

Wykład 8

16 listopada 2012
00:23

Testowanie hipotez, Chernov, Sanov etc.

4. Testowanie Hipotez

4.1 Optymalne Bayesowskie testowanie hipotez

Obserwujemy realizację zmiennej losowej X .

Zostaniamy się czy punkci z realizacji

$p(x|H_i)$ (hipoteza H_i) $i=1, \dots, M$

- taka dyskretna estymacja.

Zbiór wartości zmiennej losowej X : \mathcal{X}

dużym \mathcal{X}_i uprawiedlamy

"funkcja decyzji"

$$h(x) = i \quad \text{dla } x \in \mathcal{X}_i$$

Jaka jest optymalna $h(x)$?

Przyjmijmy prawdopodobieństwa a priori:

$p(H_i)$, że wybierzemy zaktualizowaną hipotezę H_i

Niech C_{ij} koszt wybierzemy hipotezę H_i jeśli
prawdziwa była H_j .. M_p : $C_{ij} = 1 - \delta_{ij}$

Średni koszt dla danej funkcji decyzji:

$$C_h = \sum_j p(H_j) \int dx C_{h(x),j} p(x|H_j) =$$

$$= \int dx \sum_j C_{h(x),j} p(H_j|x) p(x)$$

Czyli powinniśmy wybrać :

$$h_B(x) = \arg \min_i \sum_j C_{ij} p(H_j | x)$$

optymalna Bayesowska funkcja decyzyjna :

$$p(H_j | x) = \frac{p(x | H_j) p(H_j)}{p(x)} = \frac{p(x | H_j) p(H_j)}{\sum_j p(x | H_j) p(H_j)}$$

Dla $C_{ij} = 1 - \delta_{ij}$ (Minimum Error Cost)

$$h_{ME}(x) = \arg \min_i p(H_i | x)$$

$$C_{ME} = 1 - \int dx \max_i \{ p(H_i | x) \} p(x)$$

wyberamy i dla którego prawdopodobieństwa a posteriori największe. równoważnie,

$$h_{ME}(x) = \arg \max_i p(x | H_i) p(H_i)$$

$$C_{ME} = 1 - \int dx \max_i (p(x | H_i) p(H_i)) =$$

Jeśli dodatkowo $p(H_i) = \frac{1}{M}$:

$$\arg \max_i p(H_i | x) = \arg \max_i \frac{p(x | H_i) \frac{1}{M}}{p(x)} =$$

$$= \arg \max_i p(x | H_i)$$

Czyli wybieramy H_i dla którego x największy prawdopodobieństwo: (Max-likelihood),

$$h_{ML}(x) = \arg \max_i p(x | H_i)$$

$$M = 2$$

$$\underbrace{p(H_i) \cdot p(x | H_i)} \quad p(x | H_i) \cdot p(H_i)$$

$$C_{ij} = 1 - \delta_{ij}$$



$$\begin{aligned}
 C_{ME} &= 1 - \int dx \min(p(x|H_0) | p(H_0), p(x|H_1) | p(H_1)) = \\
 &= 1 - \frac{1}{2} \left[\int dx (p(x|H_0)p(H_0) - p(x|H_1)p(H_1)) \right. \\
 &\quad \left. + \int dx p(x|H_0)p(H_0) + \int dx p(x|H_1)p(H_1) \right] = \\
 &= \frac{1}{2} \left[1 - \int dx (p(x|H_0)p(H_0) - p(x|H_1)p(H_1)) \right] \\
 &= \frac{1}{2} \left[1 - \|p_1 - p_2\| \right] \\
 &\quad \int \text{total variation measure between prob. distributions}
 \end{aligned}$$

Przykład:

$$X \stackrel{H_0}{\sim} N(\mu_0, \sigma_0^2)$$

$$p(H_0) = \pi_0$$

$$X \stackrel{H_1}{\sim} N(\mu_1, \sigma_1^2)$$

$$p(H_1) = \pi_1$$

$$C_{ij} = 1 - \delta_{ij}$$

$$p(x|H_i) = \left(\frac{1}{\sqrt{2\pi}\sigma_i} \right)^N e^{-\frac{(x-\mu_i)^2}{2\sigma_i^2}}$$

$$p(x) = \sum_i p(x|H_i) p(H_i) = \sum_{i=0}^1 \left(\frac{\pi_i}{\sqrt{2\pi}\sigma_i} \right)^N e^{-\frac{(x-\mu_i)^2}{2\sigma_i^2}} \quad \text{nie wie}$$

$$p(H_i|x) = \frac{\left(\frac{1}{\sqrt{2\pi}\sigma_i} \right)^N e^{-\frac{(x-\mu_i)^2}{2\sigma_i^2}} \cdot \pi_i}{p(x)}$$

