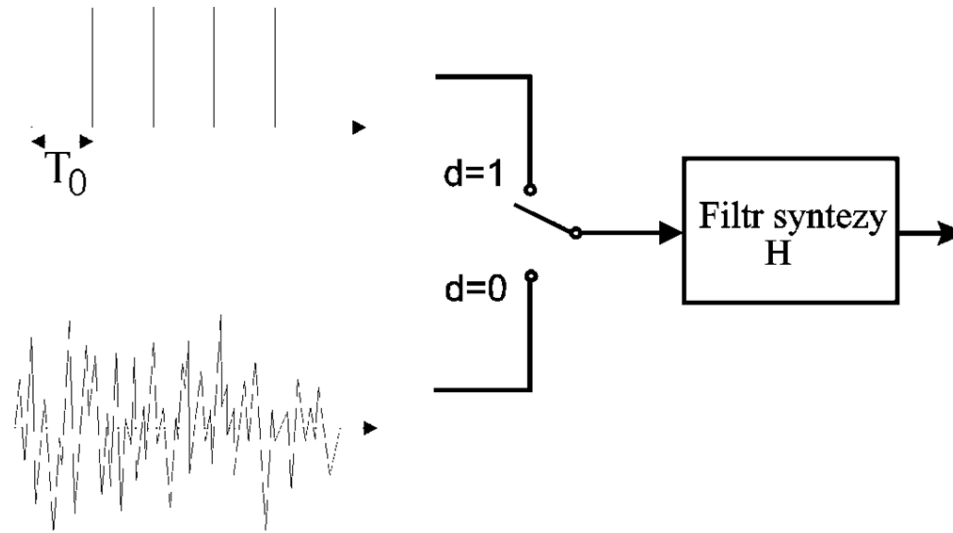


# Przykład: rozpoznawanie mowy dźwięcznej i bezdźwięcznej w wokoderze

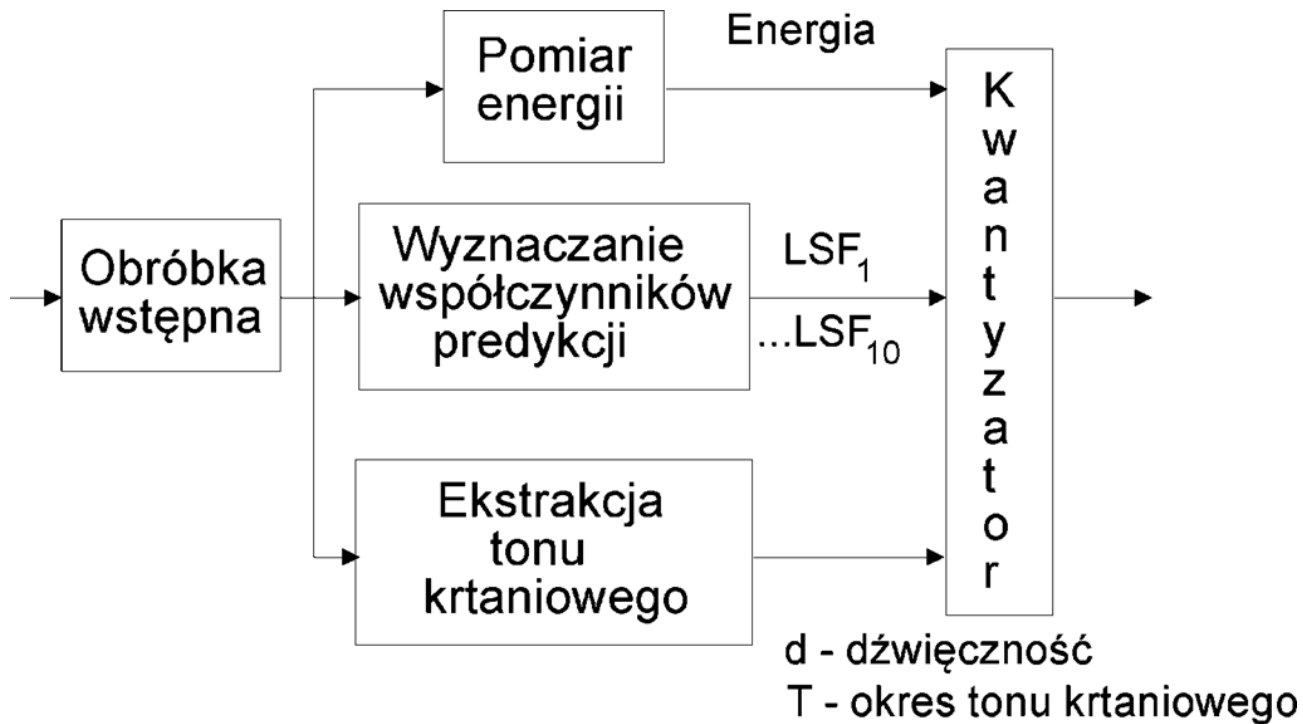


Synteza mowy w odbiorniku wokodera:

$d=1$  - mowa dźwięczna ( $T_0$  = okres tonu krtaniowego)


$d=0$  - mowa bezdźwięczna

# Wokoder – nadajnik



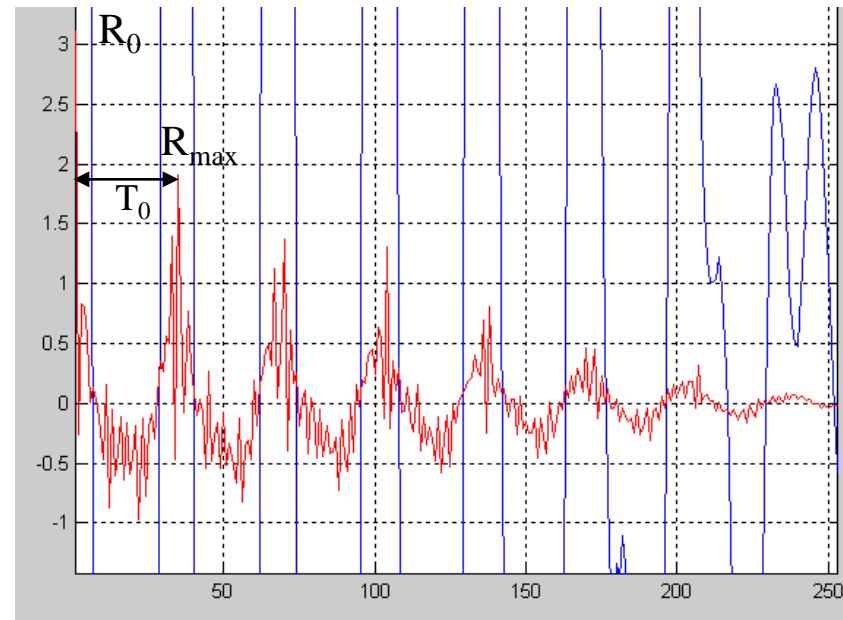
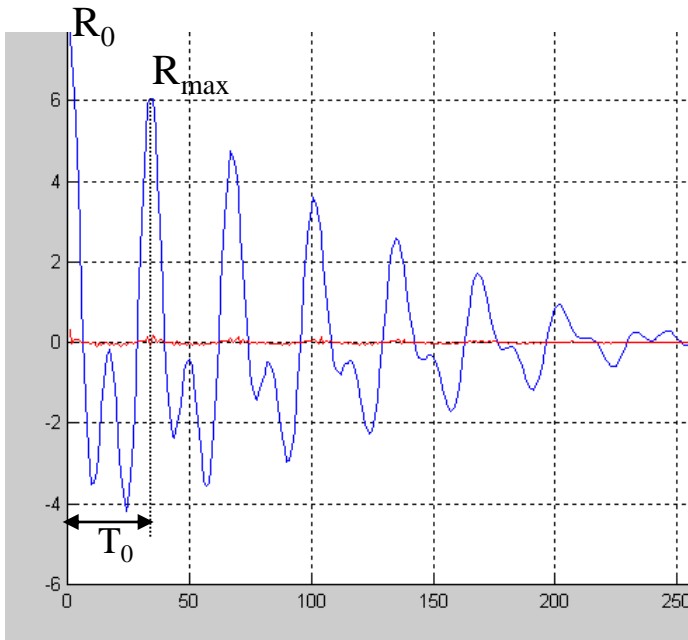
# Ekstrakcja tonu krtaniowego

