

Bayesian updating

Frage: wie lassen sich die neuen Informationen in den Entscheidungsprozess integrieren?

Θ - states / Zustände D - decisions / Entscheidungen

$U: \Theta \times D \rightarrow \mathbb{R}$ - Nutzenfunktion gegeben

$\theta \in \Theta, d \in D$
 \uparrow Zustand der Natur \uparrow Entscheidung des Subjekts

Annahme: • $\pi: \Theta \rightarrow \mathbb{R}_+$
 \uparrow prior gegeben Wahrscheinlichkeitsdichte auf Zuständen, d.h. $\int_A \pi(\theta) d\theta$ \downarrow Wahrscheinlichkeitsmaß auf Θ .

$\delta \in \arg \max_{d \in D} \int_{\Theta} U(\theta, d) \cdot \pi(\theta) d\theta$ "Maximierung des erwarteten Nutzens"

• X - Erfahrungen / Observations

Bayes estimator

$\delta(x) \in \arg \max_{d \in D} \int_{\Theta} U(\theta, d) \cdot \pi(\theta|x) d\theta$
 Bayes decision rule
 $\delta: X \rightarrow D$

\uparrow posterior Wahrscheinlichkeitsdichte auf Zuständen gegeben Erfahrung x

Bayes formel:

Diskret: $P(A|E) = \frac{P(E|A) \cdot P(A)}{P(E)}$
 posterior likelihood prior evidence

Stetig: $\pi(\theta|x) = \frac{f(x|\theta) \cdot \pi(\theta)}{\int_{\Theta} f(x|\theta) \cdot \pi(\theta) d\theta}$
 \leftarrow W'dichte der Erfahrung x gegeben Zustand θ
 \leftarrow W'dichte der Erfahrung x
 \uparrow $m(x)$

Utilities

$$p(d, x) := \int_{\Theta} u(\theta, d) \cdot \pi(\theta|x) d\theta$$

posterior expected utility
for $d \in D, x \in X$

$$R(\theta, \delta) := \int_X u(\theta, \delta(x)) \cdot f(x|\theta) dx$$

frequentist utility
for $\theta \in \Theta, \delta: X \rightarrow D$

$$r(\delta) := E_{\theta}[R(\theta, \delta)] = \int_{\Theta} \left[\int_X u(\theta, \delta(x)) f(x|\theta) dx \right] \pi(\theta) d\theta$$

"average utility from δ
gegeben state θ "
integrated utility

Fubini
$$\int_X \left[\int_{\Theta} u(\theta, \delta(x)) \underbrace{f(x|\theta) \cdot \pi(\theta)}_{\substack{= \pi(\theta|x) \cdot m(x) \\ \text{Bayes}}} d\theta \right] dx =$$

$$= \int_X \left[\int_{\Theta} u(\theta, \delta(x)) \cdot \pi(\theta|x) d\theta \right] m(x) dx$$

$= p(\delta(x), x)$

$$\Rightarrow r(\delta) = \int p(\delta(x), x) \cdot m(x) dx$$

Also:
$$\delta(x) \in \underset{\delta: X \rightarrow D}{\text{argmax}} r(\delta)$$


Bayes estimator
den integrierten
Nutzen

Interpretation von Bayes estimator

Entscheidung:	$d_1 \rightarrow$	Spielen	Ansatz	Gewinn	\leftarrow unbekannte Gewinnwahrscheinlichkeit
	$d_2 \rightarrow$	"Wurf %" auf z.B. 0	K_1 K_2	$K_1 \cdot \theta$ $K_2 \cdot \theta$	

$$u(\theta, d_1) = K_1 \cdot \theta - k_1, \quad u(\theta, d_2) = K_2 \cdot \theta - k_2$$

erwarteter
Nutzen



Prior: $\pi(\theta) = \mathbb{1}_{[0,1]}(\theta)$, d.h. $P(\theta \leq \theta) = \int_{-\infty}^{\theta} \mathbb{1}_{[0,1]}(\theta) d\theta = \theta$

$$\int_{\Theta} \underbrace{u(\theta, d_i) \cdot \pi(\theta)}_{\text{expected utility}} d\theta = \int_0^1 (K_i \cdot \theta - k_i) d\theta = K_i \cdot \frac{\theta^2}{2} - k_i \cdot \theta \Big|_0^1 = \frac{K_i}{2} - k_i$$

$$d_1 > d_2 \Leftrightarrow \frac{K_1}{2} - k_1 > \frac{K_2}{2} - k_2$$

Entscheidungskriterium, vgl. $E(K_i \cdot \theta - k_i) = K_i \cdot E(\theta) - k_i = K_i \cdot \frac{1}{2} - k_i$

Erfahrung: $f(x|\theta) \sim \text{Bin}(n, \theta)$ - Binomialverteilung mit n -Versuchen und Gewinnwahrscheinlichkeit θ .

d.h. $P(X=x|\theta=\theta) = \binom{n}{x} \theta^x (1-\theta)^{n-x}$
 Anzahl von "0"-Werten im Versuch

$$m(x) = \int_0^1 f(x|\theta) \cdot \pi(\theta) d\theta = \int_0^1 \binom{n}{x} \theta^x (1-\theta)^{n-x} d\theta = \binom{n}{x} B(x+1, n-x+1)$$

$P(X=x)$

$$B(a, b) = \int_0^1 t^{a-1} \cdot (1-t)^{b-1} dt = \frac{\Gamma(a) \cdot \Gamma(b)}{\Gamma(a+b)}, \quad \Gamma(n) = (n-1)! \quad \text{Gamma-Funktion}$$