Cc just wiecie $p(H_0|\bar{x})$ i $p(H_1|\bar{x})$?

$$\begin{aligned}
 \frac{p(H_0|\bar{x})}{p(H_1|\bar{x})} &= \frac{\pi_0}{\pi_1} \left(\frac{\sqrt{2\pi}\sigma_1}{\sqrt{2\pi}\sigma_0} \right)^N e^{-\frac{1}{2} \left[\bar{x}^2 \left(\frac{1}{\sigma_0^2} - \frac{1}{\sigma_1^2} \right) + (\bar{x}) \left(\frac{\mu_0}{\sigma_0^2} - \frac{\mu_1}{\sigma_1^2} \right) - \frac{N}{2} \left(\frac{\mu_0^2}{\sigma_0^2} - \frac{\mu_1^2}{\sigma_1^2} \right) \right]} \\
 &\quad - \frac{1}{2} \left[\bar{x}^2 \left(\frac{1}{\sigma_1^2} - \frac{1}{\sigma_0^2} \right) - 2\bar{x} \left(\frac{\mu_0}{\sigma_0^2} - \frac{\mu_1}{\sigma_1^2} \right) + \frac{\mu_0^2}{\sigma_0^2} - \frac{\mu_1^2}{\sigma_1^2} \right]
 \end{aligned}$$

$$= \frac{\pi_0}{\pi_1} \left(\frac{\sigma_1}{\sigma_0} \right) e^{-\frac{1}{2\sigma_0^2}(\mu_0 - \mu_1)x - \frac{1}{2\sigma_1^2}(\mu_1 - \mu_0)x} = \frac{\pi_0}{\pi_1} e^{-\frac{(\mu_0^2 - \mu_1^2)}{2\sigma^2}x}$$

Jeśli ≥ 1 wybieramy H_0 , jeśli < 1 wybieramy H_1


• Jeśli $\sigma_1 = \sigma_0$:

$$\frac{\pi_0}{\pi_1} e^{-\frac{1}{\sigma^2}(\mu_0 - \mu_1)x - \frac{(\mu_0^2 - \mu_1^2)}{2\sigma^2}x} \stackrel{H_0}{\geq} 1$$

$$\log \frac{\pi_0}{\pi_1} + \frac{1}{\sigma^2}(\mu_0 - \mu_1)x + \frac{(\mu_0^2 - \mu_1^2)}{2\sigma^2}x \stackrel{H_0}{\geq} 0$$

$$\{ \mu_0 \leq \mu_1 \} \stackrel{H_0}{< x} \leq \frac{\sigma^2 \log \frac{\pi_0}{\pi_1} + \frac{\mu_0^2 - \mu_1^2}{2}}{\mu_1 - \mu_0} = \underbrace{\frac{\mu_0 + \mu_1}{2}}_{\bar{\mu}} + \underbrace{\frac{\sigma^2}{\mu_1 - \mu_0} \log \frac{\pi_0}{\pi_1}}_{\delta}$$

Wtedy średni kraj + błąd:



$$C = \pi_0 \int_{\bar{\mu} + \delta}^{\infty} \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{1}{2\sigma^2}(x - \mu_0)^2} dx$$

$$+ \pi_1 \int_{-\infty}^{\bar{\mu} + \delta} \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{1}{2\sigma^2}(x - \mu_1)^2} dx$$

$$= \pi_0 \frac{1}{\sqrt{\pi}} \int_{\frac{\mu_0 - \mu_1}{2} + \delta}^{\infty} e^{-x^2} dx + \frac{\pi_1}{\sqrt{\pi}} \int_{-\infty}^{\frac{\mu_0 - \mu_1}{2} + \delta} e^{-x^2} dx =$$

$$= \frac{\pi_0}{2} \left(1 - \text{Erf} \left(\delta + \frac{\mu_1 - \mu_0}{2} \right) \right) + \frac{\pi_1}{2} \left(1 + \text{Erf} \left(\frac{\mu_1 - \mu_0}{2} - \delta \right) \right)$$

4.2 Testowanie hipotez w granicy b. wch. decyzji:

Przyjmijmy że chcemy zmierzyć parametry

dwoma hipotezami: H_0 i H_1

$$x \sim p(x | H_0) =: p_0(x) \quad \pi_0 = p(H_0)$$

$$x \sim p(x | H_1) =: p_1(x) \quad \pi_1 = p(H_1)$$

1 jako koszt przyjętej $C_{ij} = 1 - \delta_{ij}$

Przyjmijmy że mamy N niezależnych realizacji x

czyli: $\vec{x} \sim \prod_i p_0(x_i)$ jeśli H_0

$\vec{x} \sim \prod_i p_1(x_i)$ jeśli H_1

Wtedy jest poprawnym wyborem H_0 jeśli

$$\frac{\prod_i p_0(x_i)}{\prod_i p_1(x_i)} \geq 1$$

1 wtedy koszt będzie:

$$C_N = 1 - \int dx^{(N)} \max\left(\prod_i p_0(x_i), \prod_i p_1(x_i)\right)$$

W ogólności trudno obliczyć.

