

## Ćwiczenie SVM

# Maszyna wektorów nośnych

### Część teoretyczna

Wykład 16: Maszyna wektorów nośnych.

### Zadania pomocnicze

Zapoznaj się z funkcjami `svmtrain` i `svmclassify` (help Matlab).

### Zadania do wykonania

Zbadaj jak działa maszyna wektorów nośnych (*support vector machine*, SVM) w różnych zadaniach klasyfikacji dwuklasowej: klasyfikacja liniowa, klasyfikacja nieliniowa dla danych separowalnych nieliniowo i klasyfikacja nieliniowa dla danych nieseparowalnych.

1. Utwórz zbiór danych do klasyfikacji liniowej:

```
rand('state',nr_gr*r_k);
N1=20; %liczba punktów pierwszej klasy
N2=20; %liczba punktów drugiej klasy
x=[rand(2,N1), rand(2,N2).*rand(2,N2)+1]; %przykłady uczące
d=[zeros(1,N1)-1, zeros(1,N1)+1]; %i ich etykiety
```

gdzie za `nr_gr` wstaw numer swojej sekcji a za `r_k` aktualny rok kalendarzowy.

Pokaż dane na wykresie.

2. Użyj metody SVM do klasyfikacji danych – `svmtrain` (użyj domyślnych wartości parametrów tej funkcji z wyjątkiem `showplot`, który ustaw na `true`).
3. Utwórz zbiór danych do klasyfikacji nieliniowej:

```
[A,B]=gener_zbiorow(nr_gr,2,100);
x=[A'; B'];
d=[zeros(1,size(A_trn,2))-1 zeros(1,size(B_trn,2))+1]';
```

4. Użyj metody SVM do klasyfikacji danych. Jako jąder użyj radialnych funkcji bazowych. Wykorzystaj funkcję `svmtrain` (użyj domyślnych wartości parametrów tej funkcji z wyjątkiem `kernel_function`, który ustaw na `rbf` i `showplot`, który ustaw na `true`). Za pomocą funkcji `svmclassify` wyznacz odpowiedzi klasyfikatora na przykłady uczące. Wyznacz dokładność klasyfikatora. Zanotuj rezultat.
5. W procedurze 10-krotnej krosvalidacji znajdź optymalną wartość szerokości funkcji radialnych `sig`:

```
id = crossvalind('Kfold',200,10); %podział przykładów na podzbiory
                                do krosvalidacji
k=1;
Sig=[0.1:0.05:3];
for sig=Sig
    for i = 1:10 %10-krotna krosvalidacja
        val = (id == i);
        train = ~val;
```

```

svmStruct = svmtrain(x(train,:),d(train),'kernel_function',
                    'rbf','rbf_sigma',sig,'showplot',false);
dval = svmclassify(svmStruct,x(val,:));
acc(i)=sum(d(val)==dval)/sum(val)*100; %dokładność
end
Acc(k) = mean(acc); %średnie dokładności
k=k+1;
end

```

Zmienna `Acc` przechowuje procentową dokładność klasyfikatora oszacowaną w procedurze krosvalidacji. Narysuj wykres zależności  $Acc = f(sig)$ . Wybierz optymalną wartość `sig`.

- Utwórz wykresy obrazujące przykłady uczące i linie decyzyjne utworzone przez SVM dla `sig = 0,1, 1, 2 i 3` oraz dla optymalnej wartości `sig`, znalezionej w p. 5. Skomentuj wykresy.

- Utwórz zbiór danych nieseparowalnych:

```

[A,B]=gener_zbiorow(nr_gr,3,100);
x=[A'; B'];
d=[zeros(1,size(A_trn,2))-1 zeros(1,size(B_trn,2))+1]';

```

- Powtórz p. 5 i 6 dla danych nieseparowalnych.
- W procedurze 10-krotnej krosvalidacji znajdź optymalną wartość parametru `C` (patrz slajd 10 wykładu 16). Procedura krosvalidacji będzie analogiczna do tej użytej w p. 5. Za `sig` przyjmij optymalną wartość znaną w p. 8. Wartość parametru `C` wprowadza się do funkcji `svmtrain` poprzez argument `boxconstraint`:  

```
svmStruct = svmtrain(x(train,:),d(train),'kernel_function','rbf',
                    'rbf_sigma',sig,'boxconstraint',C);
```

Narysuj wykres zależności  $Acc = f(C)$ . Wybierz optymalną wartość `C`.

## Co powinno znaleźć się w sprawozdaniu

- Cel ćwiczenia.
- Treść zadania.
- Opis metody SVM (nie kopiuj treści wykładu, poszukaj w literaturze i Internecie).
- Metodyka rozwiązania – poszczególne instrukcje Matlaba z wynikami i komentarzem (zachowaj numerację zadań).
- Wnioski końcowe.

## Zadania dodatkowe dla ambitnych

- Dokonaj klasyfikacji zbioru danych Iris za pomocą SVM.
- Porównaj wyniki SVM dla przykładów separowalnych liniowo z wynikami maszyny liniowej, perceptronu i metody Fishera.
- Porównaj wyniki SVM z wynikami wielowarstwowego perceptronu.
- Zbuduj klasyfikator SVM do klasyfikacji wieloklasowej.
- Wykonaj powyższe zadania w środowisku R lub w Pythonie.

## Przykładowe zagadnienia i pytania zaliczeniowe

- Cel i plan ćwiczenia.
- Materiał ze sprawozdania.
- Zadanie optymalizacyjne w SVM.
- Reguła decyzyjna w SVM
- SVM dla danych nieseparowalnych liniowo.

6. Maszyna jądrowa.
7. *Kernel trick*.
8. Funkcje jądrowe.
9. Wieloklasowa maszyna jądrowa.

## Do przygotowania na następne zajęcia

1. Zapoznać się z instrukcją do kolejnego ćwiczenia.
2. Zapoznać się z częścią teoretyczną do kolejnego ćwiczenia.
3. Wykonać zadania pomocnicze do kolejnego ćwiczenia.