

48 22 55 44 300

Matematyka dla Wojciecha Nieminy z Mat. Stos.  
od Piotra Potarowskiego

---

Zad	Punktacja
1	3
2	3
3	2
4	2
5	3

liczba punktów	0-5	5.5-6	6.5-8	8.5-10	10.5-12	12.5-13
ocena	2	3	3+	4	4+	5

Maksymalna rozdzielność 0.5 punktu.

Zad 1. Wyprowadź wzór na drugą zmienną kanoniczną.

Rozw.  $X$  - macierz danych  $n \times p$  ( $n$  obser.,  $p$  - wym.)

$T := \text{var}(X)$ ,  $W$  - macierz variancji wewnątrzgrupowych,

$B$  - macierz variancji pomiędzygrupowych;  $T = W + B$ .

Zadanie polega na znalezieniu dwóch pierwszych kierunków kanonicznych:  $1^\circ a_1^T B a_1 \rightarrow \max_{a_1}, a_1^T W a_1 = 1$

$2^\circ a_2^T B a_2 \rightarrow \max_{a_2}, a_2^T W a_2 = 1, a_1^T W a_2 = 0$ .

Mając  $a_1$  wyznaczamy 2-gą zmienną kanoniczną  $Z_2 = X a_2$ , (studenci myślą  $Z_2$  i  $a_2$  - możemy pozostać na użytku  $a_2$ ).

(i)  $W$  ma rozkład Choleskiego  $U^T U$  (zakładamy, że  $\exists W^{-1}$ )

Wtedy dla  $i=1,2$ :  $a_i^T B a_i = a_i^T U^T (U^T)^{-1} B U^{-1} U a_i$  oraz

$a_i^T U^T U a_i = 1$ . Podstawiając  $C := (U^T)^{-1} B U^{-1}$  oraz  $u_i = U a_i$  mamy zadanie analizy składowych głównych:

(PCA)  $u_i^T C u_i \rightarrow \max_{u_i}, u_i^T u_i = 1, u_1^T u_2 = 0$ .

(ii) Rozważmy PCA. Niech  $V \Lambda V^T$  będzie rozkładem spekt.

$C$ , gdzie  $V = [v_1, \dots, v_p]$  ortogonalna oraz  $\Lambda = \text{diag}(\lambda_1, \dots, \lambda_p)$ ,

$\lambda_1 \geq \dots \geq \lambda_p \geq 0$ . Przyjmijmy, że  $u = \sum_j \alpha_j v_j$ . Wtedy

$$u^T C u = \left( \sum_j \alpha_j v_j^T \right) \left( \sum_k \alpha_k \lambda_k v_k \right) = \sum_j \lambda_j \alpha_j^2 =: \text{Prawa.}$$

Ponieważ  $\sum_j \alpha_j^2 = u^T u = 1$ , więc Prawa  $\leq \lambda_1$ . Maksimum jest realizowane przez  $v_1$ , natomiast wśród  $u$  ortogonalnych do  $v_1$  maksimum jest realizowane przez  $v_2$  oraz jest równe  $\lambda_2$ .

(iii) Sprawdzamy, że  $a_i := V^{-1} v_i$  (bo  $u_i = U a_i$ ) spełniają ograniczenia, np.:  $a_1^T U^T U a_2 = v_1^T v_2 = 0$ .

Zad 4. Wyprowadź wzór na optymalną regułę decyzyjną (zwróć uwagę na "0-1" f-cję straty) w wielowymiarowym modelu normalnym:  $N(m_1, \Sigma_1), \dots, N(m_k, \Sigma_k)$  z wykładem a-priori  $(q_j)$

Rozw (i) Optymalna reguła decyzyjna (klasyfikacyjna) to

$$d(x) = \operatorname{argmax}_{1 \leq j \leq k} p(j|x) = \operatorname{argmax}_j \log [f(x|j) q_j].$$

(ii) Podstawimy gęstość normalną za  $f(x|j)$  i uproszczamy wyrażenie (wykłady norm. są  $\beta$ -wymiarowe)

$$d(x) = \operatorname{argmax}_j \left[ -\frac{p}{2} \log \Sigma_j - \frac{1}{2} (x - m_j)^T \Sigma_j^{-1} (x - m_j) - \log q_j \right]$$

Zad 5. Niech  $\hat{\beta}$  będzie estymatorem najm. kwadr. wyznaczonym w modelu regresji liniowej wielu zmiennych z  $n$ -niezależnych obserwacji  $(y_1, x_1), \dots, (y_n, x_n)$ . Niech ponadto  $(y, x)$  będzie  $(n+1)$ -szą obserwacją niezależną od pozostałych. Oblicz:

(a)  $\operatorname{var}(y_i - \hat{\beta}^T x_i)$  dla  $i = 1, \dots, n$ ;

