

## Ćwiczenie SNK

# Wielowarstwowy perceptron jako klasyfikator

### Część teoretyczna

Wykład: Sztuczne sieci neuronowe – klasyfikacja.

### Zadania pomocnicze

1. Zapoznaj się z programem **nnd4db**, który pozwala ręcznie ustawiać granicę decyzyjną realizowaną przez neuron oraz z programem **nnd4pr**, w którym granica decyzyjna ustawiana jest w procesie treningu. Punkty uczące należą do dwóch klas – czarnej i białej, możemy je przesuwać. W programie **nnd4pr** przycisk „Learn” uruchamia jeden krok treningu – prezentację na wejściu współrzędnych jednego punktu i adaptację wag, jeśli punkt ten jest źle zaklasyfikowany przez neuron. Przycisk „Train” uruchamia pięć kroków treningu. Przycisk „Random” nadaje wagom losowe wartości. Możemy wybrać opcję „Bias” – umożliwia to przesuwanie granicy decyzyjnej poprzez zmianę wagi  $b$  – lub „No bias” – wtedy granica decyzyjna kręci się wokół punktu  $(0, 0)$  (patrz program **nnd2n1**). Punkty źle zaklasyfikowane mają czerwoną otoczkę. Załączam skrypty (Przyk\_\*.m), w których oprogramowałem przykłady z [Żurada96].
2. Zapoznaj się z funkcjami `newff`, `train` i `sim` (help lub dokumentacja Matlaba).

### Zadania do wykonania

Dane są zbiory pacjentów: chorych A oraz zdrowych B. Każdy obiekt (człowiek) w tych zbiorach opisany jest dwiema cechami  $x_1$  i  $x_2$  (np. temperatura ciała, parametry krwi, występowanie lub brak określonych alleli genów itp.). Zaprojektuj klasyfikator neuronowy na bazie perceptronu do rozróżniania klas A i B. Zadanie wykonaj w trzech wariantach:

- zbiory A i B separowalne liniowo,
- zbiory A i B separowalne nieliniowo,
- zbiory A i B częściowo pokrywające się.

1. Generowanie zbiorów danych.

1.1. Tworzymy funkcję generującą dane i zapisujemy pod nazwą `gener_zbiorow.m`:

```
function [A,B]=gener_zbiorow(nr_gr,wariant,lp,rk)
%nr_gr - nr sekcji np. 1,1, 1,2, ...
%wariant - 1 - zbiory A i B separowalne liniowo, 2 - separowalne
%nieliniowo, 3 - częściowo pokrywające się
%lp - liczba punktów w zbiorach A i B
%rk - rok kalendarzowy

rand('state',nr_gr*rk);
if wariant==1
    Ap=[0.1 0.9; 0.5+rand*0.5 0.5-rand*0.5];
    [A,B]=gener_AB(Ap,Ap,lp,lp,1,1);
elseif wariant==2
    Ap=[0.1 0.4 0.9; 0.5-rand*0.5 0.5+rand*0.2 0.5-rand*0.5];
    [A,B]=gener_AB(Ap,Ap,lp,lp,2,2);
elseif wariant==3
    Ap=[0.1 0.4 0.9; 0.5-rand*0.5 0.5+rand*0.3 0.5-rand*0.5];
    Bp=[0.1 0.25 0.55 0.7 1; 0.5+rand*0.1 0.4-rand*0.3 0.4+rand*0.2 0.5 0.1];
    [A,B]=gener_AB(Ap,Bp,lp,lp,2,4);
end;
title(['Nr gr = ', num2str(nr_gr)]);

function [A,B]=gener_AB(Ap,Bp,Al,Bl,Ast,Bst)
    hold off;
```

```
Aw=polyfit (Ap (1, :), Ap (2, :), Ast);  
Bw=polyfit (Bp (1, :), Bp (2, :), Bst);  
  
rand('state', sum(100*clock));  
ll=0; i=0;  
while (ll<A1) && (i<A1*100)  
    x=rand;  
    y=rand;  
    ymax=polyval (Aw, x);  
    if (ymax>=0) && (ymax<=1) && (y<ymax)  
        ll=ll+1;  
        A (1, ll)=x;  
        A (2, ll)=y;  
    end;  
    i=i+1;  
end;  
  
ll=0; i=0;  
while (ll<B1) && (i<B1*100)  
    x=rand;  
    y=rand;  
    ymin=polyval (Bw, x);  
    if (ymin>=0) && (ymin<=1) && (y>ymin)  
        ll=ll+1;  
        B (1, ll)=x;  
        B (2, ll)=y;  
    end;  
    i=i+1;  
end;  
  
figure(2);  
plot (A (1, :), A (2, :), 'ro');  
hold on;  
plot (B (1, :), B (2, :), 'bx');  
plot (Ap (1, :), Ap (2, :), 'r. ');  
plot (Bp (1, :), Bp (2, :), 'b. ');  
v=0:0.02:1;  
plot (v, polyval (Aw, v), 'r--');  
plot (v, polyval (Bw, v), 'b--');  
xlim([0 1]); ylim([0 1]);  
xlabel('x1'); ylabel('x2');
```

## 1.2. Generujemy dane dla zbiorów separowalnych liniowo:

Uwaga - polecenia zamieszczone w kolejnych punktach należy umieścić w jednym skrypcie.

```
nr_gr =  
r_k =  
[A_u, B_u]=gener_zbiorow(nr_gr, 1, 100, r_k); %dane uczące  
[A_t, B_t]=gener_zbiorow(nr_gr, 1, 100, r_k); %dane testowe
```

gdzie do `nr_gr` przypisz numer swojej sekcji a do `r_k` aktualny rok kalendarzowy.

