

Pattern Classification

All materials in these slides were taken from *Pattern Classification (2nd ed)* by R. O. Duda, P. E. Hart and D. G. Stork, John Wiley & Sons, 2000 with the permission of the authors and the publisher

Chapter 5:

Liniowe funkcje dyskryminujące (Sections 5.1-5-3)

- Wprowadzenie
- Liniowe funkcje dyskryminujące i powierzchnie decyzyjne
- Funkcje dyskryminujące liniowe ze względu na parametry

Wprowadzenie

- Poprzednio zakładaliśmy znajomość rozkładów prawdopodobieństwa
- Obserwacje z ciągu uczącego były użyte do estymacji parametrów tych rozkładów (metoda największej wiarygodności, maksimum a'posteriori)
- Teraz zakładamy znajomość jedynie postaci funkcji dyskryminujących, podobnie jak w technikach nieparametrycznych
- Liniowe funkcje dyskryminujące są bardzo wygodne do obliczeń

Liniowe funkcje dyskryminujące i powierzchnie decyzyjne

- Definicja

Liniowa funkcja decyzyjna to taka, która jest liniową kombinacją o postaci:

$$g(x) = w^T x + w_0 \quad (1)$$

gdzie w jest wektorem współczynników wagowych a w_0 nazywamy progim

- Klasyfikator binarny (rozpoznający dwie klasy) z funkcją dyskryminującą o postaci (1) korzysta z reguły decyzyjnej:
Wybierz ω_1 jeżeli $g(x) > 0$ i ω_2 jeżeli $g(x) < 0$
 \Leftrightarrow Wybierz ω_1 jeżeli $w^T x > -w_0$ i ω_2 w przeciwnym przyp.
Jeżeli $g(x) = 0 \Rightarrow$ wynik rozpoznawania jest nieokreślony

