

Zu Aufgabe 12:

Bayeskriterien in Regrettafeln

Bayes-Entscheidungen hingegen werden durch den Übergang zu Regret nicht beeinflusst.

Bayes-Aktionen:

$$\sum_{j=1}^m u(a_i, \vartheta_j) \pi(\{\vartheta_j\}) \longrightarrow \max_{i=1, \dots, n}$$

Übergang zu Regret:

$$\begin{aligned} & \sum_{j=1}^m r(a_i, \vartheta_j) \pi(\{\vartheta_j\}) \longrightarrow \min_{i=1, \dots, n} \quad (\text{da Verlusttafel}) \\ \iff & \sum_{j=1}^m \left(\max_{\ell=1, \dots, n} u(a_\ell, \vartheta_j) - u(a_i, \vartheta_j) \right) \pi(\{\vartheta_j\}) \longrightarrow \min_{i=1, \dots, n} \\ \iff & \sum_{j=1}^m \max_{\ell=1, \dots, n} u(a_\ell, \vartheta_j) \pi(\{\vartheta_j\}) - \sum_{j=1}^m u(a_i, \vartheta_j) \pi(\{\vartheta_j\}) \longrightarrow \min_{i=1, \dots, n} \\ \iff & (\text{Konst. unabh. von } a_i) - \sum_{j=1}^m u(a_i, \vartheta_j) \pi(\{\vartheta_j\}) \longrightarrow \min_{i=1, \dots, n} \\ \iff & \sum_{j=1}^m u(a_i, \vartheta_j) \pi(\{\vartheta_j\}) \longrightarrow \max_{i=1, \dots, n} \end{aligned}$$

d.h. a^* „Bayes-Regret“-Aktion zu $\pi \iff a^*$ Bayes-Aktion zu π .

Zu Aufgabe 13:

\mathcal{M} besteht aus linearen Restriktionen, die sich aus der ordinalen Wahrscheinlichkeitsbewertung ergeben, z.B.

$$\pi(\{\vartheta_{j_1}\}) \geq \pi(\{\vartheta_{j_2}\}) \iff 0 \leq \pi(\{\vartheta_{j_1}\}) - \pi(\{\vartheta_{j_2}\}),$$

und den trivialen Bedingungen:

$$0 \leq \pi(\{\vartheta_j\}) \leq 1,$$

$$\pi(\{\vartheta_1\}) + \pi(\{\vartheta_2\}) + \pi(\{\vartheta_3\}) = 1,$$

also ist \mathcal{M} in der Tat ein konvexes Polyeder.

Berechnet man die Extrempunktmenge $\mathcal{E}(\mathcal{M})$, so ergibt sich (siehe z.B. E. Kofler: Prognosen und Stabilität bei unvollständiger Information. Campus (Frankfurt; New York), 1989, p. 26)

$$\mathcal{E}(\mathcal{M}) = \left\{ \begin{pmatrix} 1 \\ 0 \\ 0 \end{pmatrix}, \begin{pmatrix} \frac{1}{2} \\ \frac{1}{2} \\ 0 \end{pmatrix}, \begin{pmatrix} \frac{1}{3} \\ \frac{1}{3} \\ \frac{1}{3} \end{pmatrix} \right\}.$$

Damit ist bei a_1

$$\begin{aligned} \underline{\mathbb{E}}_{\mathcal{M}}(u(a_1)) &= \inf_{\pi \in \mathcal{M}} \mathbb{E}_{\pi}(u(a_1)) = \min_{\pi \in \mathcal{E}(\mathcal{M})} \left(\sum_{j=1}^m u(a_1, \vartheta_j) \pi(\{\vartheta_j\}) \right) \\ &= \min \left(10000 \cdot 1 + 0; 10000 \cdot \frac{1}{2} + 2000 \cdot \frac{1}{2} + 0; \frac{1}{3}(10000 + 20000 - 15000) \right) \\ &= \min(10000; 6000; -1000) = -1000. \end{aligned}$$

und für a_2

$$\begin{aligned} \underline{\mathbb{E}}_{\mathcal{M}}(u(a_2)) &= \inf_{\pi \in \mathcal{M}} \mathbb{E}_{\pi}(u(a_2)) = \min_{\pi \in \mathcal{E}(\mathcal{M})} \left(\sum_{j=1}^m u(a_2, \vartheta_j) \pi(\{\vartheta_j\}) \right) \\ &= \min \left(1000 \cdot 1; 1000 \cdot \frac{1}{2} + 1000 \cdot \frac{1}{2}; \frac{1}{3}(1000 + 1000 + 0) \right) \\ &= \frac{2000}{3} \end{aligned}$$

$$\underline{\mathbb{E}}_{\mathcal{M}}(u(a_1)) = \min_{\pi \in \mathcal{E}(\mathcal{M})} \mathbb{E}_{\pi}(u(a_1)) < \min_{\pi \in \mathcal{E}(\mathcal{M})} \mathbb{E}_{\pi}(u(a_2)) = \underline{\mathbb{E}}_{\mathcal{M}}(u(a_2)).$$

Also ist a_2 Max E Min-Aktion.

