

# Mesterséges neurális hálózatok

Benyó Balázs, BME  
*[bbenyo@iit.bme.hu](mailto:bbenyo@iit.bme.hu)*

# Mesterséges neurális hálózatok: **Neurális hálózatok története**

# Történeti áttekintés a kezdetektől



**Warren McCulloch & Walter Pitts**, wrote a paper on how neurons might work; they modeled a simple neural network with electrical circuits.

**Nathaniel Rochester** from the IBM research laboratories led the first effort to simulate a neural network.

**John von Neumann** suggested imitating simple neuron functions by using telegraph relays or vacuum tubes.

STORY BY DATA

1943

1949

1950s

1956

1957

1958

## HISTORY OF NEURAL NETWORKS

1943-2019

**Donald Hebb** reinforced the concept of neurons in his book, *The Organization of Behavior*. It pointed out that neural pathways are strengthened each time they are used.

The **Dartmouth Summer Research Project on Artificial Intelligence** provided a boost to both artificial intelligence and neural networks.

**Frank Rosenblatt** began work on the Perceptron; the oldest neural network still in use today.

1982

1981

1969

1959

1982

**John Hopfield** presented a paper to the national Academy of Sciences. His approach to create useful devices; he was likeable, articulate, and charismatic.

Progress on neural network research halted due fear, unfulfilled claims, etc.

**Marvin Minsky & Seymour Papert** proved the Perceptron to be limited in their book, *Perceptrons*.

**Bernard Widrow & Marcian Hoff** of Stanford developed models they called ADALINE and MADALINE; the first neural network to be applied to a real world problem.

1982

1985

1997

1998

NOW

**US-Japan Joint Conference on Cooperative/Competitive Neural Networks**; Japan announced their Fifth-Generation effort resulted in US worrying about being left behind and restarted the funding in US.

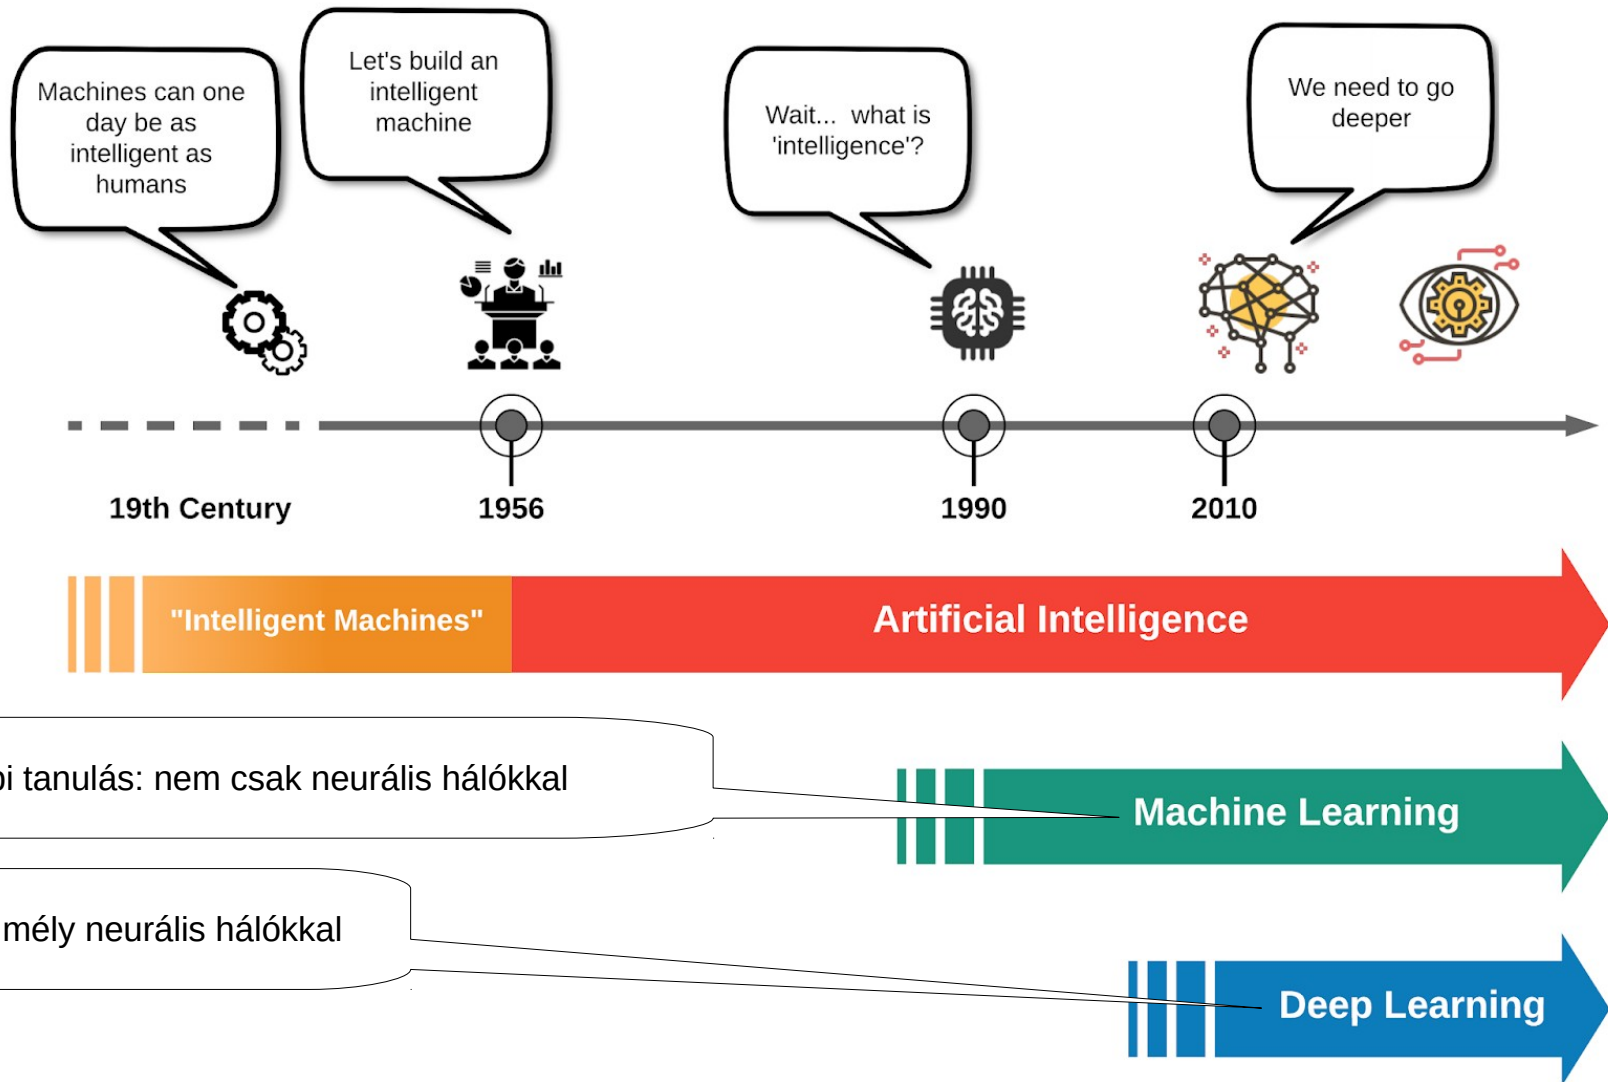
American Institute of Physics began what has become an annual meeting - **Neural Networks for Computing**.