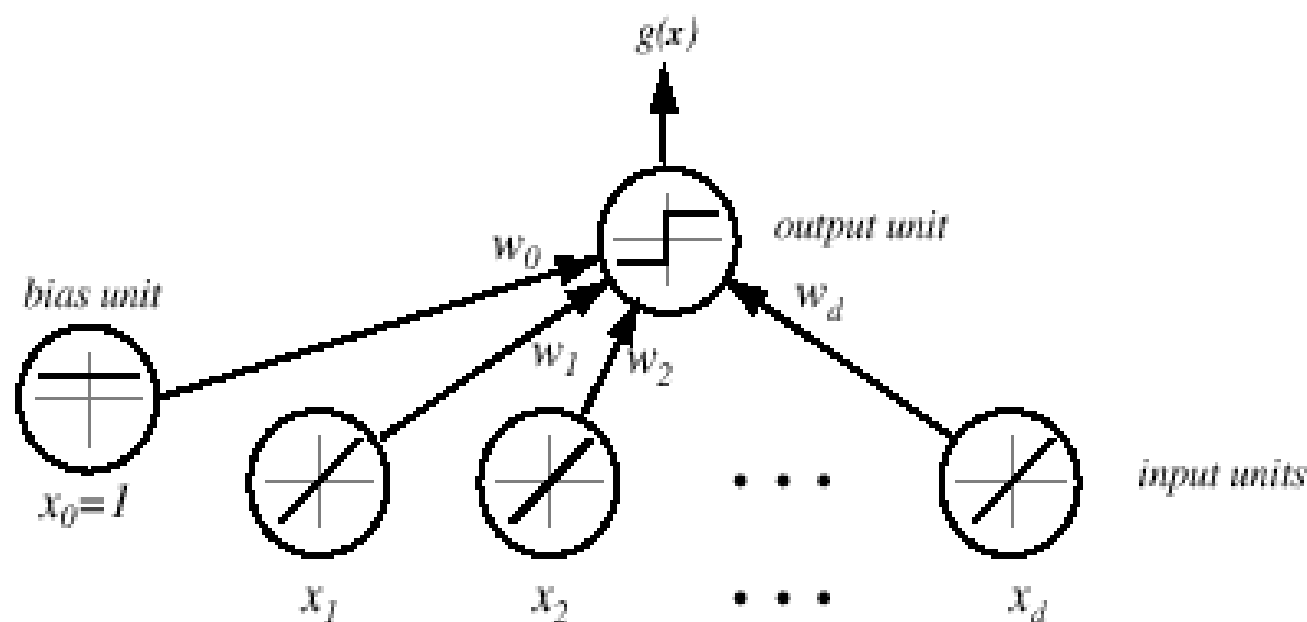


FIGURE 5.1. A simple linear classifier having d input units, each corresponding to the values of the components of an input vector. Each input feature value x_i is multiplied by its corresponding weight w_i ; the effective input at the output unit is the sum all these products, $\sum w_i x_i$. We show in each unit its effective input-output function. Thus each of the d input units is linear, emitting exactly the value of its corresponding feature value. The single bias unit unit always emits the constant value 1.0. The single output unit emits a +1 if $\mathbf{w}'\mathbf{x} + w_0 > 0$ or a -1 otherwise. From: Richard O. Duda, Peter E. Hart, and David G. Stork, *Pattern Classification*. Copyright © 2001 by John Wiley & Sons, Inc.

- Równanie $g(x) = 0$ definiuje **powierzchnię decyzyjną** separującą punkty należące do klasy ω_1 od punktów należących do klasy ω_2
- Dla liniowej funkcji $g(x)$ powierzchnia decyzyjna to hiperpowierzchnia
- Funkcja dyskryminująca $g(x)$ daje miarę odległości x od hiperpowierzchni




FIGURE 5.2. The linear decision boundary H , where $g(\mathbf{x}) = \mathbf{w}^T \mathbf{x} + w_0 = 0$, separates the feature space into two half-spaces \mathcal{R}_1 (where $g(\mathbf{x}) > 0$) and \mathcal{R}_2 (where $g(\mathbf{x}) < 0$). From: Richard O. Duda, Peter E. Hart, and David G. Stork, *Pattern Classification*. Copyright © 2001 by John Wiley & Sons, Inc.

$$x = x_p + \frac{r\mathbf{w}}{\|\mathbf{w}\|} \quad (\text{poniewa\u017c wektor } \mathbf{w} \text{ jest wsp\u00f3lniowy}$$

z wektorem $\mathbf{x} - \mathbf{x}_p$ oraz $\frac{\mathbf{w}}{\|\mathbf{w}\|} = 1$)

Poniewa\u017c $g(\mathbf{x}) = 0$ i $\mathbf{w}^T \mathbf{w} = \|\mathbf{w}\|^2$ to $r = \frac{g(\mathbf{x})}{\|\mathbf{w}\|}$

W szczególno\u015bci $d(\mathbf{0}, H) = \frac{\mathbf{w}_0}{\|\mathbf{w}\|}$

- Liniowa funkcja dyskryminuj\u0105ca dzieli przestrze\u0144 cech hiperpowierzchni\u0105 decyzyjn\u0105
- Orientacj\u0119 tej powierzchni wyznacza wektor normalny w a jej po\u0142o\u017cenie zale\u017cy od progu

• Przypadek wielu klas

- Definiujemy c liniowych funkcji dyskryminujących

$$g_i(\mathbf{x}) = \mathbf{w}_i^T \mathbf{x} + w_{i0} \quad i = 1, \dots, c$$

i przypisujemy x do klasy ω_i jeżeli $g_i(x) > g_j(x) \quad \forall j \neq i$;

- Taki klasyfikator nazywamy „maszyną liniową”
- Maszyna liniowa dzieli przestrzeń cech na c obszarów decyzyjnych, przy czym $g_i(x)$ przyjmuje wartość największą dla x należącego do obszaru R_i
- Dla dwóch przyległych obszarów R_i, R_j , granica między nimi jest fragmentem hiperpłaszczyzny H_{ij} zdefiniowanej jako:

$$g_i(x) = g_j(x)$$

$$\Leftrightarrow (w_i - w_j)^T x + (w_{i0} - w_{j0}) = 0$$

- $w_i - w_j$ jest normalny do H_{ij}

$$d(\mathbf{x}, H_{ij}) = \frac{g_i - g_j}{\|\mathbf{w}_i - \mathbf{w}_j\|}$$




FIGURE 5.4. Decision boundaries produced by a linear machine for a three-class problem and a five-class problem. From: Richard O. Duda, Peter E. Hart, and David G. Stork, *Pattern Classification*. Copyright © 2001 by John Wiley & Sons, Inc.