Zu Aufgabe 14:

a)

$$X_i \sim N(\mu, \sigma^2) \quad \vec{X} = (X_1, \dots, X_n)$$

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

1. $f(x|\mu)$ in Form $f(x|\mu) \propto h(\mu) \exp(T(x) \cdot b(\mu))$ bringen

$$f(x|\mu) \propto \underbrace{\exp\left(-\frac{\mu^2 n}{2\sigma^2}\right)}_{h(\mu)} \cdot \underbrace{\exp\left(\frac{n\mu\bar{x}}{\sigma^2}\right)}_{\exp(T(x) \cdot b(\mu))}$$

2. Priori der Form $[h(\mu)]^\alpha \exp(b(\mu) \cdot \beta)$ wählen

$$\pi(\mu) \propto \underbrace{\exp\left(-\alpha \frac{\mu^2 n}{2\sigma^2}\right)}_{[h(\mu)]^\alpha} \cdot \underbrace{\exp\left(\frac{\mu}{\sigma^2} \beta\right)}_{\exp(b(\mu)\beta)}$$

Dies ist die zu $X_i \sim N(\mu, \sigma^2)$, σ^2 bekannt, konjugierte Priori.

Probe: Bestimme Posteriori.

$$\begin{aligned} \pi(\mu|x) &\propto h(\mu) \cdot \exp(T(x) \cdot b(\mu)) \cdot [h(\mu)]^\alpha \cdot \exp(b(\mu) \cdot \beta) \\ &= [h(\mu)]^{\alpha+1} \cdot \exp(b(\mu) \cdot (T(x) + \beta)) \end{aligned}$$

Dieses Ergebnis entspricht tatsächlich der Form 3.13 und führt genau auf eine Normalverteilung, wie man anhand des folgenden Ansatzes erkennt:

$$\begin{aligned} \pi(\mu) &\propto \exp\left(-\alpha \frac{\mu^2 n}{2\sigma^2}\right) \cdot \exp\left(\frac{\mu}{\sigma^2} \beta\right) = \exp(-\alpha^* \cdot \mu^2) \cdot \exp(\beta^* \mu) \\ \pi(\mu) &= \frac{1}{\sqrt{2\pi}\rho} \cdot \exp\left(-\frac{1}{2\rho^2}(\mu - \nu)^2\right) = \\ &\propto \exp\left(-\frac{\mu^2}{2\rho^2} + \frac{2\nu\mu}{2\rho^2} - \frac{n\nu^2}{2\rho^2}\right) = \\ &\propto \exp\left(\underbrace{\frac{\nu}{\rho^2}}_{\beta^*} \cdot \mu - \underbrace{\frac{1}{2\rho^2}}_{\alpha^*} \cdot \mu^2\right) \end{aligned}$$

b) $X \sim \text{Binomial}(n, p)$

$$\begin{aligned}
 f(x|p) &\propto (1-p)^n \cdot \exp\left(\ln \frac{p}{1-p}\right) \\
 \pi(p) &\propto (1-p)^{\alpha \cdot n} \cdot \exp\left(\beta \cdot \ln \frac{p}{1-p}\right) = \\
 &= (1-p)^{\alpha'} \cdot \left(\frac{p}{1-p}\right)^\beta = (1-p)^{\alpha'-\beta} \cdot p^\beta : \quad \text{Betaverteilung}
 \end{aligned}$$

c) (X_1, \dots, X_n) i.i.d. Poisson-verteilt

$$\begin{aligned}
 f(\vec{x}|\vartheta) &= \prod_{i=1}^n f(x_i|\vartheta) = \prod_{i=1}^n \frac{\lambda^{x_i}}{x_i!} \cdot \exp(-\lambda) = \\
 &= \frac{\lambda^{\sum_{i=1}^n x_i}}{x_1! x_2! \dots x_n!} \cdot \exp(-n\lambda) \\
 &\propto \exp(-n\lambda) \exp\left(\sum_{i=1}^n x_i \ln \lambda\right) \\
 \pi(\lambda) &\propto \exp(-(n\lambda) \cdot \alpha) \cdot \exp(\beta \ln \lambda) = \\
 &= \lambda^\beta \cdot \exp(-\alpha' \lambda) : \quad \text{Gammaverteilung}
 \end{aligned}$$