Chcemy mieć zachowanie asymptotyczne C_N

$$C_N \xrightarrow{N \rightarrow \infty} ?$$

Large deviation theory

$x \sim p(\cdot)$ $x \in X$ $X = \{a_1, a_2, \dots, a_{|X|}\}$

N realizacji $x_1, \dots, x_N =: \vec{x}$

Nużem $N(a|\vec{x}^{(N)})$ - liczba obserwacji gdy $x_i = a$

Zdefiniujmy empiryczny rozkład prawdopodobieństwa

$$q_{\vec{x}}(a) = \frac{N(a|\vec{x}^{(N)})}{N}$$

Ł to samo w sobie jest zmienną losową.

Jedne jest prawdopodobieństwo, że z obserwacji
danej liczby niezależnych prawdopodobieństwa?

czy empiry jest prawdziwą prawdopodobieństwem?

Jakie jest prawdę w zabsługian koncepty
 ciąg \vec{x}^N :

$$P^{(N)}(\vec{x}^N) = \prod_i p(x_i) = \prod_a p(a)^{q_{\vec{x}^N}(a)} \cdot N =$$

$$2^{N \sum_a \log p(a) \cdot q_{\vec{x}^N}(a) + q_{\vec{x}^N}(a) \log q_{\vec{x}^N}(a) - q_{\vec{x}^N}(a) \log p(a)}$$

$$= 2^{N \left(\sum_a q_{\vec{x}^N}(a) \log q_{\vec{x}^N}(a) - \sum_a q_{\vec{x}^N}(a) \log \frac{q_{\vec{x}^N}(a)}{p(a)} \right)}$$

$H(q) = - \sum_a q(a) \log q(a)$ - entropia Shannona

$D(q \| p) = \sum_a q(a) \log \frac{q(a)}{p(a)}$ - względna entropia

$$P^{(N)}(\vec{x}^N) = 2^{-N(H(q_{\vec{x}^N}) + D(q_{\vec{x}^N} \| p))}$$

ile jest ciągów N elementów a tym samym możliwych empiry q

$$N_q^{(N)} = \frac{N!}{\prod_a (N q(a))!}$$

$$\log N_q^{(N)} = \log N! - \sum_a \log (N q(a))!$$

$$\left\{ \begin{array}{l} \log_2 N! = N \log_2 N - N \ln 2 + O(\ln N) \\ \frac{\log_a x}{\log_b x} = \log_b a \\ \ln x = \frac{\log_2 x}{\ln 2} \end{array} \right.$$

$$\frac{1}{N} \log N_q^{(N)} = \log N - \ln 2 + \sum_a (\log N + \log q(a)) q(a) - \ln 2 q(a) + \frac{1}{N} O(N \ln N)$$

$$= - \sum_a q(a) \log q(a) + \frac{1}{N} O(\log N)$$

$$N_q^{(N)} \doteq 2^{NH(q)}$$

Przedpokładujemy że rozdzielony jest ciąg a dany przez empiryczny q

$$p^{(N)}(q) \doteq N_q^{(N)} \cdot 2^{-N(H(q) + D(q||p))}$$

$$p^{(N)}(q) \doteq 2^{-ND(q||p)}$$

↑
interp. ent. względnej

Jest prawdopodobieństwo że P jest \hat{p} przedp. że w N próbach uzyskamy empiryczny rozdzielal q

Twierdzenie (Chernoff bound)

$$C_N \doteq 2^{-NC(p_0||p_1)}$$

$$C(p_0||p_1) = - \log \int_{0 \leq \lambda \leq 1} \left(\int dx p_0(x)^\lambda p_1(x)^{1-\lambda} \right) - \text{inf Chernoff}$$

\doteq minimalna wartość λ detekcji dla pewnego modelu ekspansji w N

Relacja: $\lim_{N \rightarrow \infty} -\frac{1}{N} \log C_N = C(p_0||p_1)$

Dowód: (w wersji dyskretny $\int dx \rightarrow \sum_{i=1}^{|x|}$)

