheidungskriterium.

Eine Aktion  $a^*$ , für die gilt  $\Phi_{LRM}(a^*) = \sup_{a \in \mathbb{A}} \Phi_{LRM}(a)$ , heißt Likelihood-based Region Minimax-Aktion.

# Likelihood-based Region Minimax-Aktionen

- Sei ein datengestütztes Entscheidungsproblem in Nutzenform  $((\mathbb{A}, \Theta, u(\cdot)), (\mathcal{X}, \sigma(\mathcal{X}), (P_\theta)_{\theta \in \Theta}))$ , eine Realisierung  $X = x$  des Informationsbeschaffungsexperiments und die dadurch induzierte (normierte) Likelihood-Funktion  $lik$  gegeben.
- Das Entscheidungskriterium

$$\Phi_{LRM} : \mathbb{A} \rightarrow \mathbb{R}, \quad a \mapsto \Phi_{LRM}(a) = \inf_{\theta \in \mathcal{T}_{>\beta}} u(a, \theta),$$

wobei

$$\mathcal{T}_{>\beta} = \{\theta \in \Theta : lik(\theta) > \beta\}, \quad \text{für ein } \beta \in (0, 1),$$

heißt Likelihood-based Region Minimax-Entscheidungskriterium.

Eine Aktion  $a^*$ , für die gilt  $\Phi_{LRM}(a^*) = \sup_{a \in \mathbb{A}} \Phi_{LRM}(a)$ , heißt Likelihood-based Region Minimax-Aktion.

- Liegt ein Entscheidungsproblem in Verlustform vor, können  $\Phi_{LRM}$  und  $a^*$  analog definiert werden.



# Likelihood-based Region Minimax-Entscheidungskriterium

- für jedes  $a \in \mathbb{A}$  ist  $\Phi$  Untergrenze einer Konfidenzregion  $\mathcal{U}_{a, > \beta}$  für  $u_a$ :

$$\Phi_{LRM}(a) = \inf \mathcal{U}_{a, > \beta} \quad \text{mit} \quad \mathcal{U}_{a, > \beta} = \bigcup_{\theta \in \mathcal{T}_{> \beta}} u(a, \theta) = \{v : \text{lik}_{u_a}(v) > \beta\}$$

# Likelihood-based Region Minimax-Entscheidungskriterium

- für jedes  $a \in \mathbb{A}$  ist  $\Phi$  Untergrenze einer Konfidenzregion  $\mathcal{U}_{a, > \beta}$  für  $u_a$ :

$$\Phi_{LRM}(a) = \inf \mathcal{U}_{a, > \beta} \quad \text{mit} \quad \mathcal{U}_{a, > \beta} = \bigcup_{\theta \in \mathcal{T}_{> \beta}} u(a, \theta) = \{v : \text{lik}_{u_a}(v) > \beta\}$$


- Intervalle der Form von  $\mathcal{U}_{a, > \beta}$  sind Likelihood-basierte Konfidenzregionen mit asymptotischer Überdeckungswsk.  $F_{\chi_1^2}(-2 \log(\beta))$ , z.B. für  $\beta = 0.5$  ca. 76%

# Likelihood-based Region Minimax-Entscheidungskriterium

- für jedes  $a \in \mathbb{A}$  ist  $\Phi$  Untergrenze einer Konfidenzregion  $\mathcal{U}_{a, > \beta}$  für  $u_a$ :

$$\Phi_{LRM}(a) = \inf \mathcal{U}_{a, > \beta} \quad \text{mit} \quad \mathcal{U}_{a, > \beta} = \bigcup_{\theta \in \mathcal{T}_{> \beta}} u(a, \theta) = \{v : \text{lik}_{u_a}(v) > \beta\}$$

- Intervalle der Form von  $\mathcal{U}_{a, > \beta}$  sind Likelihood-basierte Konfidenzregionen mit asymptotischer Überdeckungswsk.  $F_{\chi_1^2}(-2 \log(\beta))$ , z.B. für  $\beta = 0.5$  ca. 76%



normierte Likelihood-Funktion  $\text{lik}(\sigma^2)$  für  $n_2 = 50$  mit approximativem 76% KI

## LRM-Aktionen im Investitionsproblem bei $X = x_1$

- für  $\beta = 0.5$  enthält  $\mathcal{T}_{>\beta} = \{\theta \in \Theta : lik(\theta) > \beta\} = \{\theta_1\}$