Zu Aufgabe 15:

zu a)

$$\hat{\mu} = \frac{\bar{x}\rho^2 + \nu \cdot \frac{\sigma^2}{n}}{\rho^2 + \frac{\sigma^2}{n}} = \bar{x} \cdot \frac{\rho^2}{\rho^2 + \frac{\sigma^2}{n}} + \nu \cdot \frac{\frac{\sigma^2}{n}}{\rho^2 + \frac{\sigma^2}{n}}$$

zu b) Ceteris paribus Betrachtung

- $\rho^2 \rightarrow \infty; \sigma^2, n$ fest

$$\hat{\mu} = \bar{x} \cdot \underbrace{\frac{\rho^2}{\rho^2 + \frac{\sigma^2}{n}}}_{\rightarrow 1} + \nu \cdot \underbrace{\frac{\frac{\sigma^2}{n}}{\rho^2 + \frac{\sigma^2}{n}}}_{\rightarrow 0} \rightarrow \bar{x} \text{ ggf. durch } \rho^2 \text{ teilen}$$

$$\rho^2 = \frac{\rho^2 \cdot \frac{\sigma^2}{n}}{\rho^2 + \frac{\sigma^2}{n}} = \frac{\frac{\sigma^2}{n}}{1 + \frac{\sigma^2}{\rho^2 \cdot n}} \quad \rho^2 \rightarrow \infty : \frac{\sigma^2}{n} \text{ wie ML}$$

ρ^2 große Streuung Priori (heißt geringes Vorwissen)

Stichprobe bekommt großes Gewicht

- $\sigma^2 \rightarrow \infty; \rho^2, n$ fest

$$\hat{\mu} = \bar{x} \cdot \underbrace{\frac{\rho^2}{\rho^2 + \frac{\sigma^2}{n}}}_{\rightarrow 0} + \nu \cdot \underbrace{\frac{\frac{\sigma^2}{n}}{\rho^2 + \frac{\sigma^2}{n}}}_{\rightarrow 1} \rightarrow \nu$$

σ^2 sehr groß

Stichprobe sehr stark streuend

\Rightarrow man bleibt bei Priori-Wissen,

da man schlecht dazulernen kann

- $n \rightarrow \infty; \sigma^2, \rho^2$ fest

$$\hat{\mu} = \bar{x} \cdot \underbrace{\frac{\rho^2}{\rho^2 + \frac{\sigma^2}{n}}}_{\rightarrow 1} + \nu \underbrace{\frac{\frac{\sigma^2}{n}}{\rho^2 + \frac{\sigma^2}{n}}}_{\rightarrow 0} \rightarrow \bar{x}$$

bei sehr großen Stichproben überwiegen
die Beobachtungen völlig;
Priori Ausgangspunkt spielt keine Rolle mehr
Dieser Aspekt wird später verallgemeinert:
(„asymptotische“ Objektivität)

zu c) Weiterführende Bemerkung:

Konvexkombination zwischen Stichprobenmittel und Priori-Mittelwert bringt
auch ein „Verwaschen“ potentieller widersprüchlicher Information!

Sei

$$\varrho^2 = \frac{\sigma^2}{n}$$

so ist

$$\hat{\mu} = \nu' = \frac{\bar{x} + \nu}{2}$$

und

$$\varrho^{2'} = \frac{\varrho^4}{2\varrho^2} = \frac{\varrho^2}{2}$$

.

Beispielsweise

$$\bar{x} = 0.9 \text{ und } \nu = 1.1$$

führen genau auf dieselbe Posteriori wie

$$\bar{x} = -100 \text{ und } \nu = 102.$$

(massiver Priori-Datenkonflikt!) Eigentlich würde man im zweiten Fall viel
„unsicherer“ sein wollen als im ersten. Starkes Argument für Intervallwahr-
scheinlichkeit \rightarrow aktuelle Forschung (Gero Walter).

