



Mesterséges  
Intelligencia

Csató Lehel

# Mesterséges Intelligencia

Csató Lehel

Matematika-Informatika Tanszék  
Babeş–Bolyai Tudományegyetem, Kolozsvár

2006/2007



# Az Előadások Témái

Mesterséges  
Intelligencia

12

Csató Lehel

Multilayer

B.P.

Hebb

Self. Org.

Hebb-háló

S.O.M.

- Bevezető: mi a *mesterséges* intelligencia ...
- „Tudás”-reprezentáció
- Gráfkeresési stratégiák
- Szemantikus hálók / Keretrendszerek
- Játékok modellezése
- Bizonytalanság kezelése
- Grafikus modellek
- Tanuló rendszerek
- Szimulált kifűtés, Genetikus algoritmusok
- **Neurális hálók**
- Gépi tanulás
- Nemparametrikus módszerek



Mesterséges  
Intelligencia

12

Csató Lehel

Multilayer

B.P.

Hebb

Self. Org.

Hebb-hálóok

S.O.M.

## Előadások honlapja

<http://www.cs.ubbcluj.ro/~csatol/mestint>


## Vizsga

Szóbeli (60%) + Gyakorlat (40%)  
(v) Előadás (60%)

## Laborgyakorlatok:

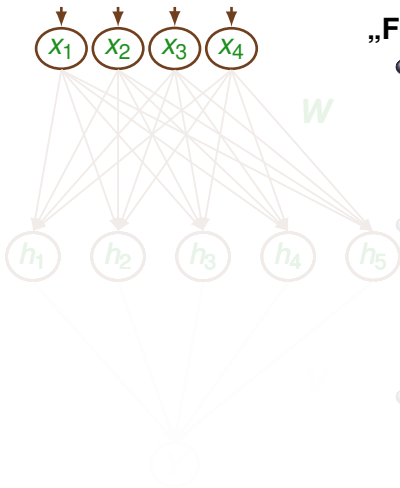
- 1 Clean vagy Prolog - dedukciós algoritmus **30%**
- 2 C / C++ / C# / ... - genetikus algoritmus **10% vagy**
- 3 Matlab - Neurális hálózatok vagy SVM **10%**

- Az információ – **számok** – a bemeneti **X** rétegből a kimeneti **Y** réteg fele halad.
- Egy mintára kiszámítjuk a kimeneti értéket, minden neuron értékét kiszámítva.
- Feltételezzük, hogy minden – adat és súly – folytonos.



## MLP **NEM** Bayes-háló

A neurális háló kapcsolatai **kommunikációt**, a Bayes-háló kapcsolatai **függőséget** jelentenek.



## „Formálisan”:

- A neuronháló csúcsai az **információt** feldolgozzák.

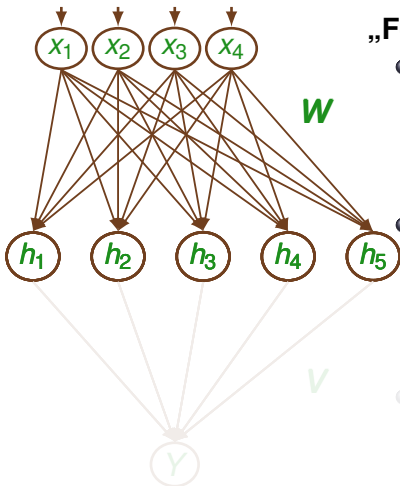
$$y_{ki} \stackrel{\text{def}}{=} f_{\text{akt}}(\mathbf{x}_{\text{be}})$$

- Az élek: a csúcsok közötti kapcsolatok.

$$x_{\text{be}}^{(j)} \stackrel{\text{def}}{=} \sum_j w_{ij} x_{ki}^{(j)}$$

- A fenti lépések ismétlődnek.

MI az információ?



