



Monitorowanie i Diagnostyka w Systemach Sterowania

**Wydział Elektrotechniki i Automatyki
Katedra Elektrotechniki, Systemów Sterowania i Informatyki
Dr inż. Michał Grochowski**

Monitorowanie i Diagnostyka w Systemach Sterowania

na studiach II stopnia specjalności: Systemy Sterowania i Podejmowania Decyzji

Maszyny Wektorów Nośnych (*Support Vector Machines - SVM*)

na podstawie:

Yaser S. Abu-Mostafa. Learning from the Data. Course at California Institute of Technology

*Alpaydin, E. Introduction to Machine Learning. The MIT Press Cambridge, Massachusetts
London, England 2010.*

Haykin, S. Neural Networks and Machine Learning., Pearson Prentice Hall, 2009.


Opracował: dr inż. Michał Grochowski

kiss.pg.mg@gmail.com

michal.grochowski@pg.gda.pl

Charakterystyka problemu


Jak rozdzielić dane ??



Nieskończenie wiele możliwości !!!

Charakterystyka problemu

Który margines jest najlepszy ??



Która z linii maksymalizuje ten margines ??

Charakterystyka problemu


Niech: $\{(x_i, y_i)\}_{i=1}^N$ oznacza zbiór danych, gdzie x_i jest wzorcem wejściowym, a y_i oznacza przynależność i -tego wejścia do danej klasy, „+1” lub „-1”.

Założmy (na chwilę) że punkty są liniowo separowalne.

Linia (płaszczyzna, hiperpłaszczyzna) decyzyjna opisana jest zależnością:

$$w^T x + b = 0 \quad (1)$$

gdzie x jest wektorem wejściowym, w jest „nastawialnym” wektorem (np. wag), b jest progamiem.



Charakterystyka problemu


Możemy zapisać:

$$w^T x_i + b \geq 0 \quad \text{dla} \quad y_i = +1$$

$$w^T x_i + b < 0 \quad \text{dla} \quad y_i = -1$$

Optymalna linia (płaszczyzna, hiperpłaszczyzna) decyzyjna maksymalizująca margines ρ opisana jest zależnością:

$$w_o^T x + b_0 = 0 \tag{3}$$



Nieco podstawowych przekształceń ...

$$w^T x_i + b \geq 0 \quad \text{dla} \quad y_i = +1$$

$$w^T x_i + b < 0 \quad \text{dla} \quad y_i = -1$$

Wiemy że (z (2)):

$$|w^T x + b| \geq 0$$

Możemy więc przyjąć że (normalizacja):

$$|w^T x + b| = 1$$


Możemy więc zapisać:

$$w_o^T x_i + b_o \geq +1 \quad \text{dla} \quad y_i = +1$$

$$w_o^T x_i + b_o < -1 \quad \text{dla} \quad y_i = -1$$

lub:

$$y_i (w_o^T x_i + b_o) = +1$$



(6)

Nieco podstawowych przekształceń ...

Odległość od płaszczyzny decyzyjnej

Niech x_i będzie punktem leżącym najbliżej płaszczyzny: $w^T x + b = 0$

oraz: $|w^T x + b| = 1$

x_i

Wektor w jest prostopadły do płaszczyzny S w przestrzeni wejść X .


Dowolne punkty x_1 oraz x_2 należące do płaszczyzny S , spełniają jej równanie, więc:

$$w^T x_1 + b = 0 \quad w^T x_2 + b = 0$$

więc: $w^T (x_1 - x_2) = 0$

Stąd w jest ortogonalny do jakiegokolwiek wektora na płaszczyźnie S

$$|w^T x + b| \geq 0$$



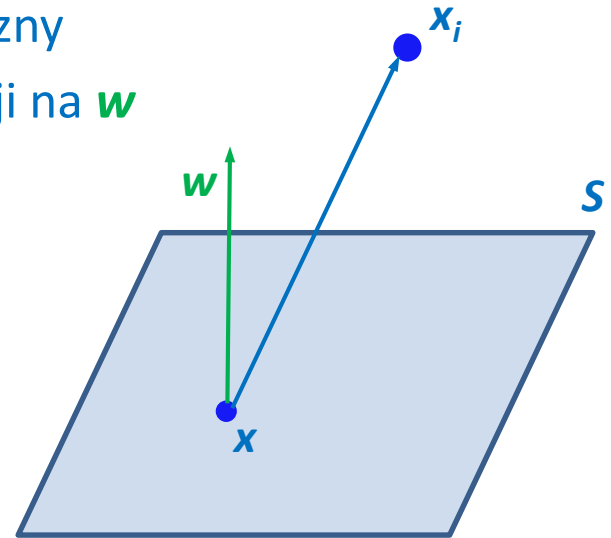
Nieco podstawowych przekształceń ...