## LRM-Aktionen im Investitionsproblem bei $X = x_1$

- für  $\beta = 0.5$  enthält  $\mathcal{T}_{>\beta} = \{\theta \in \Theta : \text{lik}(\theta) > \beta\} = \{\theta_1\}$
- damit ist  $\Phi_{LRM}(a_i) = \inf_{\theta \in \{\theta_1\}} u(a_i, \theta) = u(a_i, \hat{\theta}) = \Phi_{ML}(a_i)$  für  $i \in \{1, 2\}$

## LRM-Aktionen im Investitionsproblem bei $X = x_1$

- für  $\beta = 0.5$  enthält  $\mathcal{T}_{>\beta} = \{\theta \in \Theta : \text{lik}(\theta) > \beta\} = \{\theta_1\}$
- damit ist  $\Phi_{LRM}(a_i) = \inf_{\theta \in \{\theta_1\}} u(a_i, \theta) = u(a_i, \hat{\theta}) = \Phi_{ML}(a_i)$  für  $i \in \{1, 2\}$
- für  $\beta = 0.26$  enthält  $\mathcal{T}_{>\beta} = \{\theta \in \Theta : \text{lik}(\theta) > \beta\} = \{\theta_1, \theta_2\}$

## LRM-Aktionen im Investitionsproblem bei $X = x_1$

- für  $\beta = 0.5$  enthält  $\mathcal{T}_{>\beta} = \{\theta \in \Theta : \text{lik}(\theta) > \beta\} = \{\theta_1\}$
- damit ist  $\Phi_{LRM}(a_i) = \inf_{\theta \in \{\theta_1\}} u(a_i, \theta) = u(a_i, \hat{\theta}) = \Phi_{ML}(a_i)$  für  $i \in \{1, 2\}$
- für  $\beta = 0.26$  enthält  $\mathcal{T}_{>\beta} = \{\theta \in \Theta : \text{lik}(\theta) > \beta\} = \{\theta_1, \theta_2\}$
- damit ist  $\Phi_{LRM}(a_i) = \inf_{\theta \in \{\theta_1, \theta_2\}} u(a_i, \theta)$  für  $i \in \{1, 2\}$ , d.h.

$$\Phi_{LRM}(a_1) = \inf\{u(a_1, \theta_1), u(a_1, \theta_2)\} = 2000 \quad \text{und} \quad \Phi_{LRM}(a_2) = 1000$$

- also ergibt sich als LRM-Aktion  $a^* = a_1$

## LRM-Aktionen im Investitionsproblem bei $X = x_1$

- für  $\beta = 0.5$  enthält  $\mathcal{T}_{>\beta} = \{\theta \in \Theta : \text{lik}(\theta) > \beta\} = \{\theta_1\}$
- damit ist  $\Phi_{LRM}(a_i) = \inf_{\theta \in \{\theta_1\}} u(a_i, \theta) = u(a_i, \hat{\theta}) = \Phi_{ML}(a_i)$  für  $i \in \{1, 2\}$
- für  $\beta = 0.26$  enthält  $\mathcal{T}_{>\beta} = \{\theta \in \Theta : \text{lik}(\theta) > \beta\} = \{\theta_1, \theta_2\}$
- damit ist  $\Phi_{LRM}(a_i) = \inf_{\theta \in \{\theta_1, \theta_2\}} u(a_i, \theta)$  für  $i \in \{1, 2\}$ , d.h.

$$\Phi_{LRM}(a_1) = \inf\{u(a_1, \theta_1), u(a_1, \theta_2)\} = 2000 \quad \text{und} \quad \Phi_{LRM}(a_2) = 1000$$

- also ergibt sich als LRM-Aktion  $a^* = a_1$
- für  $\beta = 0.15$  enthält  $\mathcal{T}_{>\beta} = \{\theta \in \Theta : \text{lik}(\theta) > \beta\} = \{\theta_1, \theta_2, \theta_3\}$