## „Formálisan”:

- A neuronháló csúcsai az **információt** feldolgozzák.

$$y_{ki} \stackrel{\text{def}}{=} f_{\text{akt}}(\mathbf{x}_{\text{be}})$$


- Az élek: a csúcsok közötti kapcsolatok.

$$x_{\text{be}}^{(j)} \stackrel{\text{def}}{=} \sum_j w_{ij} x_{ki}^{(j)}$$

- A fenti lépések ismétlődnek.

MI az információ?

definíció szerint  $x_{ki} = f(\dots)$



## „Formálisan”:

- A neuronháló csúcsai az **információt** feldolgozzák.

$$y_{ki} \stackrel{\text{def}}{=} f_{\text{akt}}(\mathbf{x}_{be})$$


- Az élek: a csúcsok közötti kapcsolatok.

$$x_{be}^{(i)} \stackrel{\text{def}}{=} \sum_j w_{ij} x_{ki}^{(j)}$$

- A fenti lépések ismétlődnek.

**MI** az információ?

definíció szerint  $x_{ki} \in \mathbb{R}^k$



## „Formálisan”:

- A neuronháló csúcsai az **információt** feldolgozzák.

$$y_{ki} \stackrel{\text{def}}{=} f_{\text{akt}}(\mathbf{x}_{be})$$

- Az élek: a csúcsok közötti kapcsolatok.

$$x_{be}^{(j)} \stackrel{\text{def}}{=} \sum_j w_{ij} x_{ki}^{(j)}$$

- A fenti lépések ismétlődnek.

**MI** az információ?

definíció szerint  $\mathbf{x}_{ki} \in \mathbb{R}^k$




A **bemenő** aktivitás:

$$y_j = \sum_i w_{ij} x_i + b_j.$$

A perceptron tanulási  
algoritmushoz hasonlóan:

- előbb:  $\mathbf{x}'_j = [x_1, \dots, x_d, 1]^T$
- $\Rightarrow \mathbf{w}'_j = [w_1, \dots, w_d, b]^T$



## Univerzális approximáció

A következő rendszer:

$$f_M(z|\mathbf{w}, \mathbf{b}) = \sum_{m=1}^M w_m f(z - b_m)$$

univerzális approximátor, azaz

$$\forall \delta > 0 \forall g \in L^2(\mathbb{R}^d) \\ \exists M, \mathbf{w}, \mathbf{b} \text{ ú.h. } \|g - f_M(z|\mathbf{w}, \mathbf{b})\|_{L_2} \leq \delta$$



Mesterséges  
Intelligencia

12

Csató Lehel

Multilayer

B.P.

Hebb

Self. Org.

Hebb-hálók

S.O.M.

## Univerzális approximátor: bizonyítás a szint-halmazokon alapszik (lásd Lebesgue integrálás).

### Vizualizálás:

### Mintavételezés a



$w$  és  $b$  értékekből

#### MATLAB kód:



```
%Generatorfüggvények
f = inline('(x>0)-0.5).*2');
g = inline('2./(1+exp(-2*x))-1');
% komponensek szama
mComp = 10;
% fv.-nyek szama
nF = 6;
% X tengely
xx=-10:0.05:10;
xd= repmat(xx, [mComp, 1]);
% plot init
clf; hf = subplot(1,2,1);
set(gca, ...
    'Position', [0.05 0.1 0.42 0.85], ...
    'YTick', [], 'XTick', []);
hold on; box on; ylim([-25,25]);
set(gca, ...
    'Position', [0.55 0.1 0.42 0.85], ...
    'YTick', [], 'XTick', []);
hold on; box on; ylim([-25,25]);
```

```
hg = subplot(1,2,2);
% megjelenitesi stilus
style = {'b','r','k','m','c','g'};
% F.v.-nyek generalasa
for ii=1:nF;
    % egyutthatok
    ss=(2*rand(mComp,1) -1)*6;
    ww=(2*rand(mComp,1) -1)*6;
    bb=(2*rand(mComp,1) -1)*10;

    bd=diag(bb)*ones(size(xd));
    y_f = sum(diag(ww) * f(diag(ss)*xd + bd)
    y_g = sum(diag(ww) * g(diag(ss)*xd + bd)
    % megjelenites
    plot(hf,xx,y_f,style{ii},'LineWidth',3);
    plot(hg,xx,y_g,style{ii},'LineWidth',3);
end;
% nyomtatás
print -depsc2 rand_fn.eps
```