Beta-Funktion

Posterior $\pi(\theta|x) = \frac{f(x|\theta) \cdot \pi(\theta)}{\int_0^1 f(x|\theta) \pi(\theta) d\theta} = \frac{\binom{n}{x} \theta^x (1-\theta)^{n-x}}{\binom{n}{x} B(x+1, n-x+1)} \mathbb{1}_{[0,1]}(\theta)$

posterior expected utility $g(d_i, x) = \int_0^1 U(\theta, d_i) \cdot \pi(\theta|x) d\theta = \int_0^1 (K_i \cdot \theta - K_i) \cdot \frac{\theta^x (1-\theta)^{n-x}}{B(x+1, n-x+1)} d\theta =$

s.o. $= \frac{K_i}{B(x+1, n-x+1)} \cdot \int_0^1 \theta^{x+1} (1-\theta)^{n-x} d\theta - K_i = K_i \cdot \frac{B(x+2, n-x+1)}{B(x+1, n-x+1)} - K_i$

$$= \left[\frac{\Gamma(x+2) \cdot \Gamma(n-x+1)}{\Gamma(n+3)} \cdot \frac{\Gamma(n+2)}{\Gamma(x+1) \Gamma(n-x+1)} = \frac{(x+1)! \cdot (n+1)!}{(n+2)! \cdot x!} = \frac{x+1}{n+2} \right] =$$

$$= K_i \cdot \frac{x+1}{n+2} - K_i$$

$\Rightarrow \delta(x) = \begin{cases} d_1, & \text{falls } K_1 \frac{x+1}{n+2} - K_1 > K_2 \frac{x+1}{n+2} - K_2 \\ d_2, & \text{sonst} \end{cases}$
 Bayes decision

o.B.d.A. $\frac{K_1}{2} - K_1 > \frac{K_2}{2} - K_2 \Rightarrow d_1$ - optimal

$\Leftrightarrow K_1 - K_2 > 2(K_1 - K_2) \Rightarrow K_1 - K_2 > \frac{n+2}{x+1} (K_1 - K_2) \Rightarrow \delta(x) = d_1$
 $x \geq \frac{n}{2}$ - gerade für $x \geq \frac{n}{2}$

z.B. $K_1 = 10, K_1 = 3; K_2 = 6, K_2 = 2$.

$\frac{10}{2} - 3 = 2 > \frac{6}{2} - 2 = 1 \Rightarrow d_1$ - optimal

$K_1 \frac{x+1}{n+2} - K_1 > K_2 \frac{x+1}{n+2} - K_2 \Leftrightarrow 10 \cdot \frac{x+1}{n+2} - 3 > 6 \cdot \frac{x+1}{n+2} - 2 \Leftrightarrow \begin{cases} x \geq \frac{n-2}{4} : \delta(x) = d_1 \\ x < \frac{n-2}{4} : \delta(x) = d_2 \end{cases}$



Minimax

$$\delta_0 \text{ easy } \max_{\delta: X \rightarrow D} \inf_{\theta \in \Theta} R(\theta, \delta) = \int_X u(\theta, \delta(x)) \cdot f(x|\theta) dx$$

frequentist utility

minimax risk/estimator

worst-case

Zusammenhang mit Bayes estimator:

$$r(\delta) = \mathbb{E}_\theta [R(\theta, \delta)] \geq \mathbb{E}_\theta \left[\inf_{\theta \in \Theta} R(\theta, \delta) \right] = \inf_{\theta \in \Theta} R(\theta, \delta)$$

$$\Rightarrow \max_{\delta: X \rightarrow D} r(\delta) \geq \max_{\delta: X \rightarrow D} \inf_{\theta \in \Theta} R(\theta, \delta)$$

Nutzen des Bayes estimator

Nutzen des minimax estimator

"pessimistischer Ansatz"

Admissibility

$\delta_0: X \rightarrow D$ heißt admissible estimator, falls kein $\delta_1: X \rightarrow D$ existiert mit $R(\theta, \delta_1) \geq R(\theta, \delta_0) \forall \theta$ und $R(\theta_0, \delta_1) > R(\theta_0, \delta_0)$ für mindestens ein $\theta_0 \in \Theta$.

" δ_1 dominiert δ_0 "

Falls $\pi(\theta) > 0 \forall \theta \in \Theta$, dann ist Bayes estimator $\delta: X \rightarrow D$ und $R(\cdot, \delta)$ stetig admissible.

Ansonsten $\exists \delta_1: X \rightarrow D$ mit $R(\theta, \delta_1) \geq R(\theta, \delta) \forall \theta$ und $R(\theta_0, \delta_1) > R(\theta_0, \delta)$ für $\theta_0 \in \Theta$.

R-stetig $\Leftrightarrow R(\theta, \delta_1) > R(\theta, \delta) \forall \theta \in C \subseteq \Theta$
↑
offen

Also: $r(\delta_1) = \mathbb{E}_\theta [R(\theta, \delta_1)] \geq \mathbb{E}_\theta [R(\theta, \delta)]$

$$= \int_{\Theta} \underbrace{R(\theta, \delta)}_{< R(\theta, \delta_1) \text{ auf } C} \underbrace{\pi(\theta)}_{> 0} d\theta$$

$$= \max_{\delta: X \rightarrow D} r(\delta) \quad \Leftarrow$$