

Obsah

- Kompetičné učenie
- Kohonenove samo-organizujúce sa mapy

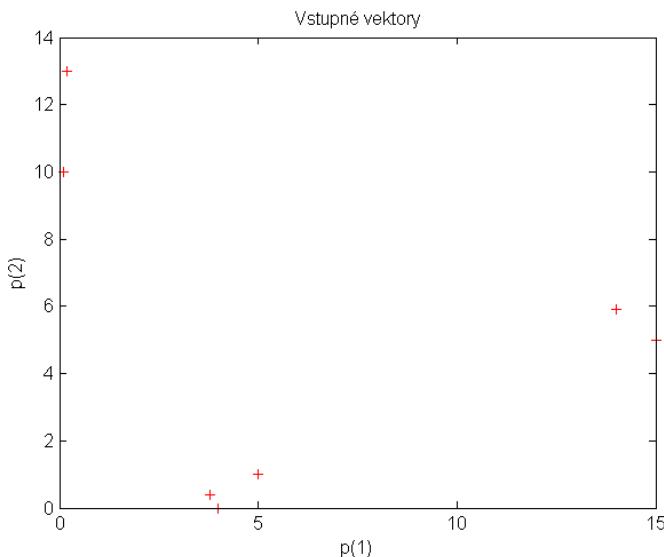
Kompetičné učenie

Máme množinu dvojrozmerných vektorov p a chceme ju rozdeliť na skupiny podobných vektorov - najst zhluky.

```
p=[ 0.1  4   5    0.2  15   3.8  14;
     10    0   1    13    5   0.4   5.9];
```

p nakreslíme

```
plot(p(1,:),p(2,:),'+r');
title('Vstupné vektorov');
xlabel('p(1)');
ylabel('p(2)');
```



Neuróny kompetitívnej vrstvy sa majú naučiť reprezentovať regióny vo vstupnom priestore vzorov. Vytvoríme kompetičnú sieť s 2 vstupnými a 3 neurónmi v kompetičnej vrstve:

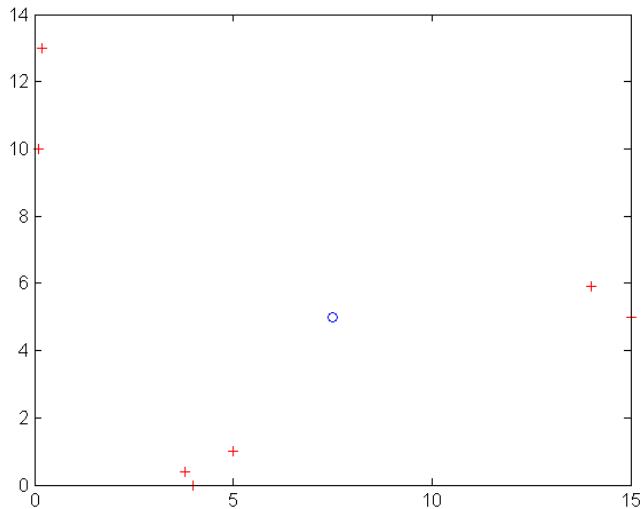
```
net=newc([0 15; 0 10],3);
```

Prvý parameter funkcie `newc` udáva rozsahy hodnôt jednotlivých zložiek vstupných vektorov, druhý argument udáva počet neurónov v kompetičnej

vrstve. Po inicializácii majú neuróny váhy v strede rozsahu jednotlivých zložiek.

```
w = net.IW{1}
plot(p(1,:),p(2,:),'+r');
hold on;
circles = plot(w(:,1),w(:,2),'ob');
hold off;

w =
    7.5000    5.0000
    7.5000    5.0000
    7.5000    5.0000
```