## Véletlen függvények a függvényosztályokból:





- **Nem bináris függvényt közelít.**

A bemeneti/kimeneti értékek folytonosak.

$$f_{NN} : \mathbb{R}^d \rightarrow \mathbb{R}$$

- Folytonos esetben használható a **négyzetes hibafüggvény**:

$$E(\mathbf{w}_{NN}) = \frac{1}{2} \sum_{n=1}^N (y_n - f_{NN}(\mathbf{x}_n))^2$$

ahol  $\mathbf{w}_{NN}$  a neuronháló paraméterei.

- Differenciálható akt. függvényeknél a **gradiens szabály** alkalmazható  $\Rightarrow$  **backpropagation szabály**.



- **Error back-propagation**  $\Leftrightarrow$  négyzetes hiba visszaterjesztése
- Egy adott **tanulási halmazhoz** és egy  $w_{NN}$  neurális háléhoz rendelt négyzetes hiba

$$E(w_{NN}) = \frac{1}{2} \sum_{n=1}^N (y_n - f_{NN}(x_n))^2$$

akkor zéró, ha a neurális háló **minden** adatot jól közelít.

- Egy adott  $w_{NN}^{(0)}$  hálónál jobban közelítő hálót kapunk ha egy kis lépést végzünk a negatív gradiens irányába.

● „Képletesen”

$$\begin{aligned} \mathbf{w}_{NN}^{(t+1)} &\Leftarrow \mathbf{w}_{NN}^{(t)} - \alpha \frac{\partial E(\mathbf{w}_{NN}^{(t)})}{\partial \mathbf{w}_{NN}^{(t)}} \\ &\Leftarrow \mathbf{w}_{NN}^{(t)} - \alpha \partial_{\mathbf{w}} E(\mathbf{w}_{NN}^{(t)}) \end{aligned}$$

ahol


$\alpha$  – tanulási együttható;

$\partial_{\mathbf{w}} E(\mathbf{w}_{NN}^{(t)})$  – a hiba gradiense (vektorok!).

**Kérdés:** milyen  $\alpha$  értékek megfelelőek?

**Kis lépések**  $\Rightarrow$  hosszú konvergencia.

**Nagy lépések**  $\Rightarrow$  nem konvergál.




## Differenciálás szabálya:

$$\frac{\partial f(g_1(w_i), \dots, g_k(w_i))}{\partial w_i} = \sum_{g_j} \frac{\partial f(g_1, \dots, g_k)}{\partial g_j} \frac{\partial g_j}{\partial w_i}$$

## Neuronháló függvénye:

$$y = \dots \left( \dots, f_j \left( \sum_i h_i w_{ij} \right), \dots \right)$$



$$\partial_{w_{ij}} E(\cdot) = \sum_j \partial_{f_j} E(\cdot) \partial_{w_{ij}} f_j \left( \sum_i w_{ij} h_i \right)$$

(folyt)


$$\begin{aligned}\partial_{w_{ij}} E(\cdot) &= \partial_{f_j} E(\dots) \partial_{w_{ij}} f_j \left( \sum_{n=1}^N w_{ij} h_i \right) \\ &= h_i f'_j \left( \sum_{n=1}^N w_{ij} h_i \right) \partial_{f_j} E(\cdot)\end{aligned}$$

A bemeneti érték és a kimeneti **hiba** szorzódnak.

$$\text{És } \partial_{f_j} E(\cdot) = \partial_{f_j} E \left( \dots, g_k \left( \sum_j v_{jk} f_j \right), \dots \right)$$

Lánc-deriválás szerint:

$$\partial_{f_j} E(\cdot) = \sum_k v_{jk} \partial_{g_k} E(\cdot) g'_k(\cdot)$$



Az egyéni hibák súlyozottan összeadódnak.