## LRM-Aktionen im Investitionsproblem bei $X = x_1$

- für  $\beta = 0.5$  enthält  $\mathcal{T}_{>\beta} = \{\theta \in \Theta : \text{lik}(\theta) > \beta\} = \{\theta_1\}$
- damit ist  $\Phi_{LRM}(a_i) = \inf_{\theta \in \{\theta_1\}} u(a_i, \theta) = u(a_i, \hat{\theta}) = \Phi_{ML}(a_i)$  für  $i \in \{1, 2\}$
- für  $\beta = 0.26$  enthält  $\mathcal{T}_{>\beta} = \{\theta \in \Theta : \text{lik}(\theta) > \beta\} = \{\theta_1, \theta_2\}$
- damit ist  $\Phi_{LRM}(a_i) = \inf_{\theta \in \{\theta_1, \theta_2\}} u(a_i, \theta)$  für  $i \in \{1, 2\}$ , d.h.

$$\Phi_{LRM}(a_1) = \inf\{u(a_1, \theta_1), u(a_1, \theta_2)\} = 2000 \quad \text{und} \quad \Phi_{LRM}(a_2) = 1000$$

- also ergibt sich als LRM-Aktion  $a^* = a_1$
- für  $\beta = 0.15$  enthält  $\mathcal{T}_{>\beta} = \{\theta \in \Theta : \text{lik}(\theta) > \beta\} = \{\theta_1, \theta_2, \theta_3\}$
- damit ist  $\Phi_{LRM}(a_i) = \inf_{\theta \in \{\theta_1, \theta_2, \theta_3\}} u(a_i, \theta)$  für  $i \in \{1, 2\}$ , d.h.

$$\Phi_{LRM}(a_1) = \inf\{u(a_1, \theta_1), u(a_1, \theta_2), u(a_1, \theta_3)\} = -15000 \quad \text{und}$$

$$\Phi_{LRM}(a_2) = \inf\{u(a_2, \theta_1), u(a_2, \theta_2), u(a_2, \theta_3)\} = 0$$

- also ergibt sich als LRM-Aktion  $a^* = a_2$

## LRM-Aktionen im Investitionsproblem bei $X = x_2$

- für  $X = x_2$  ist  $lik(\theta_1) = \frac{3}{4}$  und  $lik(\theta_2) = lik(\theta_3) = 1$

## LRM-Aktionen im Investitionsproblem bei $X = x_2$

- für  $X = x_2$  ist  $lik(\theta_1) = \frac{3}{4}$  und  $lik(\theta_2) = lik(\theta_3) = 1$
- für  $\beta \in \{0.15, 0.26, 0.5\}$  enthält  $\mathcal{T}_{>\beta} = \{\theta \in \Theta : lik(\theta) > \beta\} = \{\theta_1, \theta_2, \theta_3\}$

## LRM-Aktionen im Investitionsproblem bei $X = x_2$

- für  $X = x_2$  ist  $lik(\theta_1) = \frac{3}{4}$  und  $lik(\theta_2) = lik(\theta_3) = 1$
- für  $\beta \in \{0.15, 0.26, 0.5\}$  enthält  $\mathcal{T}_{>\beta} = \{\theta \in \Theta : lik(\theta) > \beta\} = \{\theta_1, \theta_2, \theta_3\}$
- damit ist  $\Phi_{LRM}(a_i) = \inf_{\theta \in \{\theta_1, \theta_2, \theta_3\}} u(a_i, \theta)$  für  $i \in \{1, 2\}$ , d.h.

$$\Phi_{LRM}(a_1) = \inf\{u(a_1, \theta_1), u(a_1, \theta_2), u(a_1, \theta_3)\} = -15\,000 \quad \text{und}$$

$$\Phi_{LRM}(a_2) = \inf\{u(a_2, \theta_1), u(a_2, \theta_2), u(a_2, \theta_3)\} = 0$$

## LRM-Aktionen im Investitionsproblem bei $X = x_2$

- für  $X = x_2$  ist  $lik(\theta_1) = \frac{3}{4}$  und  $lik(\theta_2) = lik(\theta_3) = 1$
- für  $\beta \in \{0.15, 0.26, 0.5\}$  enthält  $\mathcal{T}_{>\beta} = \{\theta \in \Theta : lik(\theta) > \beta\} = \{\theta_1, \theta_2, \theta_3\}$
- damit ist  $\Phi_{LRM}(a_i) = \inf_{\theta \in \{\theta_1, \theta_2, \theta_3\}} u(a_i, \theta)$  für  $i \in \{1, 2\}$ , d.h.

$$\Phi_{LRM}(a_1) = \inf\{u(a_1, \theta_1), u(a_1, \theta_2), u(a_1, \theta_3)\} = -15\,000 \quad \text{und}$$

$$\Phi_{LRM}(a_2) = \inf\{u(a_2, \theta_1), u(a_2, \theta_2), u(a_2, \theta_3)\} = 0$$