- Można łatwo pokazać, że obszary decyzyjne generowane przez maszynę liniową są wypukłe. Nakłada to pewne ograniczenie na elastyczność i dokładność klasyfikatora

Funkcje dyskryminujące liniowe ze względu na parametry

- Granice obszarów decyzyjnych na ogół nie są liniowe
- Złożony kształt granic obszarów decyzyjnych wymaga użycia silnie nieliniowych funkcji
- Najczęściej rozważana jest ogólniejsza postać liniowych funkcji dyskryminujących:

$$g(x) = w_1 f_1(x) + w_2 f_2(x) + \dots + w_N f_N(x) + w_{N+1} \quad (1)$$

gdzie $f_i(x)$, $1 \leq i \leq N$ są jednowymiarowymi funkcjami wektora x ,

$x \in R^n$ (przestrzeń euklidesowa)

- Wstawiając $f_{n+1}(\mathbf{x}) = 1$, otrzymujemy:

$$g(x) = \sum_{i=1}^{N+1} w_i f_i(\mathbf{x}) = \mathbf{w}^T \dot{\mathbf{x}}$$

$$\text{gdzie } \mathbf{w} = (w_1, w_2, \dots, w_N, w_{N+1})^T \text{ i } \dot{\mathbf{x}} = (f_1(\mathbf{x}), f_2(\mathbf{x}), \dots, f_N(\mathbf{x}), f_{N+1}(\mathbf{x}))^T$$

- Ten zapis funkcji $g(x)$ wskazuje na fakt, że każda funkcja dyskryminująca postaci (1) może być traktowana jako liniowa w $(N + 1)$ – wymiarowej przestrzeni ($N + 1 > n$)
- $g(x)$ maintains its non-linearity characteristics in R^n

- Często wyborem funkcji $g(\mathbf{x})$, dla których $f_i(\mathbf{x})$ ($1 \leq i \leq N$) są wielomiany

$$g(\mathbf{x}) = (\mathbf{w})^T \dot{\mathbf{x}}$$

gdzie $\dot{\mathbf{w}}$ jest nowym wektorem parametrów wagowych wyznaczonym na podstawie oryginalnego wektora \mathbf{w} oraz $f_i(\mathbf{x})$, $1 \leq i \leq N$

- Kwadratowe funkcje dyskryminujące dla 2-wymiarowej przestrzeni cech:

$$g(\mathbf{x}) = w_1 x_1^2 + w_2 x_1 x_2 + w_3 x_2^2 + w_4 x_1 + w_5 x_2 + w_6,$$

$$\mathbf{w} = (w_1, w_2, \dots, w_6)^T \text{ i } \dot{\mathbf{x}} = (x_1^2, x_1 x_2, x_2^2, x_1, x_2, 1)^T$$

- Dla obrazów $\mathbf{x} \in R^n$, najogólniejsza postać kwadratowych funkcji dyskryminujących jest następująca:

$$g(\mathbf{x}) = \sum_{i=1}^n w_{ii} x_i^2 + \sum_{i=1}^{n-1} \sum_{j=i+1}^n w_{ij} x_i x_j + \sum_{i=1}^n w_i x_i + w_{n+1} \quad (2)$$

Liczba elementów po prawej stronie wyrażenia jest równa:

$$l = N + 1 = n + \frac{n(n-1)}{2} + n + 1 = \frac{(n+1)(n+2)}{2}$$

Jest to całkowita liczba swobodnych parametrów wagowych, przykładowo:

- Dla $n = 3$, wektor $\dot{\mathbf{x}}$ ma 10 wymiarów
- Dla $n = 10$, wektor $\dot{\mathbf{x}}$ ma 65 wymiarów

- W przypadku funkcji dyskryminujących będących wielomianami m -tego rzędu, typowa $f_i(\mathbf{x})$ ma postać:

$$f_i(\mathbf{x}) = x_{i_1}^{e_1} x_{i_2}^{e_2} \dots x_{i_m}^{e_m}$$

gdzie $1 \leq i_1, i_2, \dots, i_m \leq n$ oraz $e_i, 1 \leq i \leq m$ to 0 lub 1.