## 1.3. Na podstawie wygenerowanych zbiorów tworzymy macierze wejściowe. Tworzymy wektory pożądaných odpowiedzi:

```
%zbiór uczący  
x_u=[A_u B_u]; %wektory wejściowe  
t_u=[zeros(1, size(A_u, 2))+1 zeros(1, size(B_u, 2))-1]; %pożądane odpowiedzi: +1  
dla zbioru A i -1 dla zbioru B  
  
%zbiór testujący  
x_t=[A_t B_t]; %wektory wejściowe
```

```
t_t=[zeros(1,size(A_t,2))+1 zeros(1,size(B_t,2))-1]; %pożądane odpowiedzi: +1  
dla zbioru A i -1 dla zbioru B
```

2. Tworzymy i uczymy sieć neuronową z  $l_n$  neuronami w warstwie ukrytej:

```
l_n=1; %liczba neuronów w warstwie ukrytej  
%utworzenie sieci  
net=newff([0 1;0 1],[l_n 1],{'tansig','tansig'},'trainscg');  
%pierwszy argument reprezentuje zakresy danych wejściowych, drugi - liczbę  
neuronów w warstwie ukrytej i wyjściowej, trzeci - typy funkcji aktywacji w  
tych warstwach, czwarty - metodę uczenia sieci; funkcja zwraca obiekt sieci  
net  
net.trainParam.epochs = 200; %liczba epok uczenia  
[net]=train(net,x_u,t_u); %trening sieci
```

3. Testujemy sieć i wyznaczamy błędy klasyfikacji na zbiorze uczącym:

```
%symulacja nauczonej sieci na zbiorze uczącym  
y=sim(net,x_u);  
for i=1:length(y)  
    if y(i)>0.8 y(i)=1; %jeśli odpowiedź sieci jest w zakresie od 0.8 do 1,  
        %przyjmujemy +1  
    elseif y(i)<-0.8 y(i)=-1; %jeśli odpowiedź sieci jest w zakresie od -0.8  
        %do -1, przyjmujemy -1  
    else y(i)=0; end; %jeśli odpowiedź sieci jest w zakresie od -0.8 do 0.8,  
        %przyjmujemy 0, co oznacza brak decyzji  
end;  
  
%błędy  
lb_u=0;%liczba punktów źle zaklasyfikowanych  
ln_u=0;%liczba punktów niezaklasyfikowanych do żadnej klasy  
for i=1:length(y)  
    if y(i)==0 ln_u=ln_u+1;  
    elseif y(i)~=t_u(i) lb_u=lb_u+1;  
    end;  
end;  
lb_u=lb_u/length(y)*100; %lb_u wyrażone w procentach  
ln_u=ln_u/length(y)*100; %ln_u wyrażone w procentach
```

Uwaga – powyżej przyjęto zasadę, że:

- jeśli odpowiedź sieci jest w zakresie od 0.8 do 1, przyjmujemy +1, co oznacza klasę A,
- jeśli odpowiedź sieci jest w zakresie od -0.8 do -1, przyjmujemy -1, co oznacza klasę B,
- jeśli odpowiedź sieci jest w zakresie od -0.8 do 0.8, przyjmujemy 0, co oznacza brak decyzji.

4. Testujemy sieć i wyznaczamy błędy klasyfikacji na zbiorze testowym:

```
%symulacja nauczonej sieci na zbiorze testowym  
y=sim(net,x_t);  
for i=1:length(y)  
    if y(i)>0.8 y(i)=1;  
    elseif y(i)<-0.8 y(i)=-1;  
    else y(i)=0; end;  
end;  
  
%błędy  
lb_t=0;%liczba punktów źle zaklasyfikowanych  
ln_t=0;%liczba punktów niezaklasyfikowanych do żadnej klasy  
for i=1:length(y)  
    if y(i)==0 ln_t=ln_t+1;  
    elseif y(i)~=t_t(i) lb_t=lb_t+1;  
    end;  
end;  
lb_t=lb_t/length(y)*100; %lb_t wyrażone w procentach  
ln_t=ln_t/length(y)*100; %ln_t wyrażone w procentach
```