(b)  $\operatorname{var}(y - \hat{\beta}^T x)$

Rozw (a) z wykładu: jeśli  $H := X(X^T X)^{-1} X^T$ ,  $\hat{Y} := HY$ ,  $X$ -macierz eksponentu  $\begin{bmatrix} 1 & x_1 \\ & \vdots \\ & x_n \end{bmatrix}$ , to

$$\sigma^2 I = \operatorname{var} Y = \sigma^2 H + \sigma^2 (I - H) = \operatorname{var} \hat{Y} + \operatorname{var}(Y - \hat{Y}).$$

Ponieważ  $\hat{\beta} = (X^T X)^{-1} X^T Y$ , więc  $\hat{Y} = X \hat{\beta}$ .

Cygli  $\operatorname{var}(y_i - \hat{\beta}^T x_i)$  to element  $(i, i)$  macierzy  $\operatorname{var}(Y - \hat{Y}) = \sigma^2 (I - H)$ . zatem  $\operatorname{var}(y_i - \hat{\beta}^T x_i) = \sigma^2 (1 - x_i^T (X^T X)^{-1} x_i)$ .

(b) Wiemy z wykładu, że  $\operatorname{var} \hat{\beta} = \sigma^2 (X^T X)^{-1}$ .

zatem z niezależności  $\operatorname{var}(y - \hat{\beta}^T x) = \operatorname{var} Y + \operatorname{var} \hat{\beta}^T x$

$$= \sigma^2 + x^T (\operatorname{var} \hat{\beta}) x = \sigma^2 (1 + x^T (X^T X)^{-1} x).$$

Za zrobienie (a) - 1 pkt, za (b) - 2 pkt.

Zad 2 Niech  $X, Y$  będą zm. los. oraz  $f$  - funkcja  $X$  mierzalna. Udowodnij, że  $\text{cor}(Y, E(Y|X))^2 \leq \text{cor}(Y, f(X))^2$ . 2

Rozw (i) Niech  $\hat{Y} = E(Y|X)$  oraz  $\text{cor}(X, Y) = \rho(X, Y)$ .

$$\begin{aligned} \text{cov}(Y, f) &= E(Y - EY)(f - Ef) = EY(f - Ef) = E((f - Ef)\hat{Y}) \\ &= E(f - Ef)(\hat{Y} - E\hat{Y}) = \text{cov}(\hat{Y}, f). \end{aligned}$$

(ii) W szczególności dla  $f = \hat{Y}$  mamy  $\text{cov}(Y, \hat{Y}) = \text{var}\hat{Y} =: \sigma_{\hat{Y}}^2$ .

(iii) zatem  $\rho(Y, f) = \frac{\text{cov}(Y, f)}{\sigma_Y \sigma_f} = \frac{\sigma_{\hat{Y}}^2}{\sigma_Y \sigma_{\hat{Y}}} \frac{\text{cov}(\hat{Y}, f)}{\sigma_{\hat{Y}} \sigma_f}$

$$= \frac{\text{cov}(Y, \hat{Y})}{\sigma_Y \sigma_{\hat{Y}}} \frac{\text{cov}(\hat{Y}, f)}{\sigma_{\hat{Y}} \sigma_f}.$$

Po podniesieniu stronem do kwadratu dostajemy:

$$\rho^2(Y, f) = \rho^2(Y, \hat{Y}) \rho^2(\hat{Y}, f).$$

Ponieważ  $\rho^2(Y, \hat{Y}) \leq 1$ ,

wsc maksimum lewej mamy dla  $f = \hat{Y}$ , że  $\rho^2(\hat{Y}, f) = 1$ , a wsc również dla  $f = \hat{Y}$ .

Zad 3 Sformułuj model logistyczny i podaj algorytm dla wyznaczenia jego parametrów z zasady największej wiarygodności.

Rozw (i)  $(Y_i, X_i)_{i=1}^n$  niezależne,  $Y_i \sim \text{binom}(1, p(x))$ , gdzie  $\text{logit } p(x) = \alpha + \beta^T x \Leftrightarrow p(x) = \frac{e^{\alpha + \beta^T x}}{1 + e^{\alpha + \beta^T x}}$

(ii) Największość próby:  $L(\alpha, \beta) := \prod_{i=1}^n p(x_i)^{Y_i} (1 - p(x_i))^{1 - Y_i}$

Log-wiarygodność  $l(\alpha, \beta) := \sum_i Y_i (\alpha + \beta^T x_i) + \sum_i (1 - Y_i) - \sum_i \log \Delta_i$

gdzie  $\Delta_i = 1 + e^{\alpha + \beta^T x_i}$ . Parametry  $\alpha, \beta$  znajdujemy numerycznie, np z pomocą alg. Newtona.