(folyt)

**Tehát:** amíg a működésnél a **jel előre** terjed, a tanulás folyamán a hiba **visszafele**; a kimeneti réteg felől a háló bemenete felé „terjed”.

## Hiba-visszaterjesztés (BP)




• azaz az osztópontok összegzővé alakulnak;



• azaz az összegző csomópontok meg hiba-elosztóvá.

- A **BP** algoritmus a gradiens szabály alkalmazása a neuronhálókra;
- Az alap a **négyzetes** hiba;
- Egyszerűen implementálható;
- Nagyon sok alkalmazás;



## Hátrányok:

- Mivel gradiens, lassú  $\Rightarrow$  nagyon sokáig tarthat a tanulás.
- **Más módszerekkel** állítani be a súlyokat: *Newton*, *Konjugált gradiens*.
- **Nincs** a becsült mennyiségre **konfidencia**  $\Rightarrow$  valószínűségi módszerek szükségesek.

**Feladat:** keressük a  $h(x_1, x_2) = 100(x_2 - x_1^2)^2 + (1 - x_1)^2$  függvény minimumát a gradiens szabály használatával.

Rosenbrock függvény

$$\partial_1 h(\cdot) = 400(x_2 - x_1^2)x_1 + 2(x_1 - 1)$$

$$\partial_2 h(\cdot) = 200(x_2 - x_1^2)$$


A második egyenlet

$$\leftrightarrow x_2 = x_1$$

Behelyettesítve  $x_1 = 1$ .

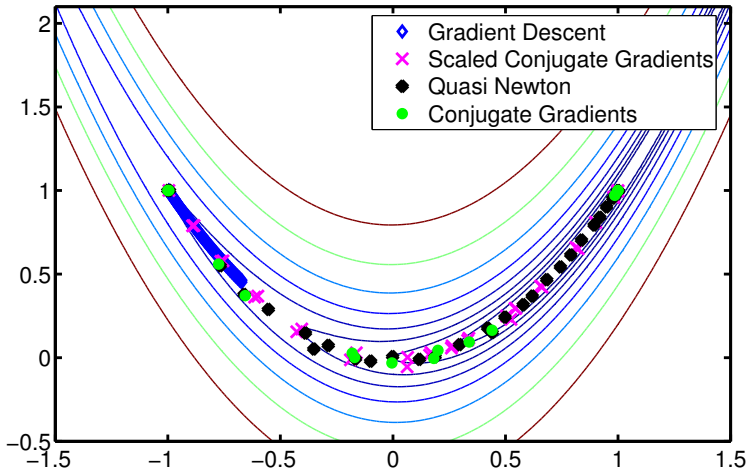
Induljunk a  $(-1, 1)$

pontból.



**BP szabály = gradiens** – általában **nagyon lassú**.

Rosenbrock fv. optimalizálás





- Neurális hálók **fekete-doboz** módszerek:
  - 1 minden feladat megoldására potenciálisan alkalmazhatóak;
  - 2 jó eredményekhez (majdnem mindig) kell egy kis igazítás a módszeren;
  - 3 siker függ a tapasztalattól;<sup>5</sup>
- **BackPropagation = gradiens**
  - 1 általában **nagyon lassú**;
  - 2 fejlett módszerek: konjugált gradiens módszerek, quasi-Newton, etc. **gyorsítanak a konvergencián**.
  - 3 **lokális optimumok elkerülésére** többszálú optimalizálás, pl. mintavételezéssel kijelölni a kezdőértékeket.



Mesterséges  
Intelligencia

12

Csató Lehel

Multilayer

B.P.

Hebb

Self. Org.

Hebb-hálók

S.O.M.