## 5. Prezentacja wyników:

```
fprintf('Odsetek poprawnych, złych i nierozstrzygniętych klasyfikacji\n')
fprintf('          %5.2f%% - %5.2f%% - %5.2f%% w zbiorze
treningowym \n', (100-lb_u-ln_u), lb_u, ln_u)
fprintf('          %5.2f%% - %5.2f%% - %5.2f%% w zbiorze testowym
\n', (100-lb_t-ln_t), lb_t, ln_t)

%wykreślenie obszarów decyzyjnych utworzonych przez sieć
a=0:0.01:1;
i=1;
for b=0:0.01:1
    x=[a;zeros(1,length(a))+b];
    yy(i,:)=sim(net,x);
    i=i+1;
end;
figure(1);
surf(a,a,yy,'EdgeColor','none');
colorbar;
title('Powierzchnia decyzyjna utworzona przez sieć');
xlabel('x1'); ylabel('x2');
view(2);
grid off;
figure(2);
yy(find(yy>0.8))=1; yy(find(yy<-0.8))=-1; yy(find(yy>=-0.8&yy<=0.8))=0;
contour(a,a,yy);
title('Obszary decyzyjne:');
```

6. Zaobserwuj jak zmieniają się wyniki w zależności od liczby neuronów ukrytych. Zmieniaj `l_n` w granicach od 1 do wartości, przy której nie obserwuje się już poprawy rezultatów. Błędy zamieść w tabeli. Zaznacz wariant najlepszy. Pokaż wykresy dla tego wariantu.
7. Zaobserwuj jak zmieniają się wyniki w zależności od funkcji aktywacji. W kodzie zamieszczonym w p. 2 zmieniaj funkcje aktywacji: `tansig`, `logsig`, `purelin`. Przetestuj każdy możliwy układ par tych trzech funkcji aktywacji. Eksperymenty wykonaj przy optymalnej liczbie neuronów `l_n` (najlepszy wariant z p. 6). Błędy zamieść w tabeli. Zaznacz wariant najlepszy. Pokaż wykresy dla tego wariantu.
8. Powtórz eksperymenty dla danych separowanych nieliniowo. W tym celu w kodzie zamieszczonym w p. 1.2 wprowadź 2 zamiast 1 jako drugi parametr funkcji `gener_zbiorow`. Wykonaj ponownie p. 6 i 7 dla nowych danych.
9. Powtórz eksperymenty dla danych nieseparowanych. W tym celu w kodzie zamieszczonym w p. 1.2 wprowadź 3 zamiast 2 jako drugi parametr funkcji `gener_zbiorow`. Wykonaj ponownie p. 6 i 7 dla nowych danych.

## Zawartość sprawozdania

Sprawozdania powinny być sporządzone według wzoru zamieszczonego na stronie i zawierać:

- A) Cel ćwiczenia.
- B) Treść zadania.
- C) Opis problemu klasyfikacji, sieci neuronowe stosowane do klasyfikacji (nie kopiuj treści wykładu, poszukaj w literaturze i Internecie).
- D) Metodyka rozwiązania zadania.
- E) Zestawienie wyników (wykresy, tabele z komentarzem).
- F) Wnioski końcowe.
- G) Wydruk programu.

## Zadania dodatkowe dla ambitnych

Wybrane zadanie student wykonuje indywidualnie, po uzgodnieniu z prowadzącym. Zadania nie są obligatoryjne. Z zadania sporządzamy sprawozdanie.

1. Sprawdź jak kształtują się wyniki, gdy zmienimy wartość progową  $\pm 0.8$  w p. 3. Jakie błędy klasyfikacji wtedy się obserwuje?
2. Sprawdź jak uczy się sieć na danych uczących z różną zawartością szumu (szum dodaj do wektorów wejściowych  $x_u$ ). Jakie błędy klasyfikacji wtedy się obserwuje?
3. Oprogramuj przykład 3.2 z [Żurada96]. Wykonaj obliczenia i zobrazuj działanie dychotomizatora wykresami (rys. 3.12). Porównaj wyniki.
4. Oprogramuj przykład 3.3 z [Żurada96]. Wykonaj obliczenia i zobrazuj działanie klasyfikatora ciągłego wykresami (rys. 3.16). Porównaj wyniki.
5. Oprogramuj przykład 3.4 z [Żurada96]. Wykonaj obliczenia i zobrazuj działanie klasyfikatora ciągłego wykresem (rys. 3.18). Porównaj wyniki.
6. Oprogramuj przykład 4.3 z [Żurada96]. Wykonaj obliczenia i wykreśl linie decyzyjne opisane w tym przykładzie. Porównaj wyniki.
7. Wykonaj podobne ćwiczenie w innym środowisku, np. R, Python, Statistica, C#, ...

## Przykładowe zagadnienia i pytania zaliczeniowe

1. Narysuj model sztucznego neuronu.
2. Neuron jako klasyfikator.
3. Narysuj model sieci neuronowej użytej w ćwiczeniu.
4. Na czym polega klasyfikacja danych.
5. Narysuj i objaśnij wykres ze sprawozdania.
6. Funkcje aktywacji neuronów.
7. Wsteczna propagacja błędów.
8. Metody oceny klasyfikatora.

## 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.