## 1. Przebieg czasowy sygnału i błędu predykcji



Mowa dźwięczna:  $T_0$  = okres tonu krtaniowego

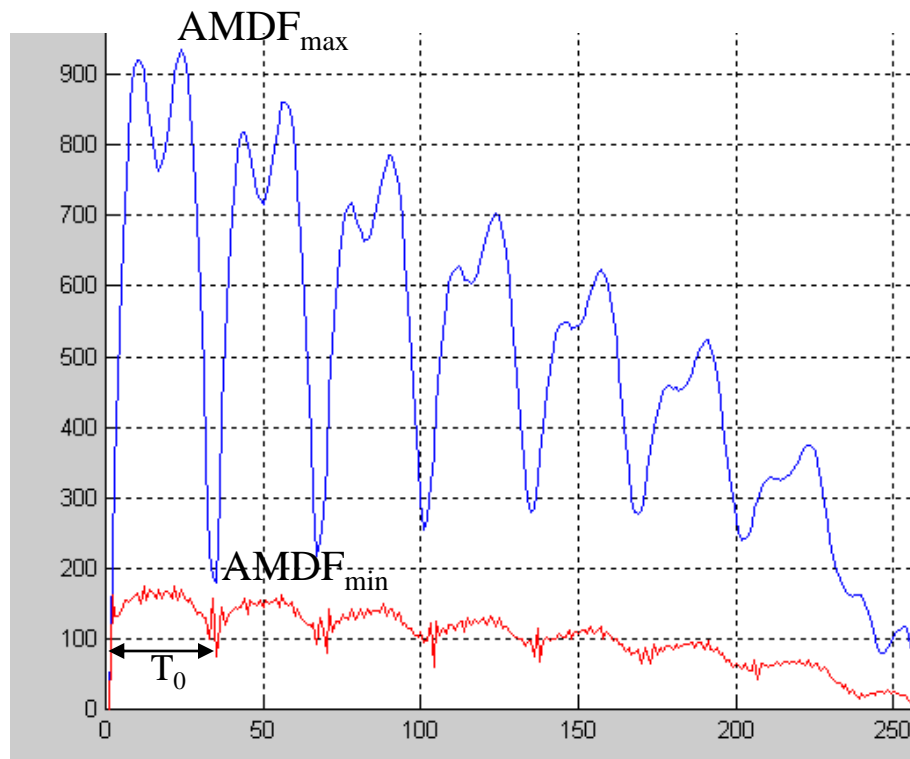
## 2. Autokorelacja fragmentu sygnału i błędu predykcji



$R_{\max}$  – maksimum autokorelacji w zakresie 2 – 20 ms  
gdy  $R_{\max} / R_0 > \text{progu}$  -> mowa dźwięczna

### 3. AMDF (average magnitude difference function)


$$\text{AMDF}_k = \sum_i |x_i - x_{i-k}|$$




$\text{AMDF}_{\min}$  – w zakresie 2 – 20 ms

gdy  $\text{AMDF}_{\max} / \text{AMDF}_{\min} > \text{progu}$   $\rightarrow$  mowa dźwięczna

## 4. Widmo sygnału i błędu predykcji



skala liniowa




skala logarytmiczna (dB)

$F_0=1/T_0$  – częstotliwość tonu krtaniowego

## 5. Cepstrum sygnału i błędu predykcji


$$\text{cepstrum} = \text{IDFT} (\log (\text{abs}(\text{DFT}(\text{sygnał}))))$$




Widmo amplitudy jest funkcją parzystą (na poprzednim slajdzie pokazano jedynie jego prawostronną część), więc IDFT (a także DFT) zlogarytmowanego widma amplitudy można interpretować jako rozkład w szereg cosinusów. Z tego względu zamiast IDFT lub DFT można wykorzystać DCT.