Odległość od płaszczyzny decyzyjnej

Odległość pomiędzy x_i i płaszczyzną:

... weźmy jakikolwiek punkt x należący do płaszczyzny

... utwórzmy wektor $x_i - x$ i dokonajmy jego projekcji na w



Nieco podstawowych przekształceń ...

Odległość od płaszczyzny decyzyjnej

Odległość pomiędzy x_i i płaszczyzną (L):

... weźmy jakikolwiek punkt x należący do płaszczyzny

... utwórzmy wektor $x_i - x$ i dokonajmy jego projekcji na w

Matematyka ...

$$\hat{w} = \frac{w}{\|w\|} \quad \hat{w} - \text{wektor jednostkowy}$$


odległość L :

$$L = \left| \hat{w}^T (x_i - x) \right|$$

$$L = \frac{1}{\|w\|} \left| w^T x_i - w^T x \right| = \frac{1}{\|w\|} \left| w^T x_i + b - w^T x - b \right| = \frac{1}{\|w\|}$$

ponieważ:

$$\left| w^T x + b \right| = 0 \quad \text{oraz} \quad \left| w^T x_i + b \right| = 1$$



Problem optymalizacyjny

Zmaksymalizować odległość $L = \rho$

$$\max \frac{1}{\|w\|} = \min w^T w$$

Zadanie optymalizacji:


$$\min_{w \in R} g(w) = \frac{1}{2} w^T w$$

przy ograniczeniach (z równania 6):

$$y_i (w^T x_i + b) \geq 1 \quad \text{dla} \quad i = 1, 2, \dots, N$$

gdzie:

$$w \in R^d, \quad b \in R$$



Problem optymalizacyjny

Problem optymalizacji kwadratowej z ograniczeniami - liniowo kwadratowy

Zadanie optymalizacji (kwadratowej, $g(w)$ jest wypukła):

$$\min_{w \in R} g(w) = \frac{1}{2} w^T w$$

przy ograniczeniach (liniowych względem w):

$$y_i (w^T x_i + b) \geq 1 \quad \text{dla} \quad i = 1, 2, \dots, N$$

Tak sformułowany problem jest prymalnym zagadnieniem optymalizacyjnym.

Możemy go rozwiązać stosując metodę mnożników Lagranga oraz warunków Kukna – Tuckera (lub Karush – Kukna – Tuckera, w skrócie *KKT*).

Problem optymalizacyjny

Sformułowanie prymalne

Funkcja Lagrange'a:

$$L(w, b, \lambda) = \frac{1}{2} w^T w - \sum_{i=1}^N \lambda_i [y_i (w^T x_i + b) - 1]$$

λ_i - mnożniki Lagrange'a

Minimalizujemy względem w oraz b ,
 a jednocześnie maksymalizujemy względem λ ($\lambda_i \geq 0$) !!!

Warunki optymalności:

$$\frac{\delta L(w, b, \lambda)}{\delta w} = 0$$

$$\frac{\delta L(w, b, \lambda)}{\delta b} = 0$$

stąd:

$$w = \sum_{i=1}^N \lambda_i y_i x_i \quad \text{oraz} \quad \sum_{i=1}^N \lambda_i y_i = 0$$

Problem optymalizacyjny

Sformułowanie dualne

Możemy podstawić:

$$w = \sum_{i=1}^N \lambda_i y_i x_i \quad \text{oraz} \quad \sum_{i=1}^N \lambda_i y_i = 0$$

do:

$$L(w, b, \lambda) = \frac{1}{2} w^T w - \sum_{i=1}^N \lambda_i [y_i (w^T x_i + b) - 1]$$

otrzymując ($Q(\lambda) = L(w, b, \lambda)$):

$$Q(\lambda) = \sum_{i=1}^N \lambda_i - \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N [y_i y_j \lambda_i \lambda_j x_i^T x_j]$$

Którego szukamy maksimum po λ_i , przy ograniczeniach:

$$\lambda_i \geq 0, \quad i = 1, \dots, N \quad \text{oraz} \quad \sum_{i=1}^N \lambda_i y_i = 0$$