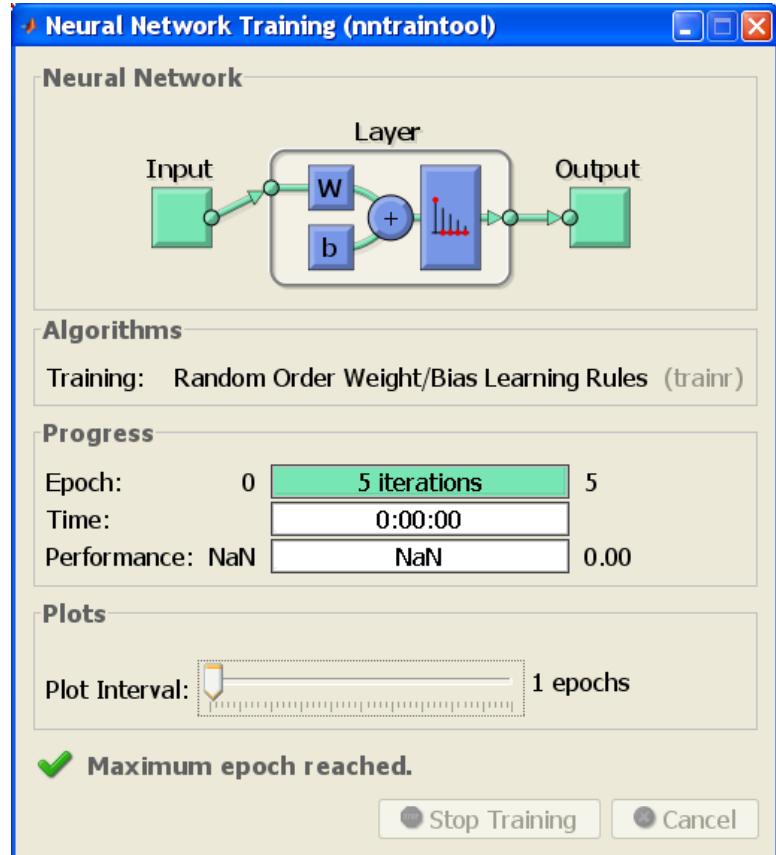
Nastavíme počet iterácií cez vstupné vzory

```
net.trainParam.epochs=5;
```

Spuštíme trénovanie siete.

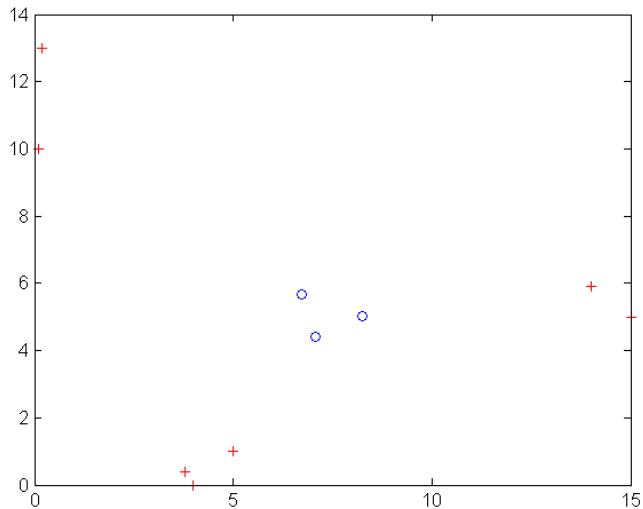
```
net = train(net,p);
```

V priebehu trénovania sa nám zobrazí okno



Po krátkom učení majú neuróny váhy posunuté k jednotlivým zhlukom, ale počet epoch bol príliš malý na naučenie.

```
w = net.IW{1};
plot(p(1,:),p(2,:),'+r');
hold on;
circles = plot(w(:,1),w(:,2),'ob');
hold off
```



Nastavíme vyšší počet iterácií cez vstupné vzory

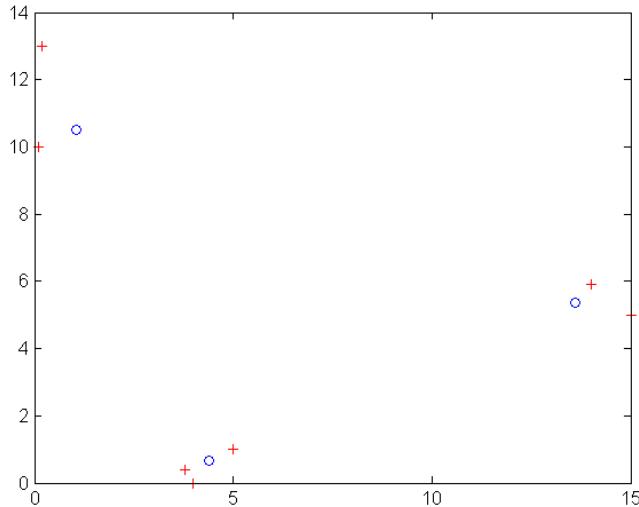
```
net.trainParam.epochs=100;
```

Spustíme znova trénovanie siete.

```
net = train(net,p);
```

Teraz už majú neuróny váhy posunuté k jednotlivým zhlukom.

```
w = net.IW{1};
plot(p(1,:),p(2,:),'r');
hold on;
circles = plot(w(:,1),w(:,2),'ob');
hold off
```