A recurrent neural network framework, LSTM was proposed by **Schmidhuber & Hochreiter**.

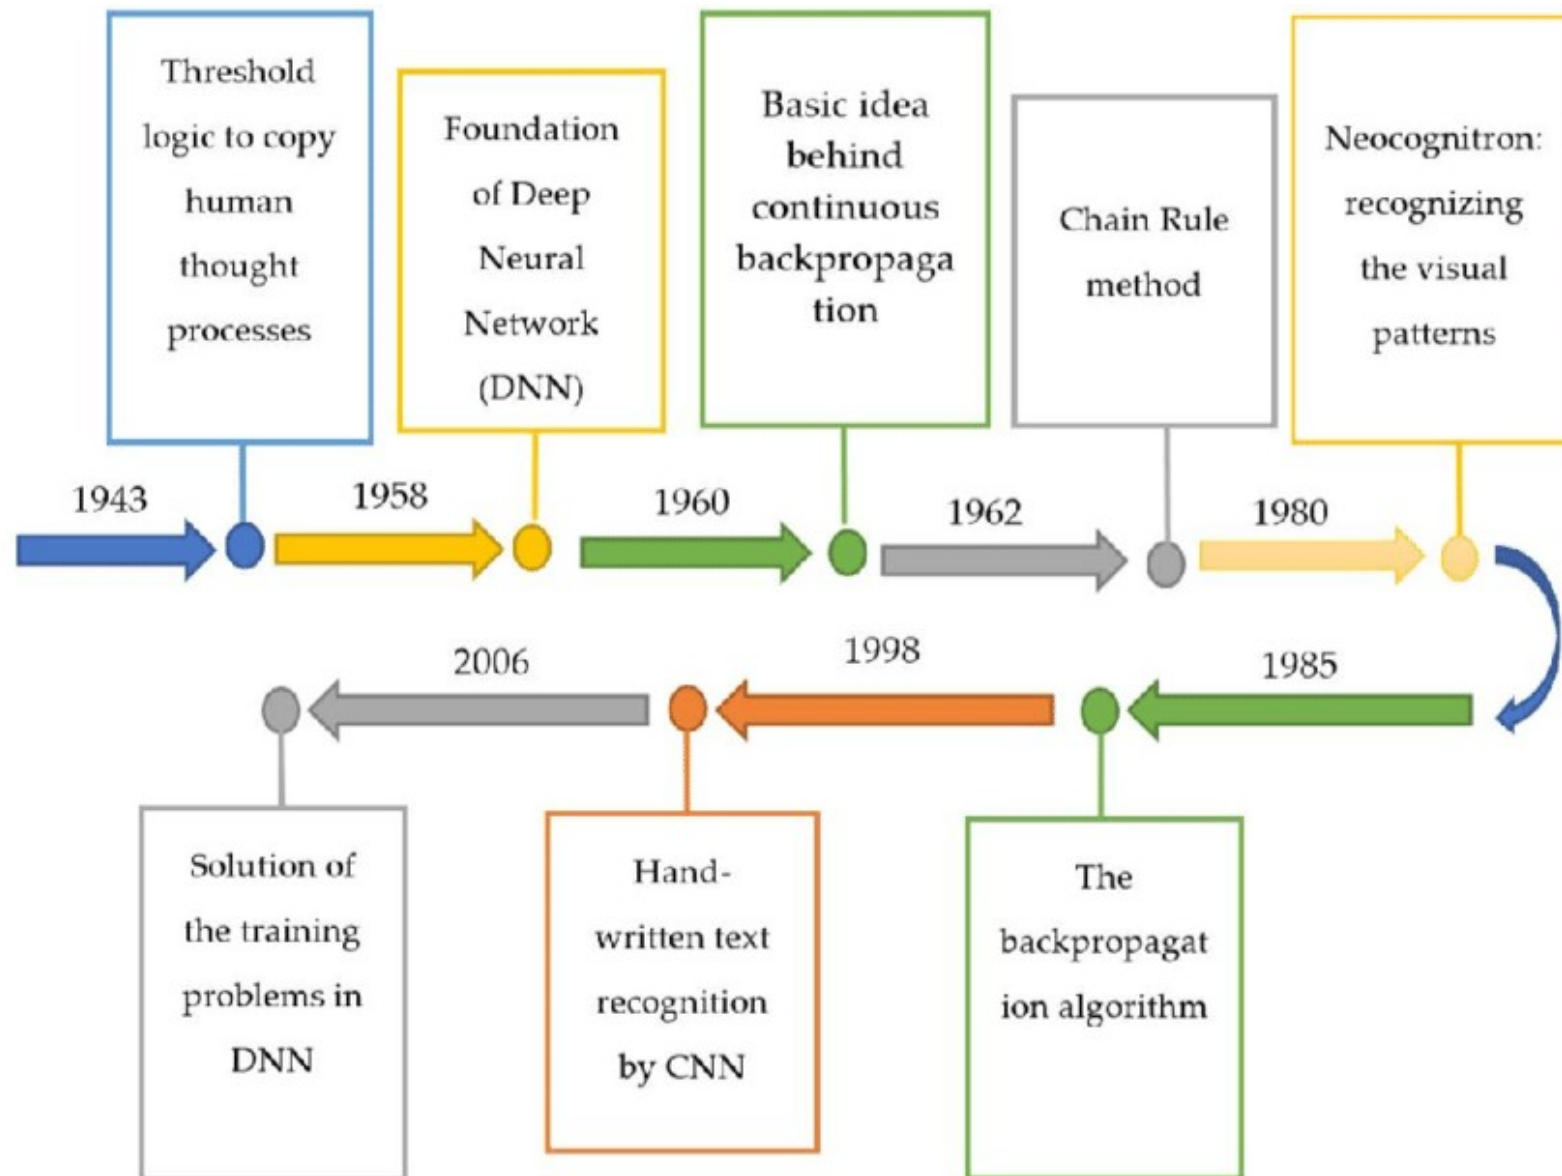
**Yann LeCun** published *Gradient-Based Learning Applied to Document Recognition*.