# Klasyfikacja mowa dźwięczna / bezdźwięczna


## Parametry



znormalizowane max. autokorelacji:  $r_{\max} = R_{\max} / R_0$






dolnospasowosc:  $L_{lp} = E_{lp} / E_{sig}$




predykcynosc:  $L_{res} = E_{res} / E_{sig}$

O Ś






# DYSKRYMINATOR PROGOWY i DYSKRYMINATOR LINIOWY

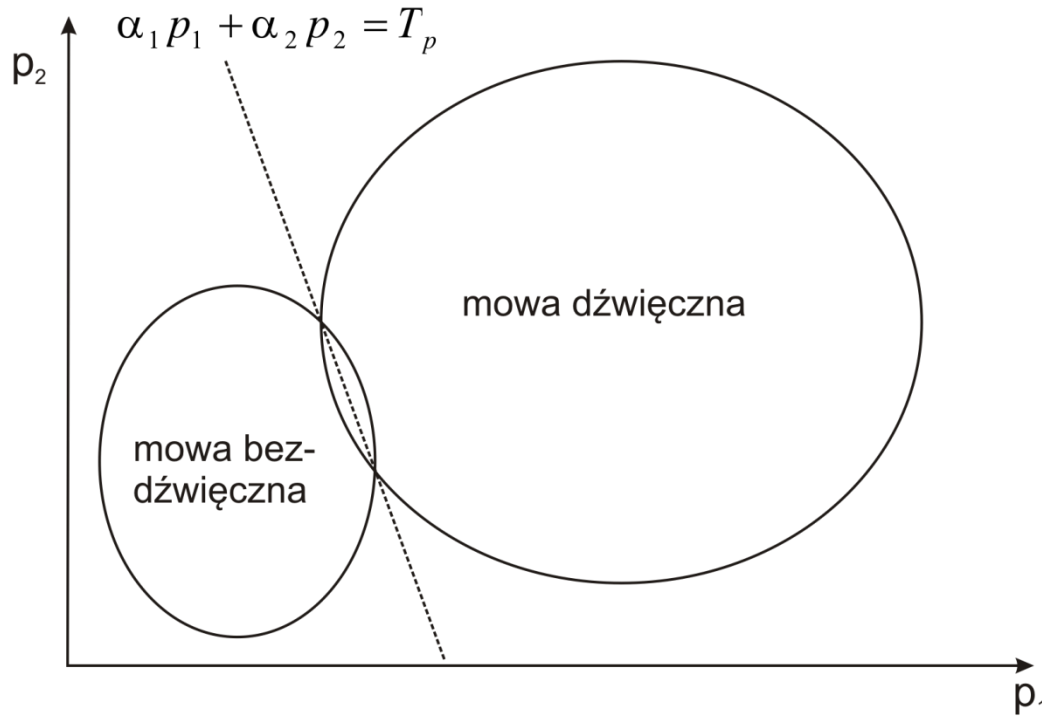


(a)



(b)

# Dyskryminator mowa dźwięczna/bezdźwięczna wykorzystujący kilka parametrów




$p_1$  to np.  $\text{AMDF}_{\max}/\text{AMDF}_{\min}$

$p_2$  to np.  $R_{\max}/R_0$

Dyskryminator liniowy:

Gdy  $\alpha_1 p_1 + \alpha_2 p_2 > T_p \rightarrow$  mowa dźwięczna

# DYSKRYMINATOR LINIOWY



$$y = \alpha^t \mathbf{p} = \sum_{i=1}^N \alpha_i p_i \quad - \text{funkcja dyskryminująca,} \quad T_p - \text{próg}$$

$$\mathbf{p} = [p_1, p_2, \dots, p_N]^t \quad - \text{wektor parametrów}$$

# MET. FISHERA OBLICZANIA DYSKRYMINATORA LINIOWEGO

Dla sekwencji treningowej oblicza się dla obu klas:

wartości średnie wektora parametrów

$$\mathbf{m}_1 = \frac{1}{n_1} \sum_{\mathbf{p}^j \in C_1} \mathbf{p}^j$$

$$\mathbf{m}_2 = \frac{1}{n_2} \sum_{\mathbf{p}^j \in C_2} \mathbf{p}^j$$

macierze kowariancji

$$\bar{\mathbf{C}}_1 = \frac{1}{n_1} \sum_{\mathbf{p}^j \in C_1} (\mathbf{p}^j - \mathbf{m}_1) (\mathbf{p}^j - \mathbf{m}_1)^t$$

$$\bar{\mathbf{C}}_2 = \frac{1}{n_2} \sum_{\mathbf{p}^j \in C_2} (\mathbf{p}^j - \mathbf{m}_2) (\mathbf{p}^j - \mathbf{m}_2)^t$$

## Dyskryminator Fishera, c.d.

$$\bar{C} = \frac{1}{2}[\bar{C}_1 + \bar{C}_2]$$

$$\alpha = \bar{C}^{-1}[m_2 - m_1]$$

Próg  $T_p$  dla funkcji dyskryminującej wybiera się eksperymentalnie między  $\alpha^t m_1$  i  $\alpha^t m_2$  .

# Dyskryminator Fishera, wyprowadzenie

Wartość funkcji dyskryminującej  $y = \alpha^t p = \sum_{i=1}^N \alpha_i p_i$  jest zmienną losową:

$$E(y) = E[\alpha^t p] = \alpha^t E(p) = \alpha^t m$$

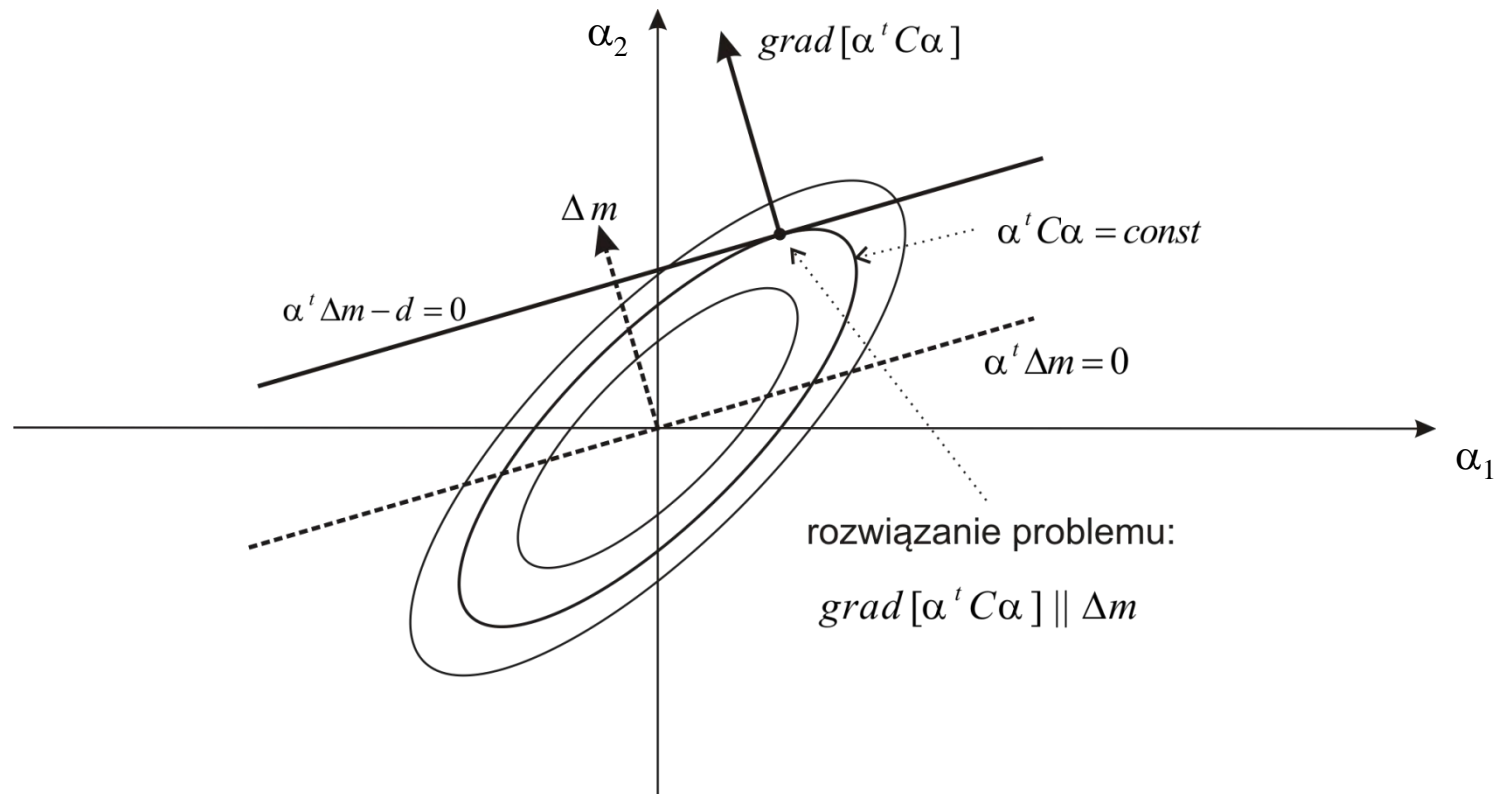
$$\begin{aligned} \sigma^2 &= E(y - \alpha^t m)^2 = E[(\alpha^t p - \alpha^t m)^2] = E[\alpha^t (p - m)]^2 = \\ &= E[\alpha^t (p - m)(p - m)^t \alpha] = \alpha^t E[(p - m)(p - m)^t] \alpha = \alpha^t C \alpha \end{aligned}$$

**Zadanie separacji 2 klas:** min wariancja  $y$  przy stałym odstępnie wartości średnich  
- zakładamy równość wariancji w obu klasach lub podstawiamy  $C = \frac{1}{2}[C_1 + C_2]$


$$\min \sigma^2 = \min \alpha^t C \alpha, \quad \alpha^t m_2 - \alpha^t m_1 = \alpha^t \Delta m = d = const$$

# Dyskryminator Fishera, wyprowadzenie

$$\min \sigma^2 = \min \alpha^t C \alpha, \quad \alpha^t m_2 - \alpha^t m_1 = \alpha^t \Delta m = d = \text{const}$$




$$\text{grad } \alpha^t C \alpha = \frac{\partial}{\partial \alpha} \alpha^t C \alpha = 2C \alpha$$



$$2C \alpha = \lambda \Delta m$$

# Dyskryminator Fishera, wyprowadzenie

$$\min \sigma^2 = \min \alpha^t C \alpha, \quad \alpha^t m_2 - \alpha^t m_1 = \alpha^t \Delta m = d = \text{const}$$



$$2C\alpha = \lambda \Delta m \implies \alpha = C^{-1} \frac{\lambda}{2} \Delta m, \quad \Delta m^t \alpha = \Delta m^t C^{-1} \frac{\lambda}{2} \Delta m = d$$

d możemy wybrać dowolnie, np. tak, aby  $\lambda=2$ . Wówczas  $\alpha$  obliczamy z

$$C\alpha = \Delta m$$



# Metoda mnożników Lagrange'a

Wykorzystaliśmy szczególny przypadek zastosowania metody mnożników Lagrange'a:

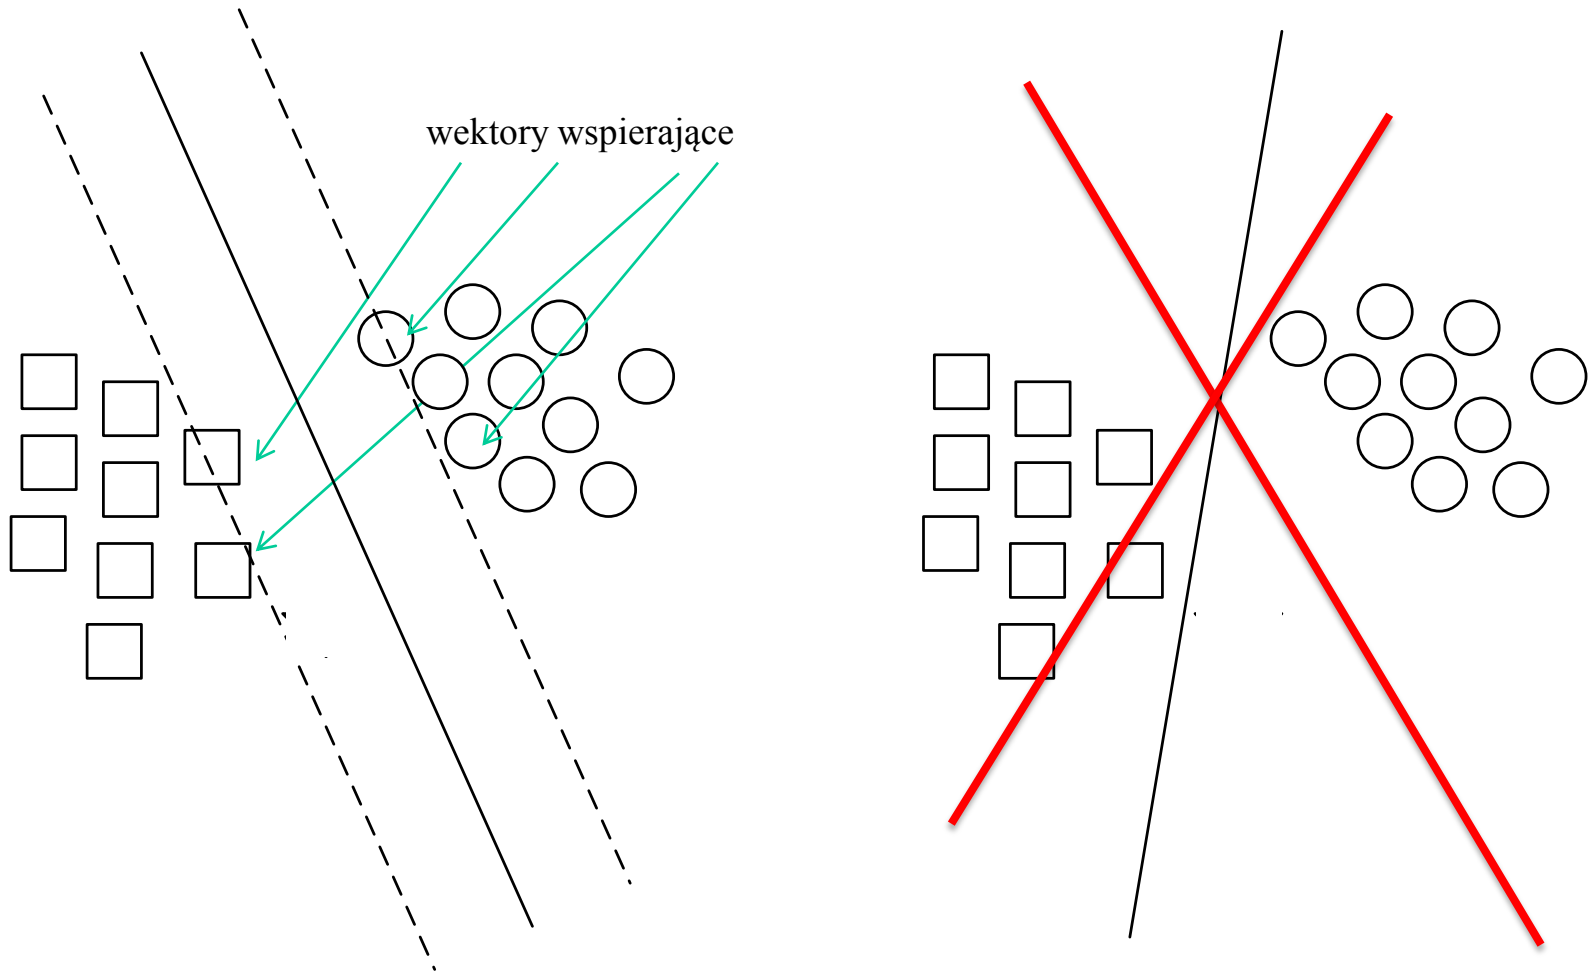
Szukamy minimum  $F(x)$ ,  $x = [x_1, \dots, x_N]$

przy ograniczeniach  $g_1(x) = 0, g_2(x) = 0, \dots, g_M(x) = 0$

Tworzymy funkcję Lagrange'a  $L(x, \lambda) = F(x) + \lambda^t g(x) = F(x) + \lambda_1 g_1(x) + \dots + \lambda_M g_M(x)$ ,