**D.O. Hebb**

*The organization of behavior*

## **A neurális moduláció alapelvei:**

- Két neuronok közötti kapcsolat erőssége arányos a neuronok pre-, illetve poszt-szinaptikus tevékenységével;
- Azon neuron-csoportok, melyek általában egyszerre tüzelnek, egy egységet alkotnak; (modularitás)
- A *gondolkodás* folyamata ezen sejt-csoportok szekvenciális aktivációja;



## Organization of Behavior:

*When an axon of cell A is near enough to excite B and repeatedly or persistently takes part in firing it, some growth process or metabolic change takes place in one or both cells such that A's efficiency, as one of the cells firing B, is increased.*

(p. 62)

Neuroscience  $\Leftrightarrow$  „Hebb synapse”

„Hebb szabály”

$$\Delta w_{ij} = \alpha a_i a_j$$

Ahol

$a_i, a_j$  – neuronok aktivitásai;

$w_{ij}$  – az összekötő szinapszis erőssége;

$\alpha$  – tanulási együttható.



## Haykin: Neural Networks

A comprehensive foundation, IEEE press, 1994

### Cél:

- **Struktúrák** felfedezése az adatokban;
- **„Felügyelet” nélküli** működés  $\Rightarrow$  önszervezés.

### Tanulói szabályok:

- lokális szabályok, melyek – sok neuronra alkalmazva – egy globális függvényt határoznak meg.
- Alapja (Turing 1952):  
*„Global order can arise from local interactions.”*





Mesterséges  
Intelligencia

12

Csató Lehel

Multilayer

B.P.

Hebb

Self. Org.

Hebb-hálók

S.O.M.

## Önszervező rendszerek alapelvei (von der Marlsburg):

- *A szinapszisok önmegerősítőek*

A pre-, illetve posztszinaptikus neuronok egyidejű aktivációja erősíti a szinapszist (lásd Hebb).

- *A szinapszisok versengenek az erőforrásokért*

A legerősebb szinapszis **biztos**, hogy túléli. Ez a többi rovására történik (winner-takes-all).

- *A szinapszisok változásai koordináltak*


Egy szinapszis nem kódol **robosztusan**, ezért egy régió neuronjai – majdnem – azonos bemenet–kimenet kapcsolatot kódolnak.

## Önszervező tanulás



## Struktúra-felismerés

- A vizuális rendszer önszervező:
  - fejlődésének elején csak a felismerésre való **képesség** van jelen;
  - a működés során egyes kép-csoportok – klaszterek – együttesen lesznek ábrázolva;
- A származtatott fogalmak ábrázolása a **hierarchia** egy felsőbb szintjén történik.



### Példa:

- neurális rendszer **pixelcsoportokat** keres.
- némely pixelcsoport **gyakori**; ezen csoportok rögzülnek a rendszerben.
- a **felső** szinten a rendszer **címkézést** végez.



## Hebb tanulás - auto-asszociatív rendszerek

- A rendszer bemenete egy minta - **nincs** kimeneti jel.
- A „kimeneten” vagy:
  - az eredeti mintát; vagy
  - egy csoportosítást, „sűrített” ábrázolást szeretnénk visszakapni.
- csoportosításkor a kimeneti neuronok **versengenek**:


$$\hat{y}_j = \sum_i x_i w_{ij}$$

$$y_l = \begin{cases} 1 & l = k \\ 0 & l \neq k \end{cases}$$

$$\text{ahol } k = \operatorname{argmax}_j \hat{y}_j$$

$$y_l = \begin{cases} 1 & l = k \\ 0 & l \neq k \end{cases} \quad \text{ahol } k = \underset{j}{\operatorname{argmax}} \hat{y}_j$$


- **Végleges** kimeneti érték az **argmin** művelet után.
- **Versengés** a bemeneti mintákért.