Natrénovanú sieť necháme spočítať výstupy pre vzory z p:

```
a = sim(net,p)
```

```
a =
(1,1)      1
(3,2)      1
(3,3)      1
(1,4)      1
(2,5)      1
(3,6)      1
(2,7)      1
```

Výsledkom je riedka matica – v každom stĺpci je len jedna hodnota 1. Nasledujúca funkcia vráti riadkové indexy prvkov 1 z matice a.

```
ac=vec2ind(a)
```

```
ac =
1      3      3      1      2      3      2
```

To sú vlastne čísla zhlukov, do ktorých bol zaradený príslušný vstupný vektor. Zhluky môžeme zobraziť farebne rozlíšené. Najprv si uložíme indexy vektorov jednotlivých zhlukov a potom ich zobrazíme rôznymi farbami. Najprv si zistíme indexy vektorov z jednotlivých zhlukov:

```

ind1=find(ac==1)
ind2=find(ac==2)
ind3=find(ac==3)

ind1 =
    1      4
ind2 =
    5      7
ind3 =
    2      3      6

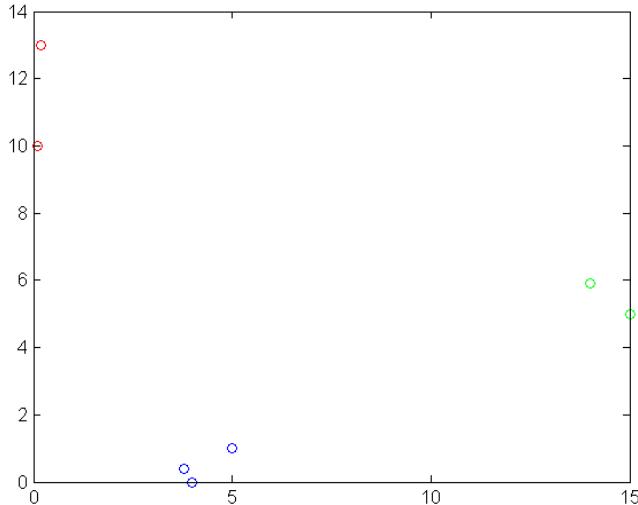
```

Nasledujúci príkaz plot musí byť celý na jednom riadku!

```

hold off
plot(p(1,ind1),p(2,ind1),'or',p(1,ind2),p(2,ind2),'og',p(1,ind3),p(2,ind3),'ob')

```



Kohonenove samo-organizujúce sa mapy

Tento model je vlastne rozšírením kompetičnej siete. Neuróny majú naviac definované topológiu. Vytvorenie Kohonenovej mapy: `net = newsom(PR, [D1,D2,...], TFCN, DFCN, OLR, OSTEPS, TLR, TND)`

`PR` matica $R \times 2$ miním a maxím jednotlivých zložiek R vstupných vektorov,
 D_i rozmery siete; implicitne = [5 8],
`TFCN` topológia; implicitne ='hextop',
`DFCN` funkcia vzdialenosťi, implicitne = 'linkdist' ,

OLR učiaca konštantá pre fázu usporiadavania, implicitne = 0.9,

0STEPS počet krokov fázy usporiadavania, implicitne = 1000,

TLR učiaca konštantá fázy ladenia, implicitne = 0.02,

TND veľkosť okolia pre fázu ladenia, implicitne = 1.

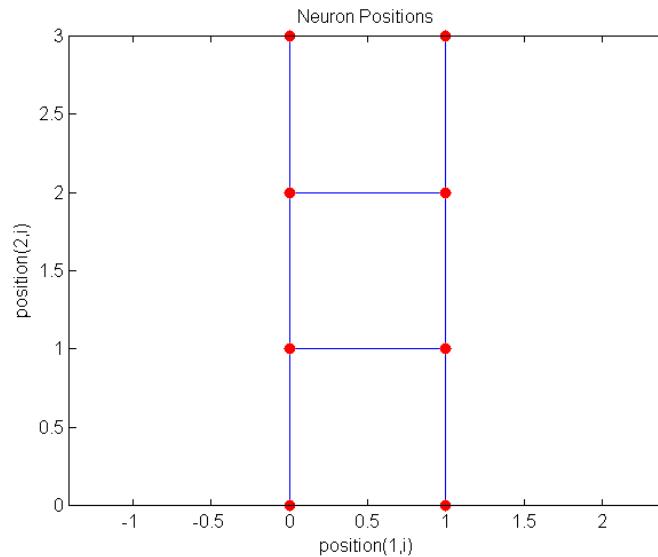
Možné topológie sú 'hextop', 'gridtop' a 'randtop'. Funkcia vzdialenosť môže byť 'linkdist', 'dist', 'boxdist' alebo 'mandist', ktoré zodpovedajú počtu prejdených hrán, Euklidovskej vzdialnosti, štvorcovému okoliu a Manhattanskej vzdialosti.