Problem optymalizacyjny

Sformułowanie dualne

Niech: $\{(x_i, y_i)\}_{i=1}^N$ oznacza zbiór danych (treningowych),

Znajdź współczynniki Lagranga $\{\lambda_i\}_{i=1}^N$, które minimalizują funkcję:

$$\min_{\lambda} Q(\lambda) = \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N [y_i y_j \lambda_i \lambda_j x_i^T x_j] - \sum_{i=1}^N \lambda_i$$

przy ograniczeniach:

$$\lambda_i \geq 0, \quad i = 1, \dots, N$$

$$\sum_{i=1}^N \lambda_i y_i = 0$$

Problem optymalizacyjny

Sformułowanie dualne

$$\min_{\lambda} Q(\lambda) = \frac{1}{2} \lambda^T \begin{bmatrix} y_1 y_1 x_1^T x_1 & y_1 y_2 x_1^T x_2 & \cdots & y_1 y_N x_1^T x_N \\ y_2 y_1 x_2^T x_1 & y_2 y_2 x_2^T x_2 & \cdots & y_2 y_N x_2^T x_N \\ \cdots & \cdots & \cdots & \cdots \\ y_N y_1 x_N^T x_1 & y_N y_2 x_N^T x_2 & \cdots & y_N y_N x_N^T x_N \end{bmatrix} \lambda + (-1^T) \lambda$$

przy ograniczeniach:

$$y^T \lambda = 0$$

$$0 \leq \lambda \leq \infty$$

Problem optymalizacyjny

Sformułowanie dualne

Uwagi:

- problem dualny oparty jest całkowicie o dane wejściowe (treningowe, pomiarowe);
- funkcja optymalizowana zależy wyłącznie od iloczynu skalarnego wejść.

$$\left\{ x_i^T \cdot x_j \right\}_{i,j=1}^N$$

Cechy wektorów nośnych

Sformułowanie dualne

Rozwiązanie:

$$\lambda_o = \lambda_{o,1}, \dots, \lambda_{o,N} \quad \lambda_o - \text{optymalne mnożniki Lagranga}$$

Z warunków KKT:

$$\lambda_i [y_i (w^T x_i + b) - 1] = 0$$

Wszystkie niezerowe mnożniki Lagranga $\lambda_{o,i}$ określają **wektory nośne (podtrzymujące)** x_i .

Takich wektorów jest N_S

$$\lambda_{o,i} > 0 \Rightarrow x_i \quad \text{wektory nośne (podtrzymujące) SV}$$

Cechy wektorów nośnych


Sformułowanie dualne

Rozwiązanie:

x_i leżące najbliżej optymalnej linii (płaszczyzny, hiperpłaszczyzna) decyzyjnej są wektorami nośnymi (podtrzymującymi).
 x_i „dotykają” marginesu ρ .

Wektory nośne spełniają:

$$y_i (w^T x_i + b) = 1$$



Cechy wektorów nośnych

$$w = \sum_{i=1}^N \lambda_i y_i x_i \quad \sum_{i=1}^N \lambda_i y_i = 0$$

Sformułowanie dualne

Rozwiązanie:

Wyznaczamy optymalny wektor w_o :


$$w_o = \sum_{i=1}^{N_s} \lambda_{o,i} y_i x_i$$

N_s – ilość niezerowych $\lambda_{o,i}$

Wyznaczamy optymalny wektor b_o :

$$b_0 = 1 - w_o^T x^{(S)} \quad \text{dla } y^{(S)} = 1$$


$$b_0 = 1 - \sum_{i=1}^{N_s} \lambda_{o,i} y_i x_i x^{(S)}$$




Problemy liniowo nieseparowalne

Transformacja do innej przestrzeni przestrzeni ($X \rightarrow Z$)

$$\min_{\lambda} Q(\lambda) = \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N [y_i y_j \lambda_i \lambda_j x_i^T x_j] - \sum_{i=1}^N \lambda_i$$



$X \rightarrow Z$

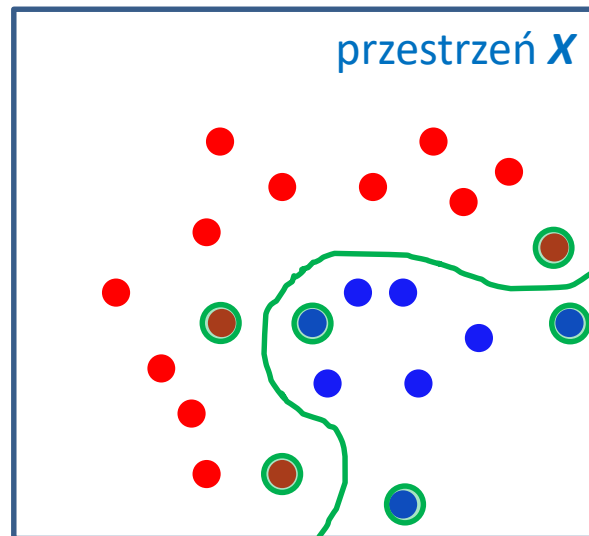


$$\min_{\lambda} Q(\lambda) = \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N [y_i y_j \lambda_i \lambda_j z_i^T z_j] - \sum_{i=1}^N \lambda_i$$

Problemy liniowo nieseparowalne

Cechy wektorów nośnych

Wektory nośne leżą w przestrzeni Z !!!