- also ergibt sich als LRM-Aktion  $a^* = a_2$

## LRM-Aktionen im Investitionsproblem bei $X = x_2$

- für  $X = x_2$  ist  $lik(\theta_1) = \frac{3}{4}$  und  $lik(\theta_2) = lik(\theta_3) = 1$
- für  $\beta \in \{0.15, 0.26, 0.5\}$  enthält  $\mathcal{T}_{>\beta} = \{\theta \in \Theta : lik(\theta) > \beta\} = \{\theta_1, \theta_2, \theta_3\}$
- damit ist  $\Phi_{LRM}(a_i) = \inf_{\theta \in \{\theta_1, \theta_2, \theta_3\}} u(a_i, \theta)$  für  $i \in \{1, 2\}$ , d.h.

$$\Phi_{LRM}(a_1) = \inf\{u(a_1, \theta_1), u(a_1, \theta_2), u(a_1, \theta_3)\} = -15\,000 \quad \text{und}$$

$$\Phi_{LRM}(a_2) = \inf\{u(a_2, \theta_1), u(a_2, \theta_2), u(a_2, \theta_3)\} = 0$$

- also ergibt sich als LRM-Aktion  $a^* = a_2$
- wählt man z.B.  $\beta = 0.8$ , enthält  $\mathcal{T}_{>\beta} = \{\theta \in \Theta : lik(\theta) > \beta\} = \{\theta_2, \theta_3\}$

## LRM-Aktionen im Investitionsproblem bei $X = x_2$

- für  $X = x_2$  ist  $lik(\theta_1) = \frac{3}{4}$  und  $lik(\theta_2) = lik(\theta_3) = 1$
- für  $\beta \in \{0.15, 0.26, 0.5\}$  enthält  $\mathcal{T}_{>\beta} = \{\theta \in \Theta : lik(\theta) > \beta\} = \{\theta_1, \theta_2, \theta_3\}$
- damit ist  $\Phi_{LRM}(a_i) = \inf_{\theta \in \{\theta_1, \theta_2, \theta_3\}} u(a_i, \theta)$  für  $i \in \{1, 2\}$ , d.h.

$$\Phi_{LRM}(a_1) = \inf\{u(a_1, \theta_1), u(a_1, \theta_2), u(a_1, \theta_3)\} = -15\,000 \quad \text{und}$$

$$\Phi_{LRM}(a_2) = \inf\{u(a_2, \theta_1), u(a_2, \theta_2), u(a_2, \theta_3)\} = 0$$

- also ergibt sich als LRM-Aktion  $a^* = a_2$
- wählt man z.B.  $\beta = 0.8$ , enthält  $\mathcal{T}_{>\beta} = \{\theta \in \Theta : lik(\theta) > \beta\} = \{\theta_2, \theta_3\}$
- damit ist  $\Phi_{LRM}(a_i) = \inf_{\theta \in \{\theta_2, \theta_3\}} u(a_i, \theta)$  für  $i \in \{1, 2\}$ , d.h.

$$\Phi_{LRM}(a_1) = \inf\{u(a_1, \theta_2), u(a_1, \theta_3)\} = -15\,000 \quad \text{und} \quad \Phi_{LRM}(a_2) = 0$$

- als LRM-Aktion ergibt sich wieder  $a^* = a_2$

## 2.7 Likelihood-basiertes Entscheiden als konditionales, datenbasiertes Entscheiden

### 2.7.1 Grundlagen zu Likelihood-Funktionen

### 2.7.2 Likelihood-basiertes Entscheiden

### 2.7.3 **Statistische Schätzprobleme im Kontext der Likelihood-basierten Entscheidungstheorie**



# Lösung eines Schätzproblems mithilfe von *lik*

- statistisches Schätzproblem ist datengestütztes Entscheidungsproblem in Verlustform

$$((\mathbb{A}, \Theta, l(\cdot)), (\mathcal{X}, \sigma(\mathcal{X}), (P_\theta)_{\theta \in \Theta})) ,$$

wobei  $\mathbb{A} = \Theta$  und  $\mathcal{X} \subset \mathbb{R}^n$  sowie häufig

$$l : \mathbb{A} \times \Theta \rightarrow \mathbb{R}_{\geq 0} , \quad (a, \theta) \mapsto l(a, \theta) = (a - \theta)^2$$