- Feltételezve egy kezdő **W** – véletlen – súlyvektort, a **v** minta bemutatása után
- csak a  $w_4$  súlyok változnak a kompetitív tanulás során.

$$y_l = \begin{cases} 1 & l = k \\ 0 & l \neq k \end{cases} \quad \text{ahol } k = \underset{j}{\operatorname{argmax}} \hat{y}_j$$

- **Végleges** kimeneti érték az **argmin** művelet után.
- **Versengés** a bemeneti mintákért.




- Feltételezve egy kezdő **W** – véletlen – súlyvektort, a **v** minta bemutatása után
- csak a **w<sub>4</sub>** súlyok változnak a kompetitív tanulás során.

$$\Delta w_{ij} = \alpha x_i y_j$$

- minden  $y_k$  neuron attraktorként működik.  
receptív mezők alakulnak ki
- $\alpha \rightarrow 0$  tanulási mód, pl.

$$\alpha_t = \frac{K}{t}$$

- az **asszociatív háló** konvergál (lásd).



**ami nincs:** kapcsolatok a kimeneti neuronok között:

**Kohonen-háló**



Mesterséges  
Intelligencia

12

Csató Lehel

Multilayer

B.P.

Hebb

Self. Org.

Hebb-hálók

S.O.M.


## Teuvo Kohonen

Since the 1960's, ~ introduced several new concepts to neural computing: theories of distributed associative memory and optimal associative mappings, the **self-organizing feature maps (SOMs)**, the learning vector quantization (LVQ), ...

the Adaptive-Subspace SOM (ASSOM) in which invariant-feature filters emerge ...

A new SOM architecture WEBSOM has been developed in his laboratory for exploratory textual data mining.

<http://websom.hut.fi/websom/>



[Wikipedia link](#)



Mesterséges  
Intelligencia

12

Csató Lehel

Multilayer

B.P.

Hebb

Self. Org.

Hebb-hálók

S.O.M.

## Jellemzők:

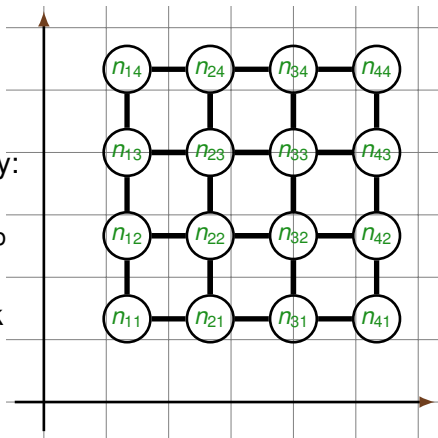
- kétrétegű háló, egy bemeneti és egy kimeneti réteggel;  
(mint előbb)
- kompetitív háló: csak egy neuron lesz aktív;  
(mint előbb)
- a kimeneti rétegen **topológia** van értelmezve

(ÚJ)



## Topológia – szomszédságot jelent

- segít a tanulásban:  
a **szomszédok** is tanulnak –  
kevésbé ...
- értelmezhető eredmény:  
a **szomszédok** aktivitása is  
aktivitása alapján pontosabb  
rekonstrukció
- a kimeneti  $n_{ij}$  neuronok  
megcímkézhetőek:  
**Kohonen:** ... fonéma  
annotáció





## Az algoritmus iteratív:

- 1 minták egyenként; a  $t$ -edik időpontban legyen  $\mathbf{x}_t$
- 2 kiszámítjuk a kimeneti neuronok aktivitását:

$$y_j = \sum_i w_{ij} x_i(t) = \mathbf{W}\mathbf{x}(t)$$

- 3 megkeressük a nyertes kimeneti neuront:

$$k \stackrel{\text{def}}{=} \operatorname{argmax}_j y_j$$

- 4 Az **összes** szomszédos neuron súlyát módosítjuk:

$$w_{ij}(t+1) = w_{ij}(t) + \alpha \eta(j, k) x_i(t)$$

Normáljuk a súlyokat  $w_{.j} \leftarrow w_{.j} / \|w_{.j}\|$

- 5 [GOTO 1](#)

Mesterséges  
Intelligencia

12

Csató Lehel

Multilayer

B.P.

