

ANALIZA DYSKRYMINACYJNA POPULACJI NORMALNYCH
PRZY NIEZNANYCH PARAMETRACH I NIEZNANYCH
PRAWDOPODOBIENSTWACH A PRIORI

1. Wstęp

Założmy, że w populacji π_1 obserwowany wektor losowy \underline{Z}_1 ma p -wymiarowy rozkład normalny z parametrami $\underline{\mu}_1, \underline{\Sigma}_1$, dla $i = 1, \dots, k$. Dana jest obserwacja \underline{z} , o której wiemy, że jest obserwacją pochodzącą z jednej z k populacji π_1, \dots, π_k , lecz nie wiemy z której.

Niech $q_i > 0$ ($q_1 + \dots + q_k = 1$) oznacza prawdopodobieństwo a priori zdarzenia, że obserwacja \underline{z} pochodzi z populacji π_1 , natomiast $f(\underline{z} | \underline{\mu}_1, \underline{\Sigma}_1)$ niech oznacza funkcję gęstości wektora losowego \underline{Z}_1 , $i = 1, \dots, k$.

W przypadku, gdy prawdopodobieństwa q_i oraz funkcje $f(\underline{z} | \underline{\mu}_i, \underline{\Sigma}_i)$ są znane, to decydujemy, że obserwacja \underline{z} pochodzi z tej populacji, dla której prawdopodobieństwo a posteriori

$$(1) \quad P(\pi_1 | \underline{z}) = \frac{q_1 f(\underline{z} | \underline{\mu}_1, \underline{\Sigma}_1)}{\sum_{j=1}^k q_j f(\underline{z} | \underline{\mu}_j, \underline{\Sigma}_j)}$$

jest maksymalne.

Rozwiązanie to pokrywa się z rozwiązaniem uzyskanym na drodze minimalizacji ryzyka bayesowskiego (patrz np. Anderson [1958], rozdz.6).

Celem tej pracy jest podanie oszacowań prawdopodobieństw a posteriori $P(\pi_i | \underline{z})$ w przypadku, gdy prawdopodobieństwa q_i oraz funkcje $f(\underline{z} | \pi_i, \underline{\Sigma}_i)$ nie są znane, $i = 1, \dots, k$.

2. Metoda

Niech $\bar{\underline{z}}_i$ oraz \underline{S}_i oznaczają zwykłe estymatory parametrów $\pi_i, \underline{\Sigma}_i$ uzyskane z próby o liczebności N_i , $i = 1, \dots, k$. Posłużymy się bayesowskim estymatorem nieznannej funkcji gęstości $f(\underline{z} | \pi_i, \underline{\Sigma}_i)$, $i = 1, \dots, k$. Wiadomo, że gdy posługujemy się kwadratową funkcją straty, to bayesowski estymator funkcji gęstości $f(\underline{z} | \mu_i, \underline{\Sigma}_i)$ jest równy wartości oczekiwanej tej funkcji względem rozkładu a posteriori parametrów w niej występujących. Oznaczmy ten estymator przez $h(\underline{z} | \bar{\underline{z}}_i, \underline{S}_i)$, $i = 1, \dots, k$.

Mamy

$$(2) \quad h(\underline{z} | \bar{\underline{z}}_i, \underline{S}_i) = \iint f(\underline{z} | \mu_i, \underline{\Sigma}_i) t(\mu_i, \underline{\Sigma}_i | \bar{\underline{z}}_i, \underline{S}_i) d\mu_i d\underline{\Sigma}_i,$$

gdzie $t(\mu_i, \underline{\Sigma}_i | \bar{\underline{z}}_i, \underline{S}_i)$ jest funkcją gęstości rozkładu a posteriori parametrów $\mu_i, \underline{\Sigma}_i$, $i = 1, \dots, k$.

Przyjmując, że funkcja gęstości łącznego rozkładu a priori parametrów $\mu_i, \underline{\Sigma}_i$ jest funkcją Jeffreys'a [1961] postaci

$$(3) \quad g(\mu_i, \underline{\Sigma}_i^{-1}) \propto |\underline{\Sigma}_i|^{-\frac{p+1}{2}} \quad (\propto \text{oznacza proporcjonalność})$$

otrzymamy (Geisser, [1964])

$$(4) \quad h(\underline{z} | \bar{\underline{z}}_i, \underline{S}_i) = c_i [1 + N_i (N_i^2 - 1)^{-1} (\underline{z} - \bar{\underline{z}}_i) \underline{S}_i^{-1} (\underline{z} - \bar{\underline{z}}_i)]^{-\frac{N_i}{2}}$$

gdzie

$$(5) \quad c_i = [\pi^{-1} N_i (N_i + 1)^{-1}]^{\frac{p}{2}} \Gamma(N_i/2) \Gamma^{-1}[(N_i - p)/2] | (N_i - 1) \underline{s}_i |^{-\frac{1}{2}}$$

$i = 1, \dots, k.$

Funkcja $h(\underline{z} | \bar{\underline{z}}_i, \underline{s}_i)$ dana wzorem (4) jest funkcją gęstości p -wymiarowego rozkładu t (Cornish, [1954]).