Odkrokuje si demo program `Demos > Self-organizing networks > two-dimensional organizing map`. Možné topológie si môžete zobrazí pomocou nasledujúcich funkcií.

- topológia pravouhlej mriežky:

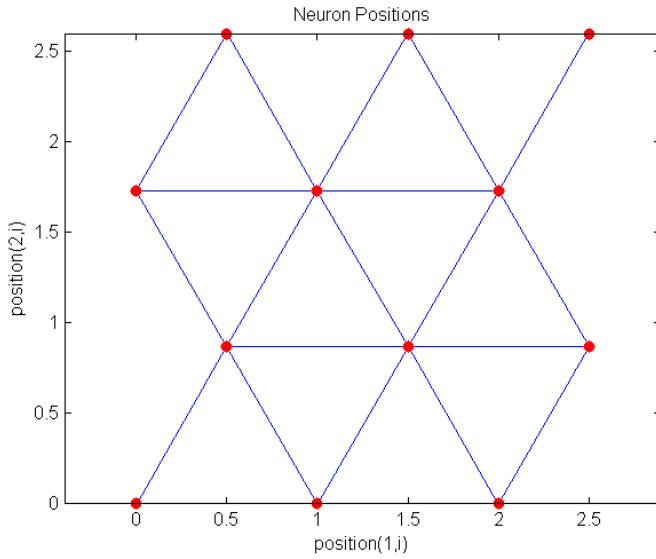
```
pos=gridtop(2,4)
plotsom(pos)
```

```
pos =
 0   1   0   1   0   1   0   1
 0   0   1   1   2   2   3   3
```



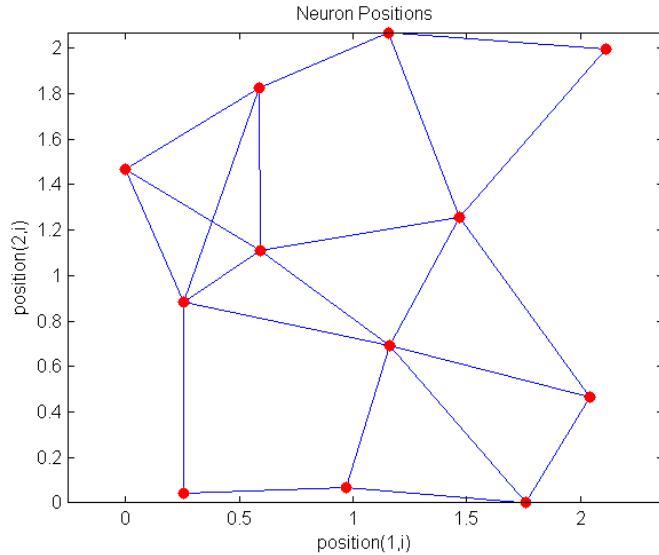
- topológia šestuholníkovej mriežky:

```
pos=hextop(3,4);
plotsom(pos)
```



- topológia náhodného grafu:

```
pos=randtop(3,4);
plotsom(pos)
```



Učenie v MATLABe má dve fázy. V prvej sa neuróny majú usporiadať podľa topológie a v druhej majú spresniť aproximáciu vstupných vzorov. Typické volanie funkcie `newsom` však vynecháva väčšinu parametrov:

```
net=newsom(minmax(p),[3, 4],'gridtop');
```

Úloha: Natrénujte Kohonenovu mapu s pravouhlou topológiou pre množinu vektorov, ktoré vracia funkcia

<http://ksvi.mff.cuni.cz/~mraz/datamining/dataset2.m>

Vyskúšajte rôzne počty neurónov a rôzne topológie siete. Pri učení siete zobražujte neuróny siete i vstupné vektory vždy po malom počte epoch.