W przestrzeni X możemy jedynie obserwować ich „obraz” !!!

Również marginesy określane są w przestrzeni Z !!!

Problemy liniowo nieseparowalne

Co potrzebujemy z przestrzeni Z ?

$$\min_{\lambda} Q(\lambda) = \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N [y_i y_j \lambda_i \lambda_j z_i^T z_j] - \sum_{i=1}^N \lambda_i$$

Uwaga: Nie potrzebujemy wektorów z_i i z_j a jedynie ich iloczynów skalarnych !!!

Ograniczenia:

$$\lambda_i \geq 0, \quad i = 1, \dots, N$$

$$\sum_{i=1}^N \lambda_i y_i = 0$$

Otrzymujemy:

$$f(x) = \text{sign}(w_o z^T + b_o)$$

gdzie:

$$w_o = \sum_{i=1}^{N_s} \lambda_{o,i} y_i z_i$$

potrzebujemy: $z_i^T z_j$

$$b_o : \quad y_i (w_o^T z_j^{(S)} + b_o) = 1$$

potrzebujemy: $z_i^T z_j$

Problemy liniowo nieseparowalne

Obliczenia w przestrzeni Z (*kernel trick*)

Dla dowolne punktów \mathbf{x}_1 oraz \mathbf{x}_2 należących do \mathbf{X} , chcemy policzyć $\mathbf{z}_1^T \mathbf{z}_2$

Niech:

$$\mathbf{z}_1^T \mathbf{z}_2 = k(\mathbf{x}_1, \mathbf{x}_2)$$

Będzie jądrem (kernel) – „iloczyn skalarny” \mathbf{x}_1 oraz \mathbf{x}_2

Np: Gaussa:

$$k(\mathbf{x}, \mathbf{y}) = \exp\left(-\frac{\|\mathbf{x}-\mathbf{y}\|^2}{2\delta^2}\right), \text{ przy } \delta > 0$$

Problemy liniowo nieseparowalne

Obliczenia w przestrzeni Z (*kernel trick*)

$$\min_{\lambda} Q(\lambda) = \frac{1}{2} \lambda^T \begin{bmatrix} y_1 y_1 \underline{x_1^T x_1} & y_1 y_2 \underline{x_1^T x_2} \cdots & y_1 y_N \underline{x_1^T x_N} \\ y_2 y_1 \underline{x_2^T x_1} & y_2 y_2 \underline{x_2^T x_2} \cdots & y_2 y_N \underline{x_2^T x_N} \\ \dots & \dots & \dots \\ y_N y_1 \underline{x_N^T x_1} & y_N y_2 \underline{x_N^T x_2} \cdots & y_N y_N \underline{x_N^T x_N} \end{bmatrix} \lambda + (-1^T) \lambda$$

$$X \rightarrow Z$$

$$\min_{\lambda} Q(\lambda) = \frac{1}{2} \lambda^T \begin{bmatrix} y_1 y_1 \underline{k(x_1, x_1)} & y_1 y_2 \underline{k(x_1, x_2)} \cdots & y_1 y_N \underline{k(x_1, x_N)} \\ y_2 y_1 \underline{k(x_2, x_1)} & y_2 y_2 \underline{k(x_2, x_2)} \cdots & y_2 y_N \underline{k(x_2, x_N)} \\ \dots & \dots & \dots \\ y_N y_1 \underline{k(x_N, x_1)} & y_N y_2 \underline{k(x_N, x_2)} \cdots & y_N y_N \underline{k(x_N, x_N)} \end{bmatrix} \lambda + (-1^T) \lambda$$

Problemy liniowo nieseparowalne

Obliczenia w przestrzeni Z (*kernel trick*)

Wyrażmy $f(x)$ przy pomocy $K(-,-)$:

$$z_1^T z_2 = k(x_1, x_2)$$

$$f(x) = \text{sign}(w_o z^T + b_o)$$

$$w_o = \sum_{i=1}^{N_s} \lambda_{o,i} y_i z_i \quad \text{to:} \quad f(x) = \text{sign}\left(\sum_{i=1}^{N_s} \lambda_i y_i K(x_i, x) + b_o\right)$$

gdzie:

$$b_o = y_i - \sum_{i=1}^{N_s} \lambda_i y_i K(x_i, x)$$

dla każdego niezerowego λ_i :

$$\lambda_i > 0$$

Dziękuję za uwagę