Zajmiemy się teraz nieznanym prawdopodobieństwem a priori q_i , $i = 1, \dots, k.$

Oznaczmy przez A_i zdarzenie, że losowo wybrana obserwacja z N elementowej próby pobranej z populacji π_1, \dots, π_k jest obserwacją pochodzącą z populacji π_i , $i = 1, \dots, k.$

Założmy, że w N -elementowej próbie wykluczające się zdarzenia A_1, A_2, \dots, A_k wystąpiły odpowiednio N_1, N_2, \dots, N_k razy. Założmy dalej, że nieznanne prawdopodobieństwo q_i jest estymowane przez N_i/N gdzie $N = \sum_i N_i$ oraz $P(A_i) = q_i.$

Zatem prawdopodobieństwo, że zdarzenie A_i wystąpi N_i razy wynosi $q_i^{N_i}$ i łączne prawdopodobieństwo, że zdarzenie A_1 wystąpi N_1 razy, A_2 wystąpi N_2 razy, itd., A_k wystąpi N_k razy wynosi $q_1^{N_1} \cdot q_2^{N_2} \cdot \dots \cdot q_k^{N_k}.$

Ponieważ liczba takich zdarzeń jest równa $\frac{N!}{N_1! N_2! \dots N_k!}$, to łączny rozkład wektora losowego N_1, N_2, \dots, N_{k-1} jest $(k-1)$ -wymiarowym rozkładem wielomianowym, którego funkcja masy jest postaci:

$$(6) \quad p(N_1, N_2, \dots, N_{k-1} | q_1, q_2, \dots, q_{k-1}) = \frac{N!}{\prod_{j=1}^k N_j!} \prod_{j=1}^k q_j^{N_j},$$

gdzie $N_k = N - N_1 - \dots - N_{k-1}$, oraz $q_k = 1 - q_1 - \dots - q_{k-1}$.

Stąd funkcję wiarygodności możemy zapisać następująco:

$$(7) \quad L(q_1, q_2, \dots, q_{k-1}) \propto \prod_{j=1}^k q_j^{N_j}.$$

Można dowieść (patrz np. Wilks, [1962]), że zachodzi następująca równość:

$$(8) \quad \int_S x_1^{v_1-1} x_2^{v_2-1} \dots x_k^{v_k-1} (1-x_1-\dots-x_k)^{v_{k+1}-1} dx_1 dx_2 \dots dx_k =$$

$$= \frac{\prod_{j=1}^{k+1} \Gamma(v_j)}{\Gamma(\sum_{j=1}^{k+1} v_j)},$$

gdzie S jest simplexem postaci:

$$(x_1, x_2, \dots, x_k): x_i \geq 0, \quad i = 1, 2, \dots, k, \quad \sum_{i=1}^k x_i \leq 1$$

oraz $v_i > 0$, dla $i = 1, 2, \dots, k$.

Całka występująca w (8) nazywa się całką Dirichleta i jest ona uogólnieniem funkcji beta.

W związku z tym funkcja gęstości postaci:

$$(9) \quad f(x_1, x_2, \dots, x_k) =$$

$$= \begin{cases} \frac{\Gamma(\sum_{j=1}^{k+1} v_j)}{\prod_{j=1}^{k+1} \Gamma(v_j)} x_1^{v_1-1} \dots x_k^{v_k-1} (1-x_1-\dots-x_k)^{v_{k+1}-1}, & \text{dla } (x_1, \dots, x_k) \in S \\ 0 & \text{dla } (x_1, \dots, x_k) \notin S \end{cases}$$

jest nazywana funkcją gęstości k -wymiarowego rozkładu Dirichleta. Załóżmy teraz, że funkcja gęstości prawdopodobieństwa a priori g łącznego rozkładu zmiennych losowych q_1, \dots, q_{k-1} jest funkcją gęstości rozkładu Dirichleta postaci:

$$(10) \quad g(q_1, q_2, \dots, q_{k-1}) \propto \prod_{j=1}^k q_j^{\alpha_j} \quad (\alpha_j > 0, j=1, 2, \dots, k)$$

przy czym równość (10) wystąpi wtedy, gdy jej prawą stronę pomnożymy przez $\frac{\Gamma[\sum_j (\alpha_j + 1)]}{\prod_j \Gamma(\alpha_j + 1)}$.