# Lösung eines Schätzproblems mithilfe von *lik*

- statistisches Schätzproblem ist datengestütztes Entscheidungsproblem in Verlustform

$$((\mathbb{A}, \Theta, l(\cdot)), (\mathcal{X}, \sigma(\mathcal{X}), (P_\theta)_{\theta \in \Theta})) ,$$

wobei  $\mathbb{A} = \Theta$  und  $\mathcal{X} \subset \mathbb{R}^n$  sowie häufig

$$l : \mathbb{A} \times \Theta \rightarrow \mathbb{R}_{\geq 0} , \quad (a, \theta) \mapsto l(a, \theta) = (a - \theta)^2$$

- die beobachtete Realisierung  $X = x$  induziert (normierte) Likelihood-Funktion  $lik : \Theta \rightarrow [0, 1]$

# Lösung eines Schätzproblems mithilfe von *lik*

- statistisches Schätzproblem ist datengestütztes Entscheidungsproblem in Verlustform

$$((\mathbb{A}, \Theta, l(\cdot)), (\mathcal{X}, \sigma(\mathcal{X}), (P_\theta)_{\theta \in \Theta})) ,$$

wobei  $\mathbb{A} = \Theta$  und  $\mathcal{X} \subset \mathbb{R}^n$  sowie häufig

$$l : \mathbb{A} \times \Theta \rightarrow \mathbb{R}_{\geq 0} , \quad (a, \theta) \mapsto l(a, \theta) = (a - \theta)^2$$

- die beobachtete Realisierung  $X = x$  induziert (normierte) Likelihood-Funktion  $lik : \Theta \rightarrow [0, 1]$
- ML-Entscheidungskriterium  $\Phi_{ML}(a) = l(a, \hat{\theta})$  für  $\hat{\theta}$  ML-Schätzer von  $\theta$

$$\inf_{a \in \mathbb{A}} \Phi_{ML}(a) = \inf_{a \in \mathbb{A}} l(a, \hat{\theta}) = 0 \quad \text{für } a = \hat{\theta}$$

# Lösung eines Schätzproblems mithilfe von *lik*

- statistisches Schätzproblem ist datengestütztes Entscheidungsproblem in Verlustform

$$((\mathbb{A}, \Theta, l(\cdot)), (\mathcal{X}, \sigma(\mathcal{X}), (P_\theta)_{\theta \in \Theta})) ,$$

wobei  $\mathbb{A} = \Theta$  und  $\mathcal{X} \subset \mathbb{R}^n$  sowie häufig

$$l : \mathbb{A} \times \Theta \rightarrow \mathbb{R}_{\geq 0} , \quad (a, \theta) \mapsto l(a, \theta) = (a - \theta)^2$$

- die beobachtete Realisierung  $X = x$  induziert (normierte) Likelihood-Funktion  $lik : \Theta \rightarrow [0, 1]$
- ML-Entscheidungskriterium  $\Phi_{ML}(a) = l(a, \hat{\theta})$  für  $\hat{\theta}$  ML-Schätzer von  $\theta$

$$\inf_{a \in \mathbb{A}} \Phi_{ML}(a) = \inf_{a \in \mathbb{A}} l(a, \hat{\theta}) = 0 \quad \text{für } a = \hat{\theta}$$

- ML-Aktion  $a^* = \hat{\theta}$

# Lösung eines Schätzproblems mithilfe von *lik*

- statistisches Schätzproblem ist datengestütztes Entscheidungsproblem in Verlustform

$$((\mathbb{A}, \Theta, l(\cdot)), (\mathcal{X}, \sigma(\mathcal{X}), (P_\theta)_{\theta \in \Theta})) ,$$

wobei  $\mathbb{A} = \Theta$  und  $\mathcal{X} \subset \mathbb{R}^n$  sowie häufig

$$l : \mathbb{A} \times \Theta \rightarrow \mathbb{R}_{\geq 0} , \quad (a, \theta) \mapsto l(a, \theta) = (a - \theta)^2$$

- die beobachtete Realisierung  $X = x$  induziert (normierte) Likelihood-Funktion  $lik : \Theta \rightarrow [0, 1]$
- ML-Entscheidungskriterium  $\Phi_{ML}(a) = l(a, \hat{\theta})$  für  $\hat{\theta}$  ML-Schätzer von  $\theta$

$$\inf_{a \in \mathbb{A}} \Phi_{ML}(a) = \inf_{a \in \mathbb{A}} l(a, \hat{\theta}) = 0 \quad \text{für } a = \hat{\theta}$$

