

# **5. Analiza dyskryminacyjna: FLD, LDA, QDA**

dr inż. Urszula Libal

Politechnika Wroclawska

2015


# 1. Liniowe funkcje dyskryminacyjne

Liniowe funkcje dyskryminacyjne mają ogólną postać

$$\delta(\mathbf{x}) = \mathbf{w}^T \mathbf{x} + w_0 = \sum_{i=1}^D w_i x_i + w_0. \quad (1)$$

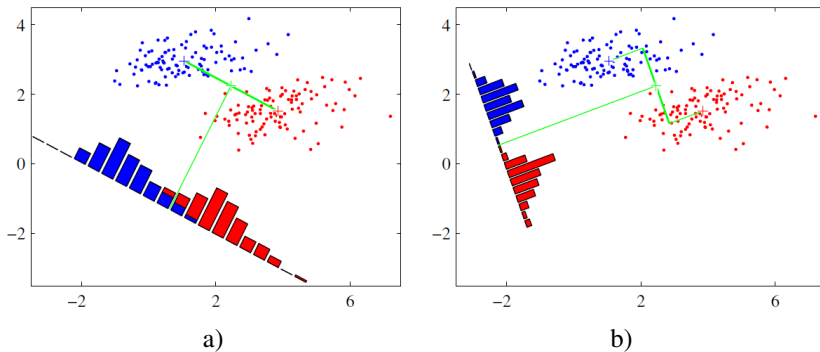
Do liniowych dyskryminatorów, czyli klasyfikatorów opartych o liniowe funkcje dyskryminacyjne, zaliczamy

- FLD - liniowy dyskryminator Fishera,
- LDA - liniową analizę dyskryminacyjną.



Rysunek 1. Prosta rozdzielająca (na czerwono) jest prostopadła do wektora  $w$  (na zielono) wyznaczającego kierunek rzutu wektora  $x$ .

Źródło: [2]



Rysunek 2. (a) Rzut na prostą łączącą średnie w klasach. (b) Rzut na prostą o kierunku wyznaczonym przez kryterium Fishera poprawia separację klas.

*Źródło: [2]*

## 2. Liniowy dyskryminator Fishera (FLD)

Liniowy dyskryminator Fishera [1] (ang. *Fisher's Linear Discriminant*, FLD) zakłada, że  $\mu_k$  to średnie, a  $\Sigma_k$  to macierze kowariancji w klasach  $k = 1, 2$ .

Dokonyjemy liniowej transformacji, dzięki której uzyskamy najlepsze rozdzielenie klas. W celu separacji klas rzutujemy wektory cech  $\mathbf{x}$  na hiperpłaszczyznę wyznaczoną przez kierunek  $\mathbf{w}$ . Aby to osiągnąć maksymalizujemy klasyczne kryterium Fishera [5]

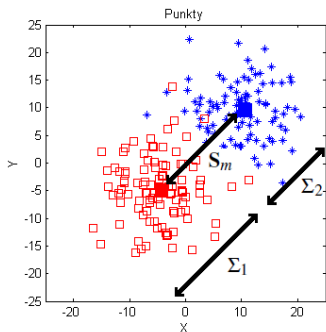
$$F(\mathbf{w}) = \frac{\mathbf{w}^T \mathbf{S}_m \mathbf{w}}{\mathbf{w}^T \mathbf{S}_w \mathbf{w}}, \quad (2)$$

gdzie  $\mathbf{S}_m$  to macierz rozproszeń międzyklasowych

$$\mathbf{S}_m = (\mu_1 - \mu_2)(\mu_1 - \mu_2)^T, \quad (3)$$

a  $S_w$  to macierz rozprożeń wewnątrzklasowych

$$S_w = p_1 \Sigma_1 + p_2 \Sigma_2. \quad (4)$$



Rysunek 3. Rozrzut międzyklasowy oraz wewnątrzklasowy.

*Źródło: opracowanie własne*

Wyliczamy pochodną kryterium  $F$  i przyrównujemy do zera

$$\frac{\partial}{\partial \mathbf{w}} F(\mathbf{w}) = 0. \quad (5)$$

Optymalny kierunek dyskryminacyjny to

$$\mathbf{w} = \mathbf{S}_w^{-1} (\mu_1 - \mu_2). \quad (6)$$

Liniowy dyskryminator Fishera ma postać

$$\Psi_{FLD}(\mathbf{x}) = \begin{cases} 1, & \text{gdy } \mathbf{w}^T \mathbf{x} < w_{gr}, \\ 2, & \text{w przeciwnym wypadku,} \end{cases} \quad (7)$$

co po podstawieniu (6) i uwzględnieniu, że  $\mathbf{S}_w$  jest macierzą symetryczną, daje

$$\Psi_{FLD}(\mathbf{x}) = \begin{cases} 1, & \text{gdy } (\mu_1 - \mu_2)^T \mathbf{S}_w^{-1} \mathbf{x} < w_{gr}, \\ 2, & \text{w przeciwnym wypadku.} \end{cases} \quad (8)$$

Próg  $w_{gr}$  wyznaczamy minimalizując średnie prawdopodobieństwo błędnej klasyfikacji - jest to punkt graniczny (por. rys. 1 z wykładu nr 1).

Niech  $f_1^\perp$  i  $f_2^\perp$  oznaczają jednowymiarowe funkcje gęstości, które są rzutami  $D$ -wymiarowych gęstości  $f_1$  i  $f_2$  w klasach na kierunek  $\mathbf{w}$  (por. histogramy na rys. (b)).

Zrzutowane rozkłady w klasach  $k = 1, 2$  charakteryzują się średnimi

$$m_k = \mathbf{w}^T \boldsymbol{\mu}_k \quad (9)$$



oraz wariancjami

$$\sigma_k^2 = \mathbf{w}^T \Sigma_k \mathbf{w}. \quad (10)$$

Szukamy  $w_{gr}$ , które spełnia

$$p_1 f_1^\perp(w_{gr}) = p_2 f_2^\perp(w_{gr}). \quad (11)$$

Ogólnie można zapisać, że FLD klasyfikuje obraz do klasy  $j \in \mathcal{M}$ ,

$$\Psi_{FLD}(\mathbf{x}) = j, \text{ gdy } |\mathbf{w}^T \mathbf{x} - \mathbf{w}^T \mu_j| < |\mathbf{w}^T \mathbf{x} - \mathbf{w}^T \mu_k|, \quad (12)$$

dla każdej klasy  $k \in \mathcal{M}$  różnej od  $j$ .

### 3. Liniowa analiza dyskryminacyjna (LDA)

Liniowa analiza dyskryminacyjna [2] (ang. *Linear Discriminant Analysis*, LDA) zakłada, że funkcje gęstości prawdopodobieństwa w klasach  $k = 1, 2$  mają  $D$ -wymiarowe rozkłady normalne  $\mathcal{N}(\boldsymbol{\mu}_k, \boldsymbol{\Sigma})$  o równych macierzach kowariancji w klasach.

Można więc powiedzieć, że LDA jest równoważne FLD przy dodatkowych założeniach, że rozkłady w klasach są gaussowskie i macierze kowariancji w klasach są równe

$$\boldsymbol{\Sigma} = \boldsymbol{\Sigma}_1 = \boldsymbol{\Sigma}_2.$$

Liniowa funkcja dyskryminacyjna ma ponownie postać

$$\delta(\mathbf{x}) = \mathbf{w}^T \mathbf{x} + w_0 = \sum_{i=1}^D w_i x_i + w_0, \quad (13)$$

a klasyfikator

$$\Psi_{LDA}(\mathbf{x}) = \begin{cases} 1, & \text{gdy } \mathbf{w}^T \mathbf{x} < w_{gr}, \\ 2, & \text{w przeciwnym wypadku,} \end{cases} \quad (14)$$

gdzie optymalny kierunek dyskryminacyjny to

$$\mathbf{w} = \Sigma^{-1} (\mu_1 - \mu_2). \quad (15)$$

Z warunku

$$p_1 f_1^\perp(w_{gr}) = p_2 f_2^\perp(w_{gr}) \quad (16)$$

wyznamy  $w_{gr}$ .

W przypadku dwóch klas rozpatrujemy rozkłady  $\mathcal{N}(\mu_1, \Sigma_1)$  oraz  $\mathcal{N}(\mu_2, \Sigma_2)$ , co po uwzględnieniu (9) i (10) prowadzi do warunku

$$p_1 \frac{1}{\sigma_1 \sqrt{2\pi}} \exp \left\{ (w_{gr} - m_1)^2 / (2\sigma_1^2) \right\} = p_2 \frac{1}{\sigma_1 \sqrt{2\pi}} \exp \left\{ (w_{gr} - m_2)^2 / (2\sigma_2^2) \right\}. \quad (17)$$

Po przekształceniu otrzymujemy równanie kwadratowe

$$(\sigma_1^2 - \sigma_2^2)w_{gr}^2 + (\sigma_1^2 m_2 - \sigma_2^2 m_1)w_{gr} + m_1^2 \sigma_2^2 - m_2^2 \sigma_1^2 - 2\sigma_1^2 \sigma_2^2 \ln \frac{p_1 \sigma_1}{p_2 \sigma_2} = 0. \quad (18)$$

Przypadki szczególne:

(a) Jeżeli  $\sigma = \sigma_1 = \sigma_2$ , to

$$w_{gr} = \frac{m_1 + m_2}{2} + \frac{\sigma^2}{m_2 - m_1} \ln \frac{p_1}{p_2}. \quad (19)$$

(b) Jeżeli  $\sigma = \sigma_1 = \sigma_2$  i  $p_1 = p_2$ , to

$$w_{gr} = \frac{m_1 + m_2}{2}. \quad (20)$$

(c) Jeżeli  $\sigma_1 \neq \sigma_2$ , to istnieją dwa pierwiastki równania

$$w_{gr1,2} = \frac{\sigma_2^2 m_1 - \sigma_1^2 m_2 \pm \sigma_1 \sigma_2 \sqrt{(m_2 - m_1)^2 + 2(\sigma_2^2 - \sigma_1^2) \ln \frac{p_1 \sigma_1}{p_2 \sigma_2}}}{\sigma_2^2 - \sigma_1^2}. \quad (21)$$

(d) Jeżeli  $\sigma_1 \neq \sigma_2$ , i  $m = m_1 = m_2$ , to

$$w_{gr1,2} = m \pm \sigma_1 \sigma_2 \sqrt{\frac{2}{\sigma_2^2 - \sigma_1^2} \ln \frac{p_1 \sigma_1}{p_2 \sigma_2}}. \quad (22)$$

**Uwaga 1.** Czasami w literaturze reguła FLD i LDA są ze sobą utożsamiane.

**Uwaga 2.** Z równości  $\Sigma = \Sigma_1 = \Sigma_2$  wynika  $\sigma = \sigma_1 = \sigma_2 = \mathbf{w}^T \Sigma \mathbf{w}$ ,

dlatego przypadki (a) i (b) odnoszą się do metody LDA.

**Uwaga 3.** Natomiast przypadki (c) i (d) zachodzą dla  $\sigma_1 \neq \sigma_2$ ,

co może zajść jedynie, gdy  $\Sigma_1 \neq \Sigma_2$ . Dopuszczenie różnych macierzy kowariancji

przy założeniu normalności rozkładów w klasach nazywane jest metodą QDA.

## 4. Kwadratowa analiza dyskryminacyjna (QDA)

W przypadku, gdy pominiemy założenie o równości macierzy kowariancji w gaussowskich rozkładach  $\mathcal{N}(\mu_1, \Sigma_1)$  oraz  $\mathcal{N}(\mu_2, \Sigma_2)$ , otrzymamy klasyfikator zwany kwadratową analizą dyskryminacyjną [3] (ang. *Quadratic Discriminant Analysis*, QDA). Warunek

$$p_1 f_1^\perp(w_{gr}) = p_2 f_2^\perp(w_{gr}) \quad (23)$$

pozwała wyznaczyć  $w_{gr}$  - patrz wzory (21) i (22). Forma reguły klasyfikacyjnej pozostaje bez zmian, tzn.

$$\Psi_{QDA}(\mathbf{x}) = \begin{cases} 1, & \text{gdy } \mathbf{w}^T \mathbf{x} < w_{gr}, \\ 2, & \text{w przeciwnym wypadku.} \end{cases} \quad (24)$$

W przypadku punktów na płaszczyźnie krzywa rozdzielająca klasy przyjmuje postać okręgu, elipsy, paraboli lub hiperboli.

## 5. Uogólnione liniowe funkcje dyskryminacyjne

Uogólnione liniowe funkcje dyskryminacyjne [4] (ang. *Generalised Linear Discriminant Functions*, GLDFs), określane także jako *maszyny  $\phi$* , są to funkcje dyskryminacyjne postaci

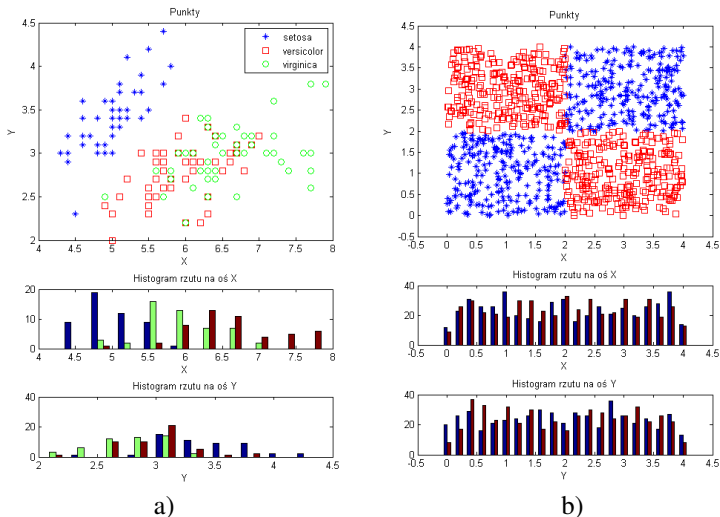
$$\delta(\mathbf{x}) = \mathbf{w}^T \phi + w_0 \quad (25)$$

gdzie  $\phi = (\phi_1(\mathbf{x}), \phi_2(\mathbf{x}), \dots, \phi_d(\mathbf{x}))^T$  jest funkcja wektorową  $\mathbf{x}$ .




Funkcja dyskryminująca	Matematyczna forma $\phi_i(\mathbf{x})$
liniowa	$\phi_i(\mathbf{x}) = x_i$
kwadratowa	$\phi_i(\mathbf{x}) = x_{k_1}^{l_1} x_{k_2}^{l_2}$ , gdzie $l_1, l_2 = 0$ lub $1$
wielomianowa $n$ -tego rzędu	$\phi_i(\mathbf{x}) = x_{k_1}^{l_1} \dots x_{k_n}^{l_n}$ , gdzie $l_1, \dots, l_n = 0$ lub $1$
radialna funkcja bazowa	$\phi_i(\mathbf{x}) = \phi( \mathbf{x} - \mathbf{v}_i )$
perceptron wielowarstwowy	$\phi_i(\mathbf{x}) = f(\mathbf{x}^T \mathbf{v}_i + v_{i0})$ , gdzie $f$ to funkcja logistyczna $f(z) = 1/(1 + \exp(-z))$

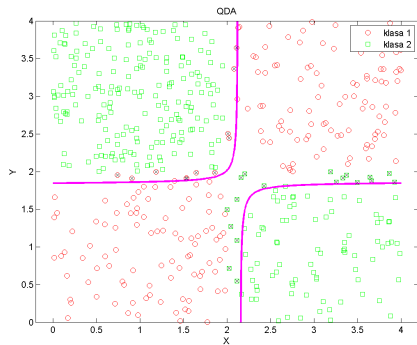
## 7. Przykłady i dyskusja założeń



Rysunek 4. Rozkłady brzegowe: (a) dla danych Fisheriris, (b) rozkłady jednostajne.




a)




b)

Rysunek 5. (a) Prosta rozdzielająca klasy za pomocą LDA.  
 (b) Krzywe rozdzielające klasy za pomocą QDA.

*Źródło: opracowanie własne*



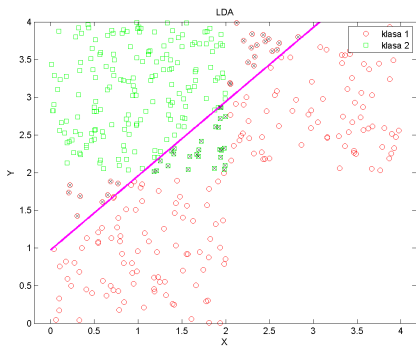
a)




b)

Rysunek 6. (a) Prosta rozdzielająca klasy za pomocą LDA.  
 (b) Krzywe rozdzielające klasy za pomocą QDA.

*Źródło: opracowanie własne*



a)



b)

Rysunek 7. (a) Prosta rozdzielająca klasy za pomocą LDA.  
 (b) Krzywe rozdzielające klasy za pomocą QDA.

*Źródło: opracowanie własne*

## Literatura

- [1] R.A. Fisher, *The Use of Multiple Measurements in Taxonomic Problems*, *Annals of Eugenics* 7 (2): 179–188, (1936)
- [2] C.M. Bishop, *Pattern Recognition and Machine Learning*, Springer Series: Information Science and Statistics (2006)
- [3] J. Koronacki, J. Ćwik, *Statystyczne systemy uczące się*, WNT, Warszawa (2005)
- [4] A.R. Webb, K.D. Copsey, *Statistical Pattern Recognition*, 3rd ed., Wiley, (2011)
- [5] W. Malina, M. Smiatacz, *Rozpoznawanie obrazów*, Exit, Warszawa, (2011)