Korzystając z (7) i (10) otrzymamy gęstość a posteriori łącznego rozkładu zmiennych q_1, \dots, q_{k-1} :

$$(11) \quad P(q_1, q_2, \dots, q_{k-1} | N_1, N_2, \dots, N_{k-1}) \propto \prod_{j=1}^k q_j^{\alpha_j + N_j},$$

przy czym równość w (11) zachodzi wtedy gdy prawą stronę (11)

pomnożymy przez $\frac{\Gamma[\sum_j (N_j + \alpha_j + 1)]}{\prod_j \Gamma(N_j + \alpha_j + 1)}$.

Ponieważ prawdopodobieństwo a posteriori zdarzenia że obserwacja \underline{z} pochodzi z populacji π_1 zależy od q_1 , to w celu znalezienia bezwarunkowego prawdopodobieństwa a posteriori $P(\pi_1 | \underline{z})$ musimy zmodyfikować gęstość (11) przez uzależnienie jej od \underline{z} .

Lemat.

Niech A, B, C będą zdarzeniami spełniającymi następujące warunki:

- (i) $A \cap C = A$
- (ii) $P(B \cap C) = P(B) P(C)$.

Zachodzi następujący związek

$$(12) \quad P(A | B \cap C) = P(A \cap C) P(B | A).$$

Dowód.

Ponieważ zachodzi równość

$P(A \cap B \cap C) = P(B|A \cap C) P(A \cap C)$, to na mocy (i) mamy

$P(A \cap B \cap C) = P(B|A) P(A \cap C)$.

Dzieląc obie strony ostatniej równości przez $P(B \cap C)$ i korzystając z (ii) mamy

$$\frac{P(A \cap B \cap C)}{P(B \cap C)} = \frac{P(B|A) P(A \cap C)}{P(B) P(C)}.$$

Ostatecznie więc

$$P(A|B \cap C) = \frac{1}{P(B)} P(B|A) P(A|C) \propto P(B|A) P(A|C), \text{ c.n.d.}$$

Z (12) wynika, że

$$(13) \quad P(q_1, q_2, \dots, q_{k-1} | \underline{z}, N_1, N_2, \dots, N_{k-1}) = \\ P(q_1, q_2, \dots, q_{k-1} | N_1, N_2, \dots, N_{k-1}) h(\underline{z} | q_1, q_2, \dots, q_{k-1}) \frac{1}{h(\underline{z})},$$

gdzie: $h(\underline{z} | q_1, q_2, \dots, q_{k-1}) = \prod_{j=1}^k q_j h(\underline{z} | \underline{\mu}_j, \underline{\Sigma}_j)$,

$$h(\underline{z}) = \prod_{j=1}^k (N_j + \alpha_j + 1) h(\underline{z} | \underline{\mu}_j, \underline{\Sigma}_j) / \prod_{j=1}^k (N_j + \alpha_j + 1).$$

Zatem:

$$(14) \quad P(q_1, q_2, \dots, q_{k-1} | \underline{z}, N_1, N_2, \dots, N_{k-1}) \propto \prod_j q_j^{N_j + \alpha_j} \prod_j q_j h(\underline{z} | \underline{\mu}_j, \underline{\Sigma}_j)$$

oraz

$$(15) \quad \int \dots \int P(q_1, \dots, q_{k-1} | \underline{z}, N_1, \dots, N_{k-1}) P(\pi_1 | \underline{z}, \underline{q}) dq_1 \dots dq_{k-1} = \\ P(\pi_1 | \underline{z}) \propto \int \dots \int \prod_j q_j^{N_j + \alpha_j} \prod_j q_j h(\underline{z} | \underline{\mu}_j, \underline{\Sigma}_j) P(\pi_1 | \underline{z}, \underline{q}) dq_1 \dots dq_{k-1},$$

gdzie $P(\pi_i | \underline{z}, q) = q_i h(\underline{z} | \mu_i, \Sigma_i) / \sum_j q_j h(\underline{z} | \mu_j, \Sigma_j)$.