- ML-Aktion  $a^* = \hat{\theta}$
- LRM-Entscheidungskriterium für ein  $\beta \in (0, 1)$

$$\Phi_{LRM}(a) = \sup \mathcal{L}_{a, > \beta} \quad \text{mit} \quad \mathcal{L}_{a, > \beta} = \{k \in \mathbb{R}_{\geq 0} : lik_a(k) > \beta\}$$


## Beispiel 2 – ML-Schätzung von $\sigma^2$

- sei  $X = (X_1, \dots, X_n)$  mit  $X_i \sim \mathcal{N}(0, \sigma^2)$  für alle  $i \in \{1, \dots, n\}$
- Schätzung von  $\sigma^2$ , d.h.  $\mathbb{A} = \Theta = \mathbb{R}_{>0}$  mit quadratischem Verlust

## Beispiel 2 – ML-Schätzung von $\sigma^2$

- sei  $X = (X_1, \dots, X_n)$  mit  $X_i \sim \mathcal{N}(0, \sigma^2)$  für alle  $i \in \{1, \dots, n\}$
- Schätzung von  $\sigma^2$ , d.h.  $\mathbb{A} = \Theta = \mathbb{R}_{>0}$  mit quadratischem Verlust
- gegeben eine Realisierung  $X = x$  mit  $n = n_2 = 50$  Beobachtungen ergibt sich

$$a^* = \hat{\theta} = \arg \max_{\theta \in \Theta} \text{lik}(\theta)$$



normierte Likelihood-Funktion  $\text{lik}(\sigma^2)$  für  $n_2 = 50$  mit ML-Schätzung

# Schlussbemerkungen

- die Likelihood-basierte Entscheidungstheorie bietet eine Alternative zur Bayes-Entscheidungstheorie für konditionales, datenbasiertes Entscheiden



# Schlussbemerkungen

- die Likelihood-basierte Entscheidungstheorie bietet eine Alternative zur Bayes-Entscheidungstheorie für konditionales, datenbasiertes Entscheiden
- dabei bildet die gesamte Likelihood-Funktion die Grundlage für verschiedene Likelihood-basierte Entscheidungskriterien

# Schlussbemerkungen

- die Likelihood-basierte Entscheidungstheorie bietet eine Alternative zur Bayes-Entscheidungstheorie für konditionales, datenbasiertes Entscheiden
- dabei bildet die gesamte Likelihood-Funktion die Grundlage für verschiedene Likelihood-basierte Entscheidungskriterien
- Pre-Data-Eigenschaften von ML-Schätzern können im Rahmen der klassischen statistischen Entscheidungstheorie untersucht werden

# Schlussbemerkungen

- die Likelihood-basierte Entscheidungstheorie bietet eine Alternative zur Bayes-Entscheidungstheorie für konditionales, datenbasiertes Entscheiden
- dabei bildet die gesamte Likelihood-Funktion die Grundlage für verschiedene Likelihood-basierte Entscheidungskriterien
- Pre-Data-Eigenschaften von ML-Schätzern können im Rahmen der klassischen statistischen Entscheidungstheorie untersucht werden
- für eine vertiefte Betrachtung der Likelihood-basierten statistischen Entscheidungstheorie siehe Cattaneo (2013, 2007)
- eine Anwendung auf das Problem der Regression mit unscharfen Beobachtungen findet sich in komprimierter Form in Cattaneo and Wiencierz (2012) und ausführlicher in Wiencierz (2013)

# Literaturverzeichnis

- Casella, G. and R. Berger (2002). *Statistical Inference* (2nd ed.). Duxbury.
- Cattaneo, M. (2007). *Statistical Decisions Based Directly on the Likelihood Function*. Ph. D. thesis, ETH Zurich.
- Cattaneo, M. (2013). Likelihood decision functions. *Electronic Journal of Statistics* 7, 2924–2946.
- Cattaneo, M. and A. Wiencierz (2012). Likelihood-based Imprecise Regression. *International Journal of Approximate Reasoning* 53, 1137–1154.
- Rüger, B. (1999). *Test und Schätztheorie*. Oldenbourg.
- Wiencierz, A. (2013). *Regression analysis with imprecise data*. Ph. D. thesis, LMU Munich.