

Ćwiczenie SVM

Maszyna wektorów nośnych

Wersja dla Matlaba 18a

Część teoretyczna

Wykład 16: Maszyna wektorów nośnych.

Zadania pomocnicze

Zapoznaj się z funkcjami `fitcsvm` i `predict` (help Matlab).a).

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

figure(1);
gscatter(x(1,:),x(2,:),d);
```

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

2. Użyj metody SVM do klasyfikacji danych – `fitcsvm` (użyj domyślnych wartości parametrów tej funkcji).

Wizualizacja rezultatów:

```
sv = svmStruct.SupportVectors; %wektory nośne
hold on;
plot(sv(:,1),sv(:,2),'ko','MarkerSize',10)
a = svmStruct.Beta;
b = svmStruct.Bias;
xx = minmax(x);
x2=-a(1)/a(2)*xx(1,:) - b/a(2);
plot(xx(1,:),x2)
legend('klasa 1','klasa 2','Wektory nośne','Linia decyzyjna');
xlim(xx(1,:));
ylim(xx(2,:));
```

gdzie `svmStruct` to nazwa obiektu zwracanego przez `fitcsvm`.

3. Utwórz zbiór danych do klasyfikacji nieliniowej:

```
[A,B]=gener_zbiorow(nr_gr,2,100);
x=[A'; B']; %wektory wejściowe
d=[zeros(1,size(A,2))-1 zeros(1,size(B,2))+1]'; %pożądane odpowiedzi:
+1 dla zbioru A i -1 dla zbioru B
```

4. Użyj metody SVM do klasyfikacji danych. Jako jąder użyj radialnych funkcji bazowych. Wykorzystaj funkcję `fitcsvm` (użyj domyślnych wartości parametrów tej funkcji z wyjątkiem `KernelFunction`, który ustaw na `RBF` i `KernelScale`, który ustaw na `0.25`).

Wizualizacja rezultatów:

```
sv = svmStruct.SupportVectors; %wektory nośne

u = 0.01;
[x1Grid,x2Grid] =
meshgrid(min(x(:,1)):u:max(x(:,1)),min(x(:,2)):u:max(x(:,2)));
xGrid = [x1Grid(:),x2Grid(:)];
N = size(xGrid,1);
d1 = predict(svmStruct,xGrid);

figure(2);
hold on;
gscatter(xGrid(:,1),xGrid(:,2),d1,[1 0.8 0.8; 0.8 1 1]);
plot(sv(:,1),sv(:,2),'ko','MarkerSize',10)
gscatter(x(:,1),x(:,2),d');
legend('klasa 1','klasa 2');
```

5. W procedurze 10-krotnej krosvalidacji znajdź optymalną wartość szerokości funkcji radialnych `sig`:

```
id = crossvalind('Kfold',200,10); %podział przykładów na podzbiory
k=1; acc=[]; Acc=[];
Sig=[0.02:0.02:0.5 0.51:0.1:3];
for sig=Sig
    for i = 1:10 %10-krotna krosvalidacja
        val = (id == i);
        train = ~val;
        svmStruct = fitcsvm(x(train,:),d(train),'KernelFunction',
                            'RBF','KernelScale',sig);
        dval = predict(svmStruct,x(val,:));
        acc(i)=sum(d(val)==dval)/sum(val)*100;
    end
    Acc(k) = mean(acc);
    k=k+1;
end
```

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

6. Utwórz wykresy obrazujące przykłady uczące i linie decyzyjne utworzone przez SVM dla `sig = 0.02, 0.1, 0.5, 1, 2 i 3` oraz dla optymalnej wartości `sig`, znalezionej w p. 5. Skomentuj wykresy.

7. Utwórz zbiór danych nieseparowalnych:

```
[A,B]=gener_zbiorow(nr_gr,3,100);
x=[A'; B']; %wektory wejściowe
d=[zeros(1,size(A,2))-1 zeros(1,size(B,2))+1]'; %pożądane odpowiedzi:
+1 dla zbioru A i -1 dla zbioru B
```

8. Powtórz p. 5 i 6 dla danych nieseparowalnych.
9. W procedurze 10-krotnej krosvalidacji znajdź optymalną wartość parametru `C` (patrz slajd 10 i 12 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 `fitcsvm` poprzez argument `BoxConstraint`:

```
svmStruct = fitcsvm(x(train,:),d(train)','KernelFunction','RBF',  
    'KernelScale',sig, 'BoxConstraint',c);
```

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

Co powinno znaleźć się w sprawozdaniu

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

Zadania dodatkowe dla ambitnych

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

Przykładowe zagadnienia i pytania zaliczeniowe

1. Cel i plan ćwiczenia.
2. Materiał ze sprawozdania.
3. Zadanie optymalizacyjne w SVM.
4. Reguła decyzyjna w SVM
5. SVM dla danych nieseparowalnych liniowo.
6. Maszyna jądrowa.
7. *Kernel trick*.
8. Funkcje jądrowe.
9. Wieloklasowa maszyna jądrowa.

Do przygotowania na następane 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.