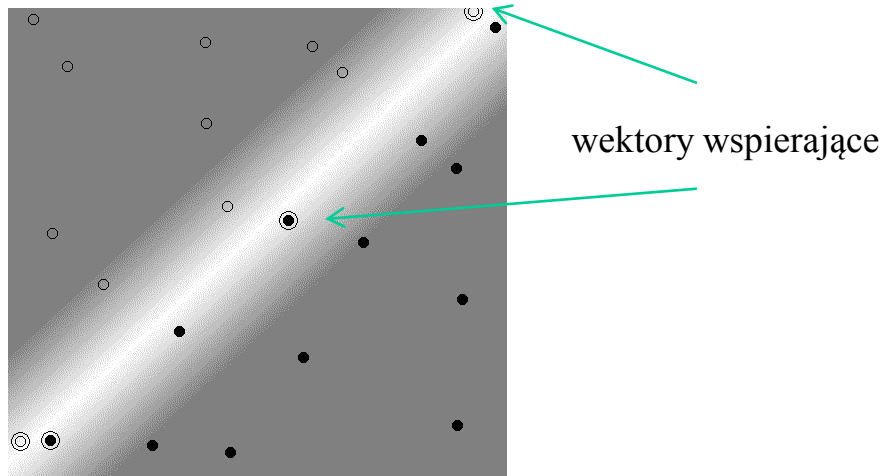
Rozwiązanie:  $\frac{\partial}{\partial x} L(x, \lambda) = 0$   
 $\frac{\partial}{\partial \lambda} L(x, \lambda) = 0$

# SVM\* – wektory wspierające



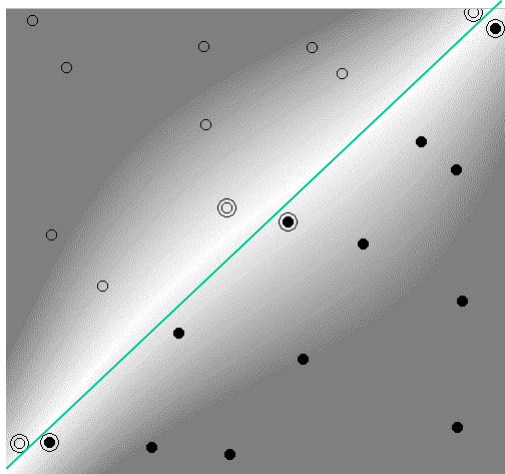
Cel: powiększenie odstęp (margin)

# SVM – wektory wspierające




Cel: powiększenie odstepu (margin)

Klasy liniowo nieseparowalne



  
nieliniowe  
przekształcenie



# O KLASYFIKATORACH NIECO OGÓLNIJ

Założmy że znane są prawdopodobieństwa (lub gęstości prawdopodobieństwa) cech (wektorów parametrów  $\mathbf{x}$ , na poprzednich slajdach oznaczany jako  $\mathbf{p}$ ) dla każdej z klas:

$$f_k(\mathbf{x}), \quad k = 1, \dots, K$$

oraz prawdopodobieństwa a priori pojawienia się każdej z klas:  $P_1, P_2, \dots, P_K$ .

Błędnemu uznaniu  $k$ -tej klasy za  $j$ -tą przypisujemy ryzyko  $r(j|k)$ , np.  $r(j|k) = 0$  gdy  $j=k$ , oraz  $r(j|k)=1$  w pozostałych przypadkach.

Dla określonego klasyfikatora można obliczyć prawdopodobieństwa błędnych decyzji:  $p(j|k)$  i oszacować średnie ryzyko:

$$v = \sum_k \sum_j P_k p(j|k) r(j|k)$$

Klasyfikator projektuje się na minimum  $v$ .

# KLASYFIKATOR BAYESA

Jeśli każdej błędnej decyzji jest przypisane jednakowe ryzyko (np.  $r(j|k) = 0$  gdy  $j=k$ , oraz  $r(j|k)=1$  w pozostałych przypadkach), wówczas klasyfikator, na podstawie obserwacji wektora parametrów  $\mathbf{x}$ , winien wskazać najbardziej prawdopodobną klasę:

$$k = \arg \max_i P(i | \mathbf{x})$$

Ze wzoru Bayesa:

$$P(i | \mathbf{x}) = \frac{P_i f_i(\mathbf{x})}{\sum_{j=1}^K P_j f_j(\mathbf{x})}$$

otrzymuje się następujący klasyfikator:

$$k = \arg \max_i P_i f_i(\mathbf{x})$$

# Kiedy dyskryminator liniowy jest klasyfikatorem Bayesa?

Założenia:

N-wymiarowe rozkłady gaussowskie  $f_i(\mathbf{x}) = \frac{1}{(2\pi)^{N/2} |\mathbf{C}_i|^{1/2}} \exp[-\frac{1}{2}(\mathbf{x} - \mathbf{m}_i)^t \mathbf{C}_i^{-1}(\mathbf{x} - \mathbf{m}_i)]$

Te same macierze kowariancji dla wszystkich klas  $\mathbf{C}_i = \mathbf{C}, \quad \forall i$

Optymalny klasyfikator jest (przy w/w założeniach) liniowy:

$$\begin{aligned} k &= \arg \max_i P_i f_i(\mathbf{x}) = \arg \max_i \ln(P_i f_i(\mathbf{x})) = \\ &= \arg \max_i \left( -\ln((2\pi)^{N/2} |\mathbf{C}|^{1/2}) - \frac{1}{2}(\mathbf{x} - \mathbf{m}_i)^t \mathbf{C}^{-1}(\mathbf{x} - \mathbf{m}_i) + \ln(P_i) \right) = \\ &= \arg \max_i \left( -\frac{1}{2}(\mathbf{x} - \mathbf{m}_i)^t \mathbf{C}^{-1}(\mathbf{x} - \mathbf{m}_i) + \ln(P_i) \right) \end{aligned}$$


# Kiedy dyskryminator liniowy jest klasyfikatorem Bayesa?

Funkcja dyskryminująca

$$\begin{aligned}\delta_i(\mathbf{x}) &= -\frac{1}{2}(\mathbf{x} - \mathbf{m}_i)^t \mathbf{C}^{-1}(\mathbf{x} - \mathbf{m}_i) + \ln(P_i) = \\ &= \underbrace{\mathbf{x}^t \mathbf{C}^{-1} \mathbf{m}_i - \frac{1}{2} \mathbf{m}_i^t \mathbf{C}^{-1} \mathbf{m}_i}_{\text{funkcja liniowa}} - \frac{1}{2} \underbrace{\mathbf{x}^t \mathbf{C}^{-1} \mathbf{x}}_{\text{można pominąć, bo nie zależy od klasy } i} + \ln(P_i)\end{aligned}$$

Granica między klasą k i j:

$$\mathbf{x}: \quad \delta_k(\mathbf{x}) = \delta_j(\mathbf{x})$$



# Dyskryminator kwadratowy


W każdej klasie inna funkcja kowariancji  $\mathbf{C}_i$

Funkcja dyskryminująca nie jest liniowa (jest kwadratowa)

$$\delta_i(\mathbf{x}) = -\ln(|\mathbf{C}_i|^{1/2}) - \frac{1}{2}(\mathbf{x} - \mathbf{m}_i)^t \mathbf{C}_i^{-1}(\mathbf{x} - \mathbf{m}_i) + \ln(P_i)$$


Klasyfikacja:

$$k = \arg \max_i \delta_i(\mathbf{x})$$





# Dyskryminatory - porównanie



## Błąd w bazie i w teście

$$R(\alpha) \leq R_{emp}(\alpha) + \sqrt{\left( \frac{h(\log(2l/h) + 1) - \log(\eta/4)}{l} \right)}$$

Błąd w teście      Błąd w bazie      wielkość bazy       $1-\eta$ : prawdopodobieństwo, że nierówność jest spełniona

parametry obliczone w bazie


$h$  – **VC dimension** (Vapnik, Czerwonienkis)

**VC dim** jest miarą złożoności dyskryminatora, ma związek z liczbą parametrów



# Jak obliczyć VC – dimension?

Jest to największa liczba obserwacji, którą klasyfikator jest zdolny bezbłędnie porozdzielać

Np. klasyfikator liniowy na płaszczyźnie (2 parametry) może rozdzielić 2 obserwacje,



może też rozdzielić 3 obserwacje, ale 4 już nie



Wniosek:  $VCdim=3$

# Jak obliczyć VC – dimension?

Klasyfikator liniowy w przestrzeni N- wymiarowej może rozdzielić N+1 obserwacji

Wniosek: VCdim=N+1



Uwaga: wzór (poniżej) najczęściej szacuje błąd z dużym nadmiarem

$$R(\alpha) \leq R_{emp}(\alpha) + \sqrt{\left(\frac{h(\log(2l/h) + 1) - \log(\eta/4)}{l}\right)}$$


# Uczenie „bez nauczyciela\*”

Brak bazy uczącej:

Metody: K-średnich (K-means), identyfikacja rozkładów prawdopodobieństwa, etc.



K- średnich



DBSCAN

*density-based spatial clustering  
of applications with noise*