Neural networks discussions are prevalent; the future is here!

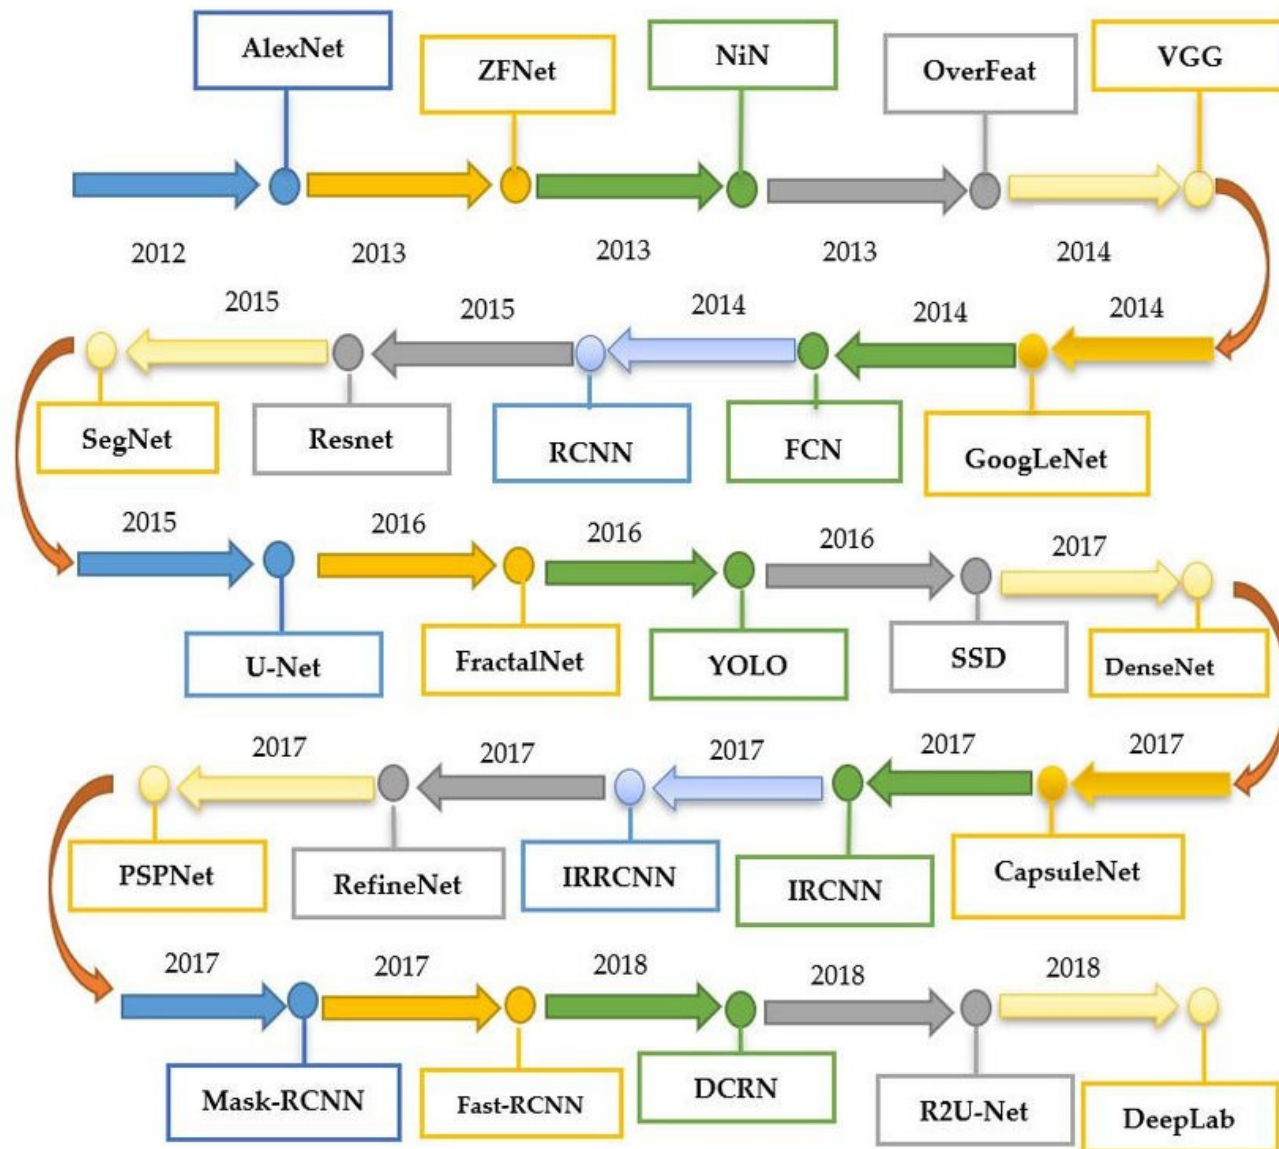
# Fontos fogalmak



# Fontos módszerek neurális hálózatok alkalmazásához



# Konkrét neurális háló típusok megjelenési ideje a közelmúltban



# Mesterséges neurális hálózatok: **Fiziológiai analógia**

# Fiziológiai analógia

- **Analógia alapja:**

- **Idegsejtek** hálózata

- **Idegsejt** (neuron) sematikus **működése:**

- Képes **ingerület átvitelre**, ill. továbbítására

- Idegrendszer: agy, gerincvelő, idegdúcok

- **Idegsejt** felépítése/működése:

- Sejtmag, sejttest

- Neuronok **kapcsolódása:**

- **szinapszis** (synapse) keresztül (kémiai/elektromos)

- Központi idegrendszer: nagyszámú kapcsolat (kimenet:  $\sim 10^3$ , bemenet:  $\sim 10^4$ )

- **Dendrit:** beérkező ingerületet a sejttest felé továbbítja


- **Axon:** hosszú nyúlvány

- Ingerület továbbítása a környező neuronok felé

- **Ingerület:** szétterjedő potenciál változás (akciós potenciál) a sejtmembránon