Dowód: (w wersji dyshdziej $\int dx \rightarrow \sum_{i=1}^{|x|}$)

Wybieramy H_0 jeśli $\frac{\prod_0 \prod_i p_0(x_i)}{\prod_1 \prod_i p_1(x_i)} \geq 1$

rozważmy:

$$\log \frac{\prod_0}{\prod_1} + \sum_i \log \frac{p_0(x_i)}{p_1(x_i)} \geq 0$$


Miemy $q(a) = \frac{N(a|\bar{x})}{N}$ - empiryczny rozkład \bar{x}

$$\log \frac{\prod_0}{\prod_1} + \sum_a N q(a) \log \left(\frac{p_0(a)}{p_1(a)} \cdot \frac{q(a)}{q(a)} \right) \geq 0$$

$$\log \frac{\prod_0}{\prod_1} + N D(q||p_0) - ND(q||p_1) \geq 0$$

albo dla N :

$$D(q||p_1) \leq D(q||p_0)$$



Jest mielen ciąg o empirycznym rozkładzie q w obszarze H_0 to prawie bład 2 powadip.

$$\hat{\pi}_1 \cdot 2^{-N D(q||p_1)}$$

Jest w obszarze H_1 to prawie bład 2 powadip.

$$\hat{\pi}_0 \cdot 2^{-N D(q||p_0)}$$

Średni bład:

Średni błąd:

$$C \doteq \prod_1 \sum_{q \in H_0} 2^{-ND(q|p_1)} + \prod_0 \sum_{q \in H_1} 2^{-ND(q|p_0)}$$

Rozmyślenie jest małe więc $(N+1)^{|X|}$ czyli
 dominujący wkład do sumy a najmniejszy
 wykładnik. Dominujący wykładnik będzie
 rowny:

$$D^* = \min_q D(q|p_1) \text{ z warunkiem}$$

$$D(q|p_1) = D(q|p_2)$$

∴ wtedy: $C \doteq 2^{-ND}$

Searchony D^* : (metoda Lagrange)

$$f(q) = \sum_a q(a) \log \frac{q(a)}{p_1(a)} + \lambda \sum_a q(a) \log \frac{p_2(a)}{p_1(a)} + \nu \sum_a q(a)$$

$$\frac{df}{dq(a)} = \log \frac{q(a)}{p_1(a)} + 1 + \lambda \log \frac{p_2(a)}{p_1(a)} + \nu = 0$$

$$2 \frac{q(a)}{p_1(a)} \cdot \left(\frac{p_2(a)}{p_1(a)} \right)^\lambda 2^{-\nu} = 0$$

$$q(a) = \frac{1}{2} p_2(a)^\lambda p_1(a)^{1-\lambda} 2^{-\nu}$$

Czyli

$$q^*(a) = \frac{p_2(a)^\lambda p_1(a)^{1-\lambda}}{\sum_a \underbrace{p_2(a)^\lambda p_1(a)^{1-\lambda}}_{A_\lambda}}$$

+ i.e $D(q^*|p_1) = D(q^*|p_2)$

Czyli wamch na λ :

$$\sum_a \frac{p_2(a)^\lambda p_1(a)^{1-\lambda}}{A_\lambda} \log \frac{p_2(a)}{p_1(a)} = 0$$

$$\sum_a p_2(a)^\lambda p_1(a)^{1-\lambda} \log \frac{p_2(a)}{p_1(a)} = 0$$

$$\left\{ \begin{array}{l} \min_{\lambda} \left(\sum_a p_2(a)^\lambda p_1(a)^{1-\lambda} \right) \\ \frac{d}{d\lambda} \left(\sum_a e^{\lambda \ln p_2(a) - \lambda + \ln p_1(a) (1-\lambda)} \right) = \sum_a \ln \frac{p_2(a)}{p_1(a)} p_2(a)^\lambda p_1(a)^{1-\lambda} = 0 \end{array} \right.$$

$$D^* = \sum_a \frac{p_2(a)^{\lambda^*} p_1(a)^{1-\lambda^*}}{A_{\lambda^*}} \log \frac{p_2(a)^{\lambda^*} p_1(a)^{1-\lambda^*}}{A_{\lambda^*} p_1(a)} =$$

$$= - \sum_a \frac{p_2(a)^{\lambda^*} p_1(a)^{1-\lambda^*}}{A_{\lambda^*}} \log A_{\lambda^*} =$$

$$= - \log \sum_a p_2(a)^{\lambda^*} p_1(a)^{1-\lambda^*}$$

Czyli

$$D^* = - \log \min_{\lambda} \sum_a p_2(a)^\lambda p_1(a)^{1-\lambda}$$