- Jest to wielomian, którego rząd jest z przedziału od 0 do m . Aby uniknąć powtórzeń wymagamy, aby $i_1 \leq i_2 \leq \dots \leq i_m$

$$g^m(\mathbf{x}) = \sum_{i_1=1}^n \sum_{i_2=i_1}^n \dots \sum_{i_m=i_{m-1}}^n w_{i_1 i_2 \dots i_m} x_{i_1} x_{i_2} \dots x_{i_m} + g^{m-1}(\mathbf{x})$$

(gdzie $g^0(\mathbf{x}) = w_{n+1}$) jest najogólniejszą funkcją dyskryminującą w postaci wielomianu rzędu m

Przykład 1: Niech $n = 3$ i $m = 2$, to wówczas:

$$\begin{aligned}
 g^2(\mathbf{x}) &= \sum_{i_1=1}^3 \sum_{i_2=i_1}^3 w_{i_1 i_2} x_{i_1} x_{i_2} + w_1 x_1 + w_2 x_2 + w_3 x_3 + w_4 \\
 &= w_{11} x_1^2 + w_{12} x_1 x_2 + w_{13} x_1 x_3 + w_{22} x_2^2 + w_{23} x_2 x_3 + w_{33} x_3^2 \\
 &\quad + w_1 x_1 + w_2 x_2 + w_3 x_3 + w_4
 \end{aligned}$$

Przykład 2: Niech $n = 2$ i $m = 3$, to wówczas:

$$\begin{aligned}
 g^3(\mathbf{x}) &= \sum_{i_1=1}^2 \sum_{i_2=i_1}^2 \sum_{i_3=i_2}^2 w_{i_1 i_2 i_3} x_{i_1} x_{i_2} x_{i_3} + g^2(\mathbf{x}) \\
 &= w_{111} x_1^3 + w_{112} x_1^2 x_2 + w_{122} x_1 x_2^2 + w_{222} x_2^3 + g^2(x)
 \end{aligned}$$

gdzie $g^2(\mathbf{x}) = \sum_{i_1=1}^2 \sum_{i_2=i_1}^2 w_{i_1 i_2} x_{i_1} x_{i_2} + g^1(\mathbf{x})$

$$= w_{11} x_1^2 + w_{12} x_1 x_2 + w_{22} x_2^2 + w_1 x_1 + w_2 x_2 + w_3$$

- Najczęściej używaną kwadratową funkcją dyskryminującą można reprezentować jako n-wymiarową powierzchnię kwadratową :

$$g(x) = x^T A x + x^T b + c$$

gdzie macierz $A = (a_{ij})$, wektor $b = (b_1, b_2, \dots, b_n)^T$ i c , zależą od wag w_{ij} , w_{ij} , w_i z równania (2)

- Jeżeli A jest dodatnio określona to funkcja dyskryminująca jest hiperelipsoidą z osiami skierowanymi w kierunkach zgodnych z wektorami własnymi macierzy A
 - W szczególności: jeżeli $A = I_n$ (macierz jednostkowa), to funkcja dyskryminująca jest n-wymiarową hipersferą

- Jeżeli A jest ujemnie określona, to funkcja dyskryminująca opisuje hiperhiperboloidę
- Wniosek: macierz A w pełni determinuje kształt i charakterystykę funkcji dyskryminującej

Przykładowy problem: Rozważmy 3-wymiarową przestrzeń i funkcję dyskryminującą w postaci wielomianu trzeciego rzędu

1. Ile elementów zawiera wyrażenie reprezentujące funkcję dyskryminującą jeżeli tylko sześcienna i liniowa funkcja wchodzi w skład wyrażenia?
2. Przedstaw ogólne wyrażenie opisujące funkcję dyskryminującą w postaci wielomianu 4-tego rzędu dla 2-wymiarowej przestrzeni obrazów
3. Niech \mathbb{R}^3 będzie oryginalną przestrzenią obrazów a funkcja dyskryminująca związana z klasami ω_1 i ω_2 ma postać:

$$g(\mathbf{x}) = 2x_1^2 + x_3^2 + x_2x_3 + 4x_1 - 2x_2 + 1$$

dla której $g(x) > 0$ jeżeli $x \in \omega_1$ i $g(x) < 0$ jeżeli $x \in \omega_2$

- a) Zapisz $g(x)$ jako $g(x) = \mathbf{x}^T A \mathbf{x} + \mathbf{x}^T \mathbf{b} + c$
- b) Wyznacz klasy następujących obrazów:
 $(1, 1, 1), (1, 10, 0), (0, 1/2, 0)$

- Macierze dodatnio określone

1. Kwadratowa macierz A jest *dodatnio określona* jeżeli $x^T A x > 0$ dla wszystkich niezerowych wektorów kolumnowych x .
2. Kwadratowa macierz A jest *ujemnie określona* jeżeli $x^T A x < 0$ dla wszystkich niezerowych x .
3. Kwadratowa macierz A jest *dodatnio pół-określona* jeżeli $x^T A x \geq 0$.
4. Kwadratowa macierz A jest *ujemnie pół-określona* jeżeli $x^T A x \leq 0$ dla wszystkich x .

Powyższe warunki trudno jest sprawdzać bezpośrednio na podstawie definicji. W praktyce potrzebne są warunki mniej wymagające obliczeniowo.

Bardziej przydatne w praktyce są następujące własności, zachodzące wówczas gdy macierz A jest symetryczna.

i-ty *minor główny* macierzy A to macierz A_i utworzona z i pierwszych wierszy i kolumn macierzy A . Np., pierwszy główny minor macierzy A jest macierzą $A_1 = (a_{11})$, drugi minor główny jest macierzą:

$$\mathbf{A}_2 = \begin{pmatrix} a_{11} & a_{12} \\ a_{21} & a_{22} \end{pmatrix}$$

i tak dalej...

- Macierz A jest dodatnio określona jeżeli wszystkie jej główne minory A_1, A_2, \dots, A_n mają wyznaczniki większe od zera
- Jeżeli te wyznaczniki są niezerowe a znaki kolejnych wyznaczników mają przeciwne znaki, począwszy od $\det(A_1) < 0$, to macierz A jest ujemnie określona
- Jeżeli wszystkie te wyznaczniki są nieujemne, to macierz jest dodatnio pół-określona
- Jeżeli znaki kolejnych wyznaczników mają przeciwne znaki, począwszy od $\det(A_1) \leq 0$, to macierz jest ujemnie pół-określona

Dla przykładu, rozważmy macierz symetryczną o wymiarach 2x2:

$$\mathbf{A} = \begin{pmatrix} a_{11} & a_{12} \\ a_{21} & a_{22} \end{pmatrix}$$

- Macierz jest dodatnio określona, jeżeli:
 - a) $\det(A_1) = a_{11} > 0$
 - b) $\det(A_2) = a_{11}a_{22} - a_{12}a_{12} > 0$

- Macierz jest ujemnie określona, jeżeli:
 - a) $\det(A_1) = a_{11} < 0$
 - b) $\det(A_2) = a_{11}a_{22} - a_{12}a_{12} > 0$

- Macierz jest dodatnio pół-określona, jeżeli:
 - a) $\det(A_1) = a_{11} \geq 0$
 - b) $\det(A_2) = a_{11}a_{22} - a_{12}a_{12} \geq 0$

- Macierz jest ujemnie pół-określona, jeżeli:
 - a) $\det(A_1) = a_{11} \leq 0$
 - b) $\det(A_2) = a_{11}a_{22} - a_{12}a_{12} \geq 0$.

Ćwiczenie 1: Sprawdź, czy poniższe macierze są dodatnio-, ujemnie- określone, dodatnio-, ujemnie- pół-określone lub nie należą do żadnej z tych grup.

$$(a) \mathbf{A} = \begin{pmatrix} 2 & 1 \\ 1 & 4 \end{pmatrix}$$

$$(b) \mathbf{A} = \begin{pmatrix} -2 & 4 \\ 4 & -8 \end{pmatrix}$$

$$(c) \mathbf{A} = \begin{pmatrix} -2 & 2 \\ 2 & -4 \end{pmatrix}$$

$$(d) \mathbf{A} = \begin{pmatrix} 2 & 4 \\ 4 & 3 \end{pmatrix}$$

Rozwiązania ćwiczenia 1:

- $A_1 = 2 > 0$
 $A_2 = 8 - 1 = 7 > 0$ \Rightarrow A jest dodatnio określona
positive definite
- $A_1 = -2$
 $A_2 = (-2 \times -8) - 16 = 0$ \Rightarrow A jest ujemnie pół-określona
- $A_1 = -2$
 $A_2 = 8 - 4 = 4 > 0$ \Rightarrow A jest ujemnie określona
- $A_1 = 2 > 0$
 $A_2 = 6 - 16 = -10 < 0$ \Rightarrow A nie należy do żadnej z grup

Ćwiczenie 2:

Niech $\mathbf{A} = \begin{pmatrix} 2 & 1 \\ 1 & 4 \end{pmatrix}$

1. Wyznacz granice obszarów decyzyjnych odpowiadających macierzy A ($g(x) = x^T A x + x^T b + c$) w przypadku, gdy $b^T = (1, 2)$ i $c = -3$
2. Rozwiąż $\det(A - \lambda I) = 0$ i określ kształt i charakterystykę granicy obszarów decyzyjnych oddzielających dwie klasy ω_1 i ω_2
3. Przypisz klasy następującym punktom:
 - $x^T = (0, -1)$
 - $x^T = (1, 1)$

Rozwiązanie ćwiczenia 2:

1.

$$\begin{aligned}
 g(\mathbf{x}) &= (x_1, x_2) \begin{pmatrix} 2 & 1 \\ 1 & 4 \end{pmatrix} \begin{pmatrix} x_1 \\ x_2 \end{pmatrix} + (x_1, x_2) \begin{pmatrix} 1 \\ 2 \end{pmatrix} - 3 \\
 &= (2x_1 + x_2, x_1 + 4x_2) \begin{pmatrix} x_1 \\ x_2 \end{pmatrix} + x_1 + 2x_2 - 3 \\
 &= 2x_1^2 + x_1x_2 + x_1x_2 + 4x_2^2 + x_1 + 2x_2 - 3 \\
 &= 2x_1^2 + 4x_2^2 + 2x_1x_2 + x_1 + 2x_2 - 3
 \end{aligned}$$

2.

Dla $\lambda_1 = 3 + \sqrt{2}$ oraz $\begin{pmatrix} 2- & 1 \\ 1 & 4-\lambda \end{pmatrix} \begin{pmatrix} x_1 \\ x_2 \end{pmatrix} = 0$, otrzymujemy:

$$\begin{cases} (-1-\sqrt{2})x_1 + x_2 = 0 \\ x_1 + (1-\sqrt{2})x_2 = 0 \end{cases} \Leftrightarrow (-1-\sqrt{2})x_1 + x_2 = 0$$

Ostatnie równanie opisuje linię prostą współliniową z wektorem:

$$\vec{V}_1 = (1, 1 + \sqrt{2})^T$$

Dla $\lambda_2 = 3 + \sqrt{2}$ oraz $\begin{pmatrix} 2-\lambda & 1 \\ 1 & 4-\lambda \end{pmatrix} \begin{pmatrix} x_1 \\ x_2 \end{pmatrix} = 0$, otrzymujemy:

$$\begin{cases} (\sqrt{2}-1)x_1 + x_2 = 0 \\ x_1 + (1+\sqrt{2})x_2 = 0 \end{cases} \Leftrightarrow (\sqrt{2}-1)x_1 + x_2 = 0$$

Ostatnie równanie opisuje linię prostą współliniową z wektorem:

$$\vec{V}_2 = (1, 1 - \sqrt{2})^T$$

Elipsa będąca granicą obszarów decyzyjnych ma dwie osie współliniowe odpowiednio z wektorami V_1 i V_2

3. $X = (0, -1)^T \Rightarrow g(0, -1) = -1 < 0 \Rightarrow x \in \omega_2$

$$X = (1, 1)^T \Rightarrow g(1, 1) = 8 > 0 \Rightarrow x \in \omega_1$$