# Gerincvelői mozgató neuron vázaltos képe




a. dendrit, b. sejttest, c. sejtmag, d. axondomb, e. Swann-hüvely, f. Swann-sejt (mag), g. Ranvier-féle befűződés, h. végfácska (telodendrion) elágazódás



# Idegsejt működésének analógiája



# Neurális hálózat egy csomópontjának működése



# Neurális hálózat egy csomópontja



# Mesterséges neurális hálózatok: **Alapfogalmak**

# Neurális hálózat felépítése


- **Gráf modell:** *irányított, súlyozott gráf*
  - **Csomópontok** (*~idegsejtek*)
  - **Irányított élek** (*~idegsejtek kapcsolatai, jelátvivő csatornák*)
  - **Súlyok** (*~neuronok kapcsolatának erősségére*)

# Egy általános csomópont jelátvitele

- **Bejövő jelek** erőssége:  $x_j$
- **Súlyok:**  $w_{ij}$
- Csomópontba **belépő jel:**  $net_i$ 
  - súlyozott összeg

$$net_i = \sum_{j=1}^n w_{ij} x_j$$

# i-dik csomópont jelátvitele





# Formális leírás

- **Csomópontba belépő jel**

- Súlyok ( $W_i$ ) és a bemenetek ( $X$ ) vektorainak skalár szorzata:

$$net_i = w_i^T x$$


- **Csomópontból kilépő jel:**

$$y_i = f(net_i) = f(w_i^T x)$$

- **Aktivációs függvény:  $f()$**

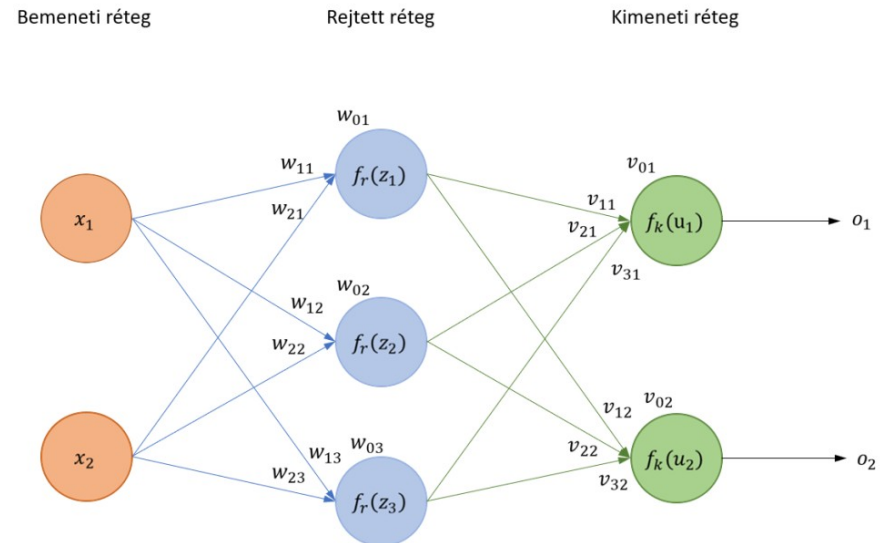
- *A hálózat az  $x$  vektort **leképezi** az  $y$  vektorba*

# Neurális hálózat csomópontjának általános működése



# Neurális hálózat felépítése

- **Gráf modell:** *irányított, súlyozott gráf*
  - Csomópontok
  - Irányított élek (*~jelátvivő csatornák*)
  - Súlyok (*~neuronok kapcsolatának erősségére*)
- **Hálózati topológia – csomópontok rétegekbe rendezettek:**
  - Összeköttetés (*általában*) csak a **szomszédos rétegekben** levő csomópontok között (*feed-forward network*).
  - Számos más megoldás is létezik.
- **Rétegek:**
  - *Szükséges rétegek:*
    - *bemeneti réteg,*
    - *kimeneti réteg,*
  - *Opcionális réteg:*
    - *rejtett-réteg(ek)*