Dalej mamy

$$\begin{aligned}
 P(\pi_i | \underline{z}) &= \frac{\Gamma[\sum_j (N_j + \alpha_j + 1)] h(\underline{z} | \mu_i, \Sigma_i)}{\prod_j \Gamma(N_j + \alpha_j + 1)} \int \dots \int \prod_j q_j^{N_j + \alpha_j} q_i dq_1 \dots dq_{k-1} = \\
 &= \frac{\Gamma[\sum_j (N_j + \alpha_j + 1)] h(\underline{z} | \mu_j, \Sigma_j)}{\prod_j \Gamma(N_j + \alpha_j + 1)} \frac{\Gamma(N_i + \alpha_i + 2) \prod_{\substack{j=1 \\ j \neq i}}^k \Gamma(\alpha_j + N_j + 1)}{\Gamma[\sum_{j=1}^k (\alpha_j + N_j + 1) + 1]} = \\
 &= \frac{\Gamma[\sum_j (N_j + \alpha_j + 1)] h(\underline{z} | \mu_i, \Sigma_i)}{\prod_j \Gamma(N_j + \alpha_j + 1)} \frac{(\alpha_i + N_i + 1) \Gamma(N_i + \alpha_i + 1) \prod_{j \neq i} \Gamma(\alpha_j + N_j + 1)}{[1 + \sum_j (\alpha_j + N_j + 1)]} = \\
 &= \frac{h(\underline{z} | \mu_i, \Sigma_i)}{h(\underline{z})} \frac{\alpha_i + N_i + 1}{\sum_j (\alpha_j + N_j + 1)}.
 \end{aligned}$$

Tak więc

$$(16) \quad P(\pi_i | \underline{z}) = \frac{(N_j + \alpha_j + 1) h(\underline{z} | \mu_i, \Sigma_i)}{\sum_j (N_j + \alpha_j + 1) h(\underline{z} | \mu_j, \Sigma_j)}, \quad i=1, 2, \dots, k.$$

Równość (16) przedstawia poszukiwane prawdopodobieństwo a posteriori zaklasyfikowania obserwacji \underline{z} do populacji π_i , gdy nieznane są prawdopodobieństwa a priori q_i , że obserwacja \underline{z} pochodzi z populacji π_i , oraz gdy nieznane są parametry μ_i , Σ_i , $i = 1, 2, \dots, k$.

Uwaga.

Wielkość α_i należy interpretować jako częściową informację o wartości q_i , jeżeli q_i nie jest znane, $i = 1, \dots, k$.

Jeżeli $\alpha_1 = \dots = \alpha_k = \alpha$ oraz $N_1 = \dots = N_k = M$, to równość (16) przyjmuje postać

$$P(\pi_i | \underline{z}) = \frac{h(\underline{z} | \underline{\mu}_i, \underline{\Sigma}_i)}{\sum_j h(\underline{z} | \underline{\mu}_j, \underline{\Sigma}_j)}, \quad i = 1, \dots, k.$$

Zauważmy, że przypadek ten odpowiada sytuacji, kiedy q_i nie są znane i kiedy zakłada się, że wszystkie q_i są sobie równe tzn. $q_1 = q_2 = \dots = q_k = \frac{1}{k}$.

Literatura cytowana

- Anderson, T.W., 1958, An Introduction to Multivariate Statistical Analysis, Wiley, New York.
- Cornish, E.A., 1954, The multivariate t - distribution associated with a set of normal sample deviates, Australian Journal of Physics, 7, str.531 - 542.
- Jeffreys, H., 1961, Theory of Probability, 3rd ed., Oxford University Press, Oxford.
- Geisser, S., 1963, Posterior Odds for Multivariate Normal Classifications, Journal of the Royal Statistical Society, str. 69 - 76.
- Wilks, S.S., 1962, Mathematical Statistics, Wiley, New York.

DISCRIMINANT ANALYSIS OF NORMAL POPULATIONS WITH
UNKNOWN PARAMETERS AND UNKNOWN PRIOR PROBABILITIES

Summary

Let us assume that the observed random vector $\underline{z}_i = (z_1, \dots, z_p)'$ from population π_i has a p -dimensional normal distribution with a mean vector $\underline{\mu}_i$ and a positive definite covariance matrix $\underline{\Sigma}_i$, $i = 1, 2, \dots, k$. A multivariate observation \underline{z} is known and it belongs to one of k multivariate normal populations π_i , but it is not known to which.

If the prior probability that \underline{z} belongs to π_i is q_i , where $\sum q_i = 1$, and the parameters of π_i are known, it is relatively easy to compute the likelihood that \underline{z} belongs to π_i and then to combine this, via Bayes's theorem, with the prior probability in order to obtain the posterior probability.

In the present paper we consider the discrimination between π_i 's when the q_i 's and the parameters of π_i 's are a priori unknown.