Zu Aufgabe 16:

Hat man bereits das Auswertungsproblem bestimmt, so ergibt sich die Laplace-optimal Aktion über die zeilenweise gebildeten Mittelwerte.

$$\text{Notation: } d(1, 2, 2) = \begin{pmatrix} x_1 & x_2 & x_3 \\ a_1 & a_2 & a_2 \end{pmatrix}$$

Datengestütztes Entscheidungsproblem:

	ϑ_1	ϑ_2	ϑ_3	Minimum	Laplace
$d(1, 1, 1)$	10 000	2 000	- 15 000	- 15 000	- 1 000
$d(1, 1, 2)$	9 100	1 600	- 7 500	- 7 500	1 066 $\bar{6}$
$d(1, 2, 1)$	7 300	1 600	- 9 000	- 9 000	- 33 $\bar{3}$
$d(1, 2, 2)$	6 400	1 200	- 1 500	- 1 500	2 033 $\bar{3}$
$d(2, 1, 1)$	4 600	1 800	- 13 500	- 13 500	- 2 366 $\bar{6}$
$d(2, 1, 2)$	3 700	1 400	- 6 000	- 6 000	- 300
$d(2, 2, 1)$	1 900	1 400	- 7 500	- 7 500	- 1 400
$d(2, 2, 2)$	1 000	1 000	0	0	666 $\bar{6}$

Verwendet man den Hauptsatz, so ist für x_s , $s = 1, \dots, 3$, die Posteriori-Verteilung $\pi(\cdot|x_s)$ über $(\Theta, \mathcal{P}(\Theta))$ zu berechnen und dann das ursprüngliche datenfreie Entscheidungsproblem mit $\pi(\cdot|x_s)$ als aufdatierter Priori zu lösen.

$$\pi(\vartheta_j|x_s) = \frac{p(x_s|\vartheta_j) \cdot \pi(\{\vartheta_j\})}{p(x_s|\vartheta_1) \cdot \pi(\{\vartheta_1\}) + p(x_s|\vartheta_2) \cdot \pi(\{\vartheta_2\}) + p(x_s|\vartheta_3) \cdot \pi(\{\vartheta_3\})}$$

z.B.

$$\pi(\vartheta_1|x_1) = \frac{0.6 \cdot 1/3}{0.6 \cdot 1/3 + 0.2 \cdot 1/3 + 0.1 \cdot 1/3} = \frac{0.6}{0.9} = \frac{2}{3}$$

Wenn x_1 (positive Konjunkturprognose) beobachtet wird, dann steigt die Wahrscheinlichkeit, dass tatsächlich Konjunktur steigt, von $1/3$ auf $2/3$.

Damit

$$\begin{pmatrix} \pi(\vartheta_1|x_1) \\ \pi(\vartheta_2|x_1) \\ \pi(\vartheta_3|x_1) \end{pmatrix} = \begin{pmatrix} 2/3 \\ 2/9 \\ 1/9 \end{pmatrix}$$

$$\begin{pmatrix} \pi(\vartheta_1|x_2) \\ \pi(\vartheta_2|x_2) \\ \pi(\vartheta_3|x_2) \end{pmatrix} = \begin{pmatrix} 3/11 \\ 4/11 \\ 4/11 \end{pmatrix}$$

$$\begin{pmatrix} \pi(\vartheta_1|x_3) \\ \pi(\vartheta_2|x_3) \\ \pi(\vartheta_3|x_3) \end{pmatrix} = \begin{pmatrix} 0.1 \\ 0.4 \\ 0.5 \end{pmatrix}$$

Kontrolle: Posteriori- *Wahrscheinlichkeit*, Komponenten müssen sich zu 1 addieren.

	ϑ_1	ϑ_2	ϑ_3	$\begin{pmatrix} 2/3 \\ 2/9 \\ 1/9 \end{pmatrix}$	$\begin{pmatrix} 3/11 \\ 4/11 \\ 4/11 \end{pmatrix}$	$\begin{pmatrix} 0.1 \\ 0.4 \\ 0.5 \end{pmatrix}$
a_1	10000	2000	-15000	<u>5444</u>	-2000	-5700
a_2	1000	1000	0	889	<u>636</u>	<u>500</u>

(gerundete Werte)

damit ist

$$x_1 \quad a_1$$

bei x_2 die Aktion a_2 Posteriori-Nutzen-optimal.

$$x_3 \quad a_3$$

Als optimale Entscheidungsfunktion ergibt sich in der Tat

$$\begin{pmatrix} x_1 & x_2 & x_3 \\ a_1 & a_2 & a_2 \end{pmatrix} = d(1, 2, 2),$$

wie aus der Analyse des Priori-Gain.

Hier nur zur Illustration alle x_s „durchdekliniert“. In der Praxis reicht es, das konkret beobachtete x zu betrachten.