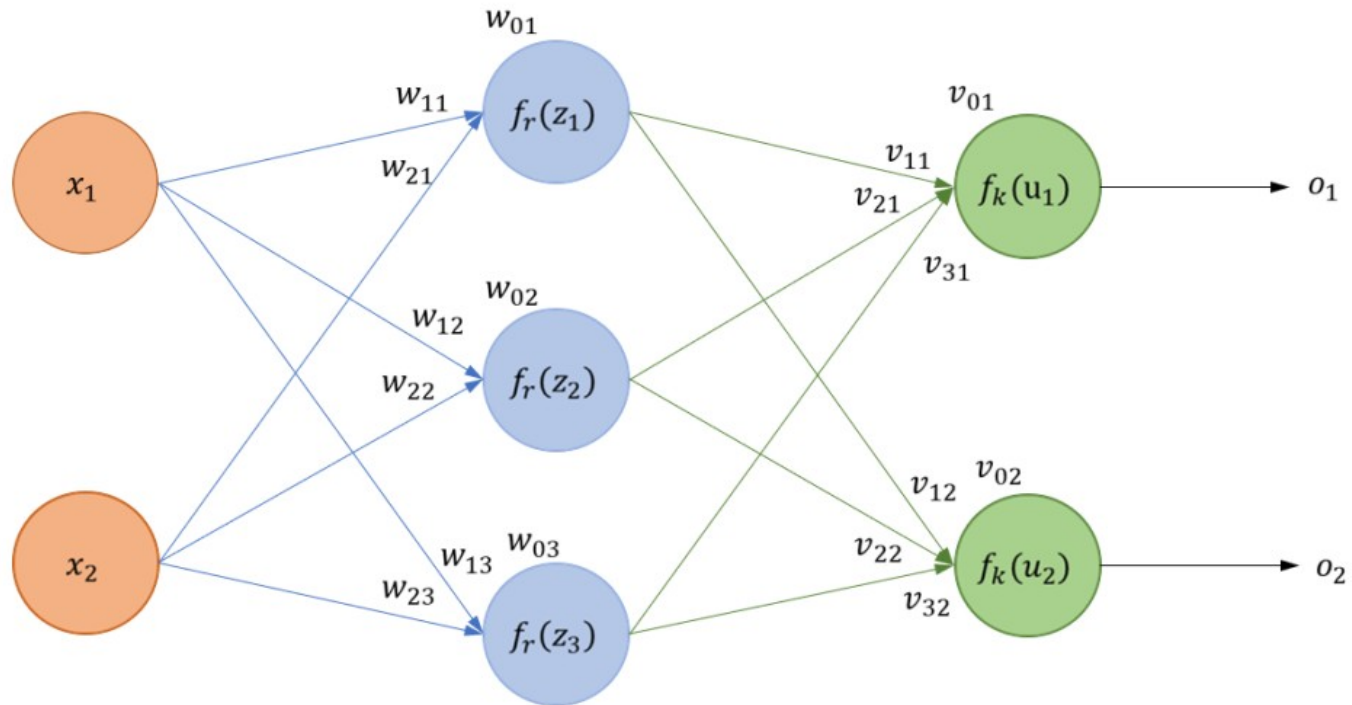


# Három rétegű hálózat

Bemeneti réteg

Rejtett réteg

Kimeneti réteg




# Aktivációs függvény ( $f()$ )

- A bemenet és a kimenet **kapcsolatának** leírása:
  - **aktivációs függvény**
  - **Nem lineáris** viselkedés meghatározása
- Egyszerű aktivációs függvény:
  - Heaviside vagy **egységugrás függvény**
- Számos más aktivációs függvényt használunk
  - Neurális háló típusától függően
- Változatok a kimeneti **értékkészletre**:
  - $\{-1, +1\}$  („bipoláris kimenet”)
  - $\{0, 1\}$  (bináris kimenet)

# Példák aktivációs függvényre


- **Signum függvény**

- Értékkészlet:  $\{-1, 1\}$
- Eltolás nélkül



- **Egységugrás fv.**


- Értékkészlet:  $\{0, 1\}$
- Eltolás = 2




# Példa folytonos aktivációs függvényre

- ***Sigmoid*** függvény
- → Folytonos kimeneti értékek előállítására

$$\sigma(x, \alpha) = \frac{1}{1 + e^{-\alpha x}}$$




# $\tanh()$



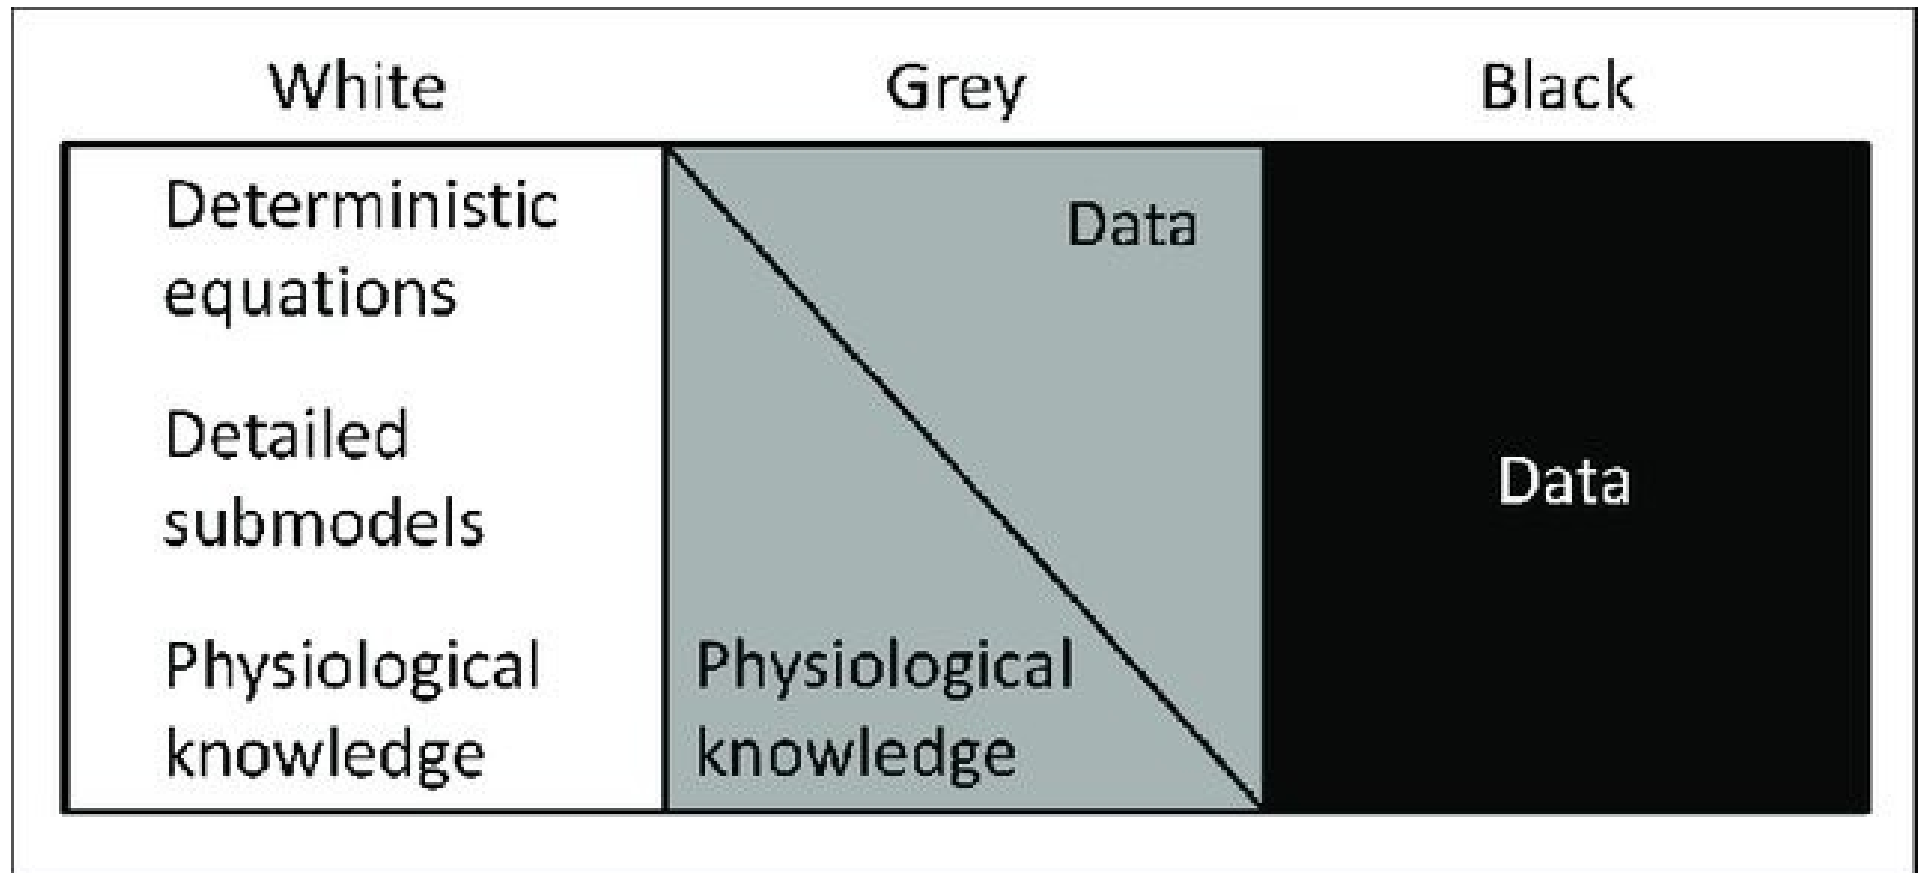


# Relu



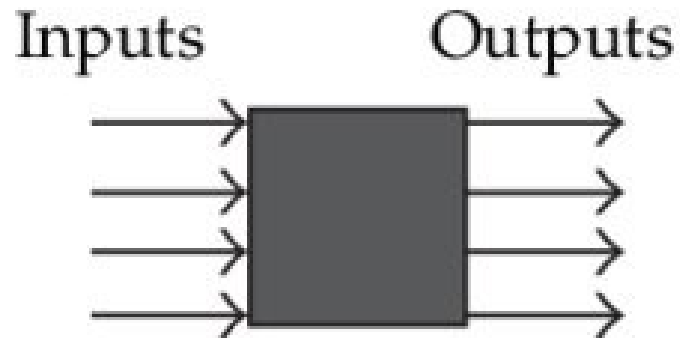
# Mesterséges neurális hálózatok: **Modell típusokról általában**

# Modell típusokról általában




# Black-box model vs. white-box model

Black box



White box



# Black-box modell vs. white-box modell

- **Black-box modell**


- A rendszer **bemenetei** és **kimenetei** alapján határozzuk meg a modellt.
- A modell interpretációja, a belső működés, a részrendszerek leírása **nem cél**.
- Az esetleges modell hibák értelmezése, a rendszerre vonatkoztatható következtetések levonása, a hibák elemzése, javítása **nehéz**.

- **White-box modell**


- A rendszerben **érvényes törvényszerűségek**, és részrendszerek **működésének ismeretében** határozzuk meg.
- A modell elemei és a valóságos rendszer elemei közötti **összerendelés megadható**.
- Az esetleges modell hibák értelmezése, a **rendszerre vonatkoztatható következtetések** levonása, a **hibák elemzése, javítása** általában **egyszerű**.

Mesterséges neurális hálózatok:  
**Tipikus neurális hálóval  
megoldható feladatok**

# Osztályozás: adatok osztályokba sorolása




# Osztályozás: adatok osztályokba sorolása






# Függvényközelítés



# Függvényközelítés

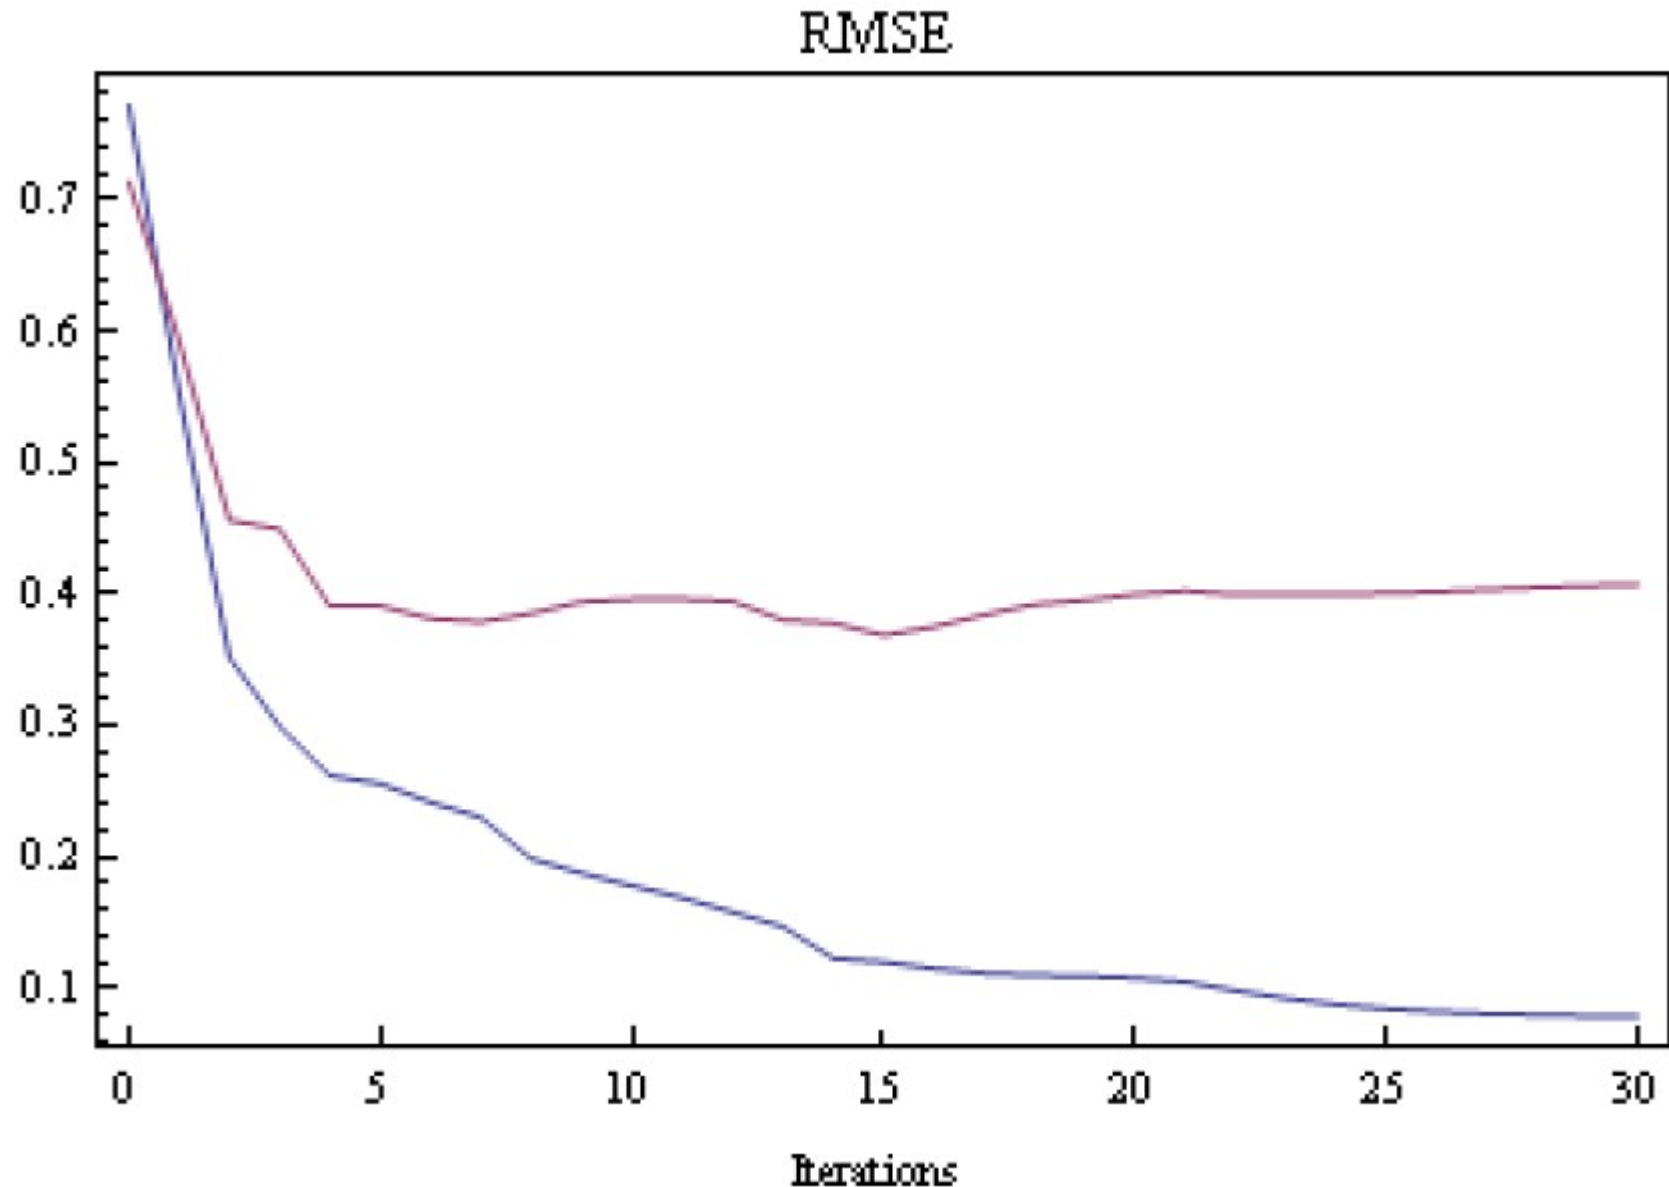


# Mesterséges neurális hálózatok: **Hálózat tanítása**

# Neurális hálózat tanítása

- Tanítás: **súlyok meghatározása**
  - Nagyon gyakran **iteratív** folyamat
  - Cél: teljesüljön a **kívánt bemenet/kimenet leképezés**
  - **Mintahalmaz:**
    - **Ismert** input-output párok
    - Számuk **lényegesen nagyobb**, mint a súlyok száma
    - Tanítás ~ többváltozós függvény minimalizálása
  - **Hibafüggvény:** az ismert bemenetekre az aktuális hálózat által adott válaszok és az elvárt kimenetek közötti eltérés jellemzése (mértéke):
    - Leggyakrabban alkalmazott **négyzetes hibafüggvény:**
      - a hálózat által adott és az ismert (helyes) kimenetek közötti értékek négyzetösszege
  - Tanítás elsődleges célja: a **hibafüggvény minimalizálása**

# Hibafüggvény változása a tanító és a validációs halmazon - példa




Mesterséges neurális hálózatok:  
**Hálózat tanításának általános problémái**

# Hálózat tanításának jellemzése


- Hálózat **általánosító képessége**
  - Tanulásban **részt nem vett** bemenetekre milyen „mértékben” ad helyes kimenetet
- Tanítás lehetséges gyakori hibái
  - **Túltanulás:** az általánosító képesség ugyan csökken a tanítás során, de a hálózat „megtanulja” a tanító halmaz elemeit
  - **Alultanulás:** a hálózat által biztosított leképzés hibája további tanulással csökkenthető

# Példa: Közelítendő függvény






# „Túltanulás” esete



Ugyan a mért hiba kicsi a tanító pontokon számolva, más pontokon vizsgálva viszont lényegesen nagyobb.  
A hálózat általánosító képessége alacsony.

# „Alultanulás” esete





A mért hiba a tanító pontokon számolva, ill. más pontokon vizsgálva hasonló, de viszonylag nagy, a tanítás folytatásával csökken.

# Hálózat tanításának jellemzése

- Hálózat **általánosító képessége**
  - Tanulásban **részt nem vett** bemenetekre milyen „mértékben” ad helyes kimenetet
- Általánosító képesség **meghatározása:**
  - Ismert input-output párok felosztása:
    - **Minta halmaz / validációs halmaz**
  - Általánosító képesség mérése:
    - **Hibafüggvény** segítségével, kiszámoljuk:
      - a minta halmazon ( $H_m$ ) és a
      - validációs ( $H_v$ ) halmazon.
  - Helyes mértékű tanítás:
    - A hiba a minta és a validációs halmazon **azonos nagyságrendben** van, ill. **együtt csökken** a tanítás folytatásával ( $H_m \sim H_v$ )
    - **Túltanulás:**  $H_m$ -et csökkenteni tudom, de  $H_v$ -t már nem a tanítás folytatásával
    - **Alultanulás:** a tanítás folytatásával  $H_m$  még lehetne csökkenteni úgy, hogy  $H_v$  is csökkenjen

# Hiba változása a tanítás során




# Mesterséges neurális hálózatok: **Hálózatok tanításának típusai**

# Hálózatok tanításának típusai

- Tanítás módszerének típusa:
  - **Felügyelt tanítás**
    - Input-output adatpárok használata a súlyok meghatározására a tanítás során
    - Jellemző megoldandó feladattípus: **függvény közelítés, adat-osztályozás**
    - Hibafüggvény: az input-output adatpárok alapján számoljuk
  - **Felügyelet nélküli tanítás**
    - Csak a bemeneti (input) adatok használata a súlyok meghatározására a tanítás során
    - Jellemző megoldandó feladattípus: **adat-klasszifikáció**
    - Hibafüggvény: az eredményre vonatkozó valamilyen a priori ismeretek alapján a kimeneti leképzés, hálózati súlyok stb. alapján számoljuk
      - pl. az osztályozás „jósága” alapján

# Felügyelt és felügyelet nélküli tanítás osztályozási feladat esetén




# Mesterséges neurális hálózatok: **Hálózatok szimulációja**



# Neurális hálózatok szimulációja

- **Hálózatok szimulációja:**

- Input-output leképzés megadása különböző bemenetek esetén



$$\begin{pmatrix} x_3 \\ x_4 \\ x_5 \end{pmatrix} = \begin{pmatrix} w_{13} & w_{23} \\ w_{14} & w_{24} \\ w_{15} & w_{25} \end{pmatrix} \begin{pmatrix} x_1 \\ x_2 \end{pmatrix}$$


$$x_6 = (w_{36} \quad w_{46} \quad w_{56}) \begin{pmatrix} f(x_3) \\ f(x_4) \\ f(x_5) \end{pmatrix}$$

$$y_6 = f(x_6)$$

# Mesterséges neurális hálózatok: **Perceptron hálózat**

# Egyrétegű perceptron hálózat

- **Egyrétegű perceptron hálózat:**  
**Rejtett réteg nélküli** neurális hálózat
- Átviteli függvény:
  - **Signum függvény**
- Alkalmazási terület:
  - Osztályozás, alakfelismerés
- Létezik bináris változata
  - 0,1 leképezés
  - Egyszerűbb tanítás
- Csak **lineárisan szeparábilis** problémák megoldására alkalmazható (l. később)
- Rosenblatt (1962)




# A eltolás (bias) alkalmazása a küszöbérték helyett

- Példa:
  - AND logikai függvény megvalósítása
  - **X1, x2** bemenetek; **w1, w2**, súlyok;  $\tau$  eltolás

# A eltolás (bias) alkalmazása a küszöbérték helyett

- Példa:
  - AND logikai függvény megvalósítása
  - $x_1, x_2$  bemenetek;  $w_1, w_2$ , súlyok;  $\tau$  eltolás




Az AND függvény input - output táblázata

x1	x2	y
0	0	0
0	1	0
1	0	0
1	1	1

$$y(x_1, x_2) = f(w_1 x_1 + w_2 x_2 - \tau)$$

# AND döntési felülete




# Tanítás és a döntési felület

- **Döntési felület** osztályozási feladat esetén: az a felület, ami elválasztja a különböző kimenetet eredményező bemeneti értékeket tartalmazó **bemeneti tartományokat**
- Döntési felület az egyrétegű **perceptron hálózat** esetén egy **n-1 dimenziós felület**, ahol n a probléma bemeneti változóinak száma
- A **tanítás során** implicit módon **a döntési felületet határozzuk meg**, azt „mozgatjuk” a súlyok változtatásával
  
- **AND** esetén a döntési felület alapján a súlyok meghatározása:  
 $x_2 = -a \cdot x_1 + b \leftarrow$  *döntési felület egyenlete*  
 $0 = w_2 \cdot x_2 + w_1 \cdot x_1 - \tau \leftarrow$  *neurális háló itt „vált” (l. háló egyenlet+aktivációs fv.)*  
 $x_2 = -w_1/w_2 \cdot x_1 + \tau/w_2$
- Döntési felület paraméterei és a súlyok közötti összefüggések:  
 $a = w_1/w_2, b = \tau/w_2 \leftrightarrow w_2 = \tau/b, w_1 = \tau \cdot a/b$

# Hálózat megvalósítása bias alkalmazásával

- Aktivációs függvény küszöbértéke: 0, az un. **bias („eltolás”)** csomópont súlyával ( $\tau$ ) állítható a küszöbérték






# Perceptron hálózat: példa

- Van három csoportba sorolható ponthalmazom a kétdimenziós térben:
  - Koordináták:  $X_1$ ,  $X_2$


# Perceptron hálózat: input pont halmaz




# Perceptron hálózat: példa

- Van három csoportba sorolható ponthalmazom a kétdimenziós térben:
  - Koordináták:  $X_1, X_2$
- A hálózat **kimeneteit** az egyes **csomópontokhoz** rendeljük:
  - A csoporthoz rendelt kimeneten az 1 érték jelezze az adott kimenethez tartozó pontot
  - Kimenetek:  $y_1, y_2, y_3$
- Perceptron hálózat: nincs rejtett réteg


# Perceptron hálózat: hálózati topológia



# Perceptron hálózat: tanító halmaz



# Perceptron hálózat: validációs halmaz



# Perceptron hálózat tanítása

- **Tanuló** halmaz:
  - $m$  darab  $\{\mathbf{x}^{(k)}, \mathbf{d}^{(k)}\}$ ,  $k = 1, 2, \dots, m$  input-output pár
  - $\mathbf{x}^{(k)}$ ,  $\mathbf{d}^{(k)}$  vektorok
  - $\mathbf{x}^{(k)}$   $k$ -adik inputhoz a  $\mathbf{d}^{(k)}$  output tartozik
- Feltesszük, hogy  $m > n$ ,  
akkor a következő egyenlet **túlhatározott**:  
( $m$  egyenlet,  $n$  ismeretlen)


$$d^{(k)} = \text{sign} \left( \sum_{i=1}^n x_i^{(k)} w_i \right) \quad k = 1, 2, \dots, m$$

# Tanítás lépései


- 1) Kezdeti súlyok adása: pl. véletlen súlyok  $[0,1]$  (  $\mathbf{w}(n) := \text{rand}()$ ;  
 $\mathbf{k} := \mathbf{1}$  ( $k$ : lépés szám)
- 2)  $\mathbf{x}^{(k)} \rightarrow \mathbf{y}^{(k)}$  kiszámítása ( $k$ -dik bemenetre adott válasz a  $\mathbf{w}(n)$  alapján)
- 3) Ha  $\mathbf{y}^{(k)} \neq \mathbf{d}^{(k)} \rightarrow \mathbf{w}(n+1) = \mathbf{w}(n) + \Delta \mathbf{w}$   
 $\Delta \mathbf{w} = \nu \cdot \mathbf{d}^{(k)} \cdot \mathbf{x}^{(k)}$  ,  $0 < \nu < 1$   
( $\nu$ : tanulási paraméter,  $\mathbf{d}^{(k)} = \{-1; +1\}$ , a súlyokat az  $\mathbf{x}^{(k)}$  irányába mozgatjuk)  
Ha  $\mathbf{y}^{(k)} = \mathbf{d}^{(k)} \rightarrow \mathbf{w}(n+1) = \mathbf{w}(n)$
- 4)  $\mathbf{k} := \mathbf{k} + \mathbf{1}$ , GOTO 2) (egymás után vesszük a bemenet/kimenet párokat)  
Megállási feltétel: egyik input esetén sem kellett a súlyokat változtatni!  
(Rosenblatt és Novikoff tétel: változtatások száma korlátos  $\rightarrow$  véges lépés)