Hebb

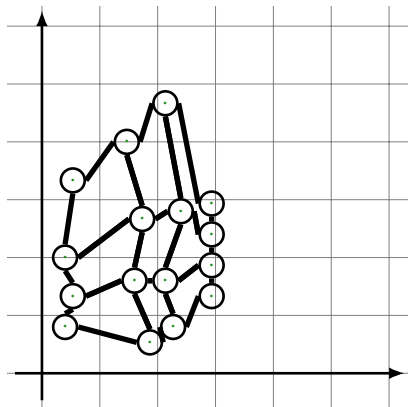
Self. Org.

Hebb-hálók

S.O.M.

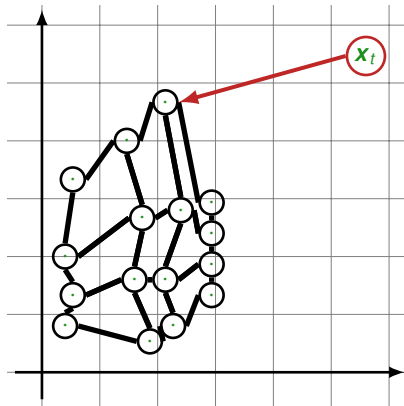
## Szavakban:

- a **nyertes** neuron „aktivizálódik”;
- A nyertes neuront és szomszédait „közelebb” hozzuk a bemenethez;
- Mindegyik neuron specializálódik a mintákra: arra lesz a legnagyobb a kimenete;




## Szavakban:


- a **nyertes** neuron „aktivizálódik”;
- A nyertes neuront és szomszédait „közelebb” hozzuk a bemenethez;
- Mindegyik neuron specializálódik a mintákra: arra lesz a legnagyobb a kimenete;




### Szavakban:

- a **nyertes** neuron „aktivizálódik”;
- A nyertes neuront és szomszédait „közelebb” hozzuk a bemenethez;
- Mindegyik neuron specializálódik a mintákra: arra lesz a legnagyobb a kimenete;





**Eredmény:** a neuronok elhelyezkedését a bemeneti minták **sűrűség-függvénye** határozza meg – több neuron kerül a sűrűbb régiókba.



**Eredmény:** a neuronok elhelyezkedését a bemeneti minták **sűrűség-függvénye** határozza meg – több neuron kerül a sűrűbb régiókba.



Mesterséges  
Intelligencia

12

Csató Lehel

Multilayer

B.P.

Hebb

Self. Org.

Hebb-hálók

S.O.M.

- Az adatokhoz **nincs** kimeneti érték rendelve;
- A rendszer általában az adatok egy **csoportosítását** valósítja meg;
- Ez implicit módon a bemeneti adatok terének a **felosztását** jelenti;
- **Zajszűrés/Sűrítés:** a teljes bemeneti adatok helyett a hozzá tartozó osztály kódját küldjük.



Mesterséges  
Intelligencia

12

Csató Lehel

Multilayer

B.P.

Hebb

Self. Org.

Hebb-hálók

S.O.M.

Walter Bischof, Jun Zhou (U. Alberta) és Terry Caelli  
(Australian N.U.) a kartográfiát (részben) automatizáló  
programmal álltak elő.

*A program embertől tanulja,*  
miként fedezzen fel és azonosítson  
légi felvételeken korábban **nem**  
**szereplő vagy megváltozott**  
elemeket: utakat, vasutakat,  
épületeket.



Ágens portál

Walter Bischof projektek

## Működése:

Egyre többet tud meg – „okosabb” lesz. Kellő mennyiségű  
gyakorlás után az operátor rábízta a munkát. *Bayes-féle*  
*következtetést használ:* korábbi mérések alapján végez új  
becsléseket. A legjobbakból állapítja meg az adott országút  
soron következő pontjait, és ezt mindaddig folytatja, amíg az új  
elemek pozíciója *megfelel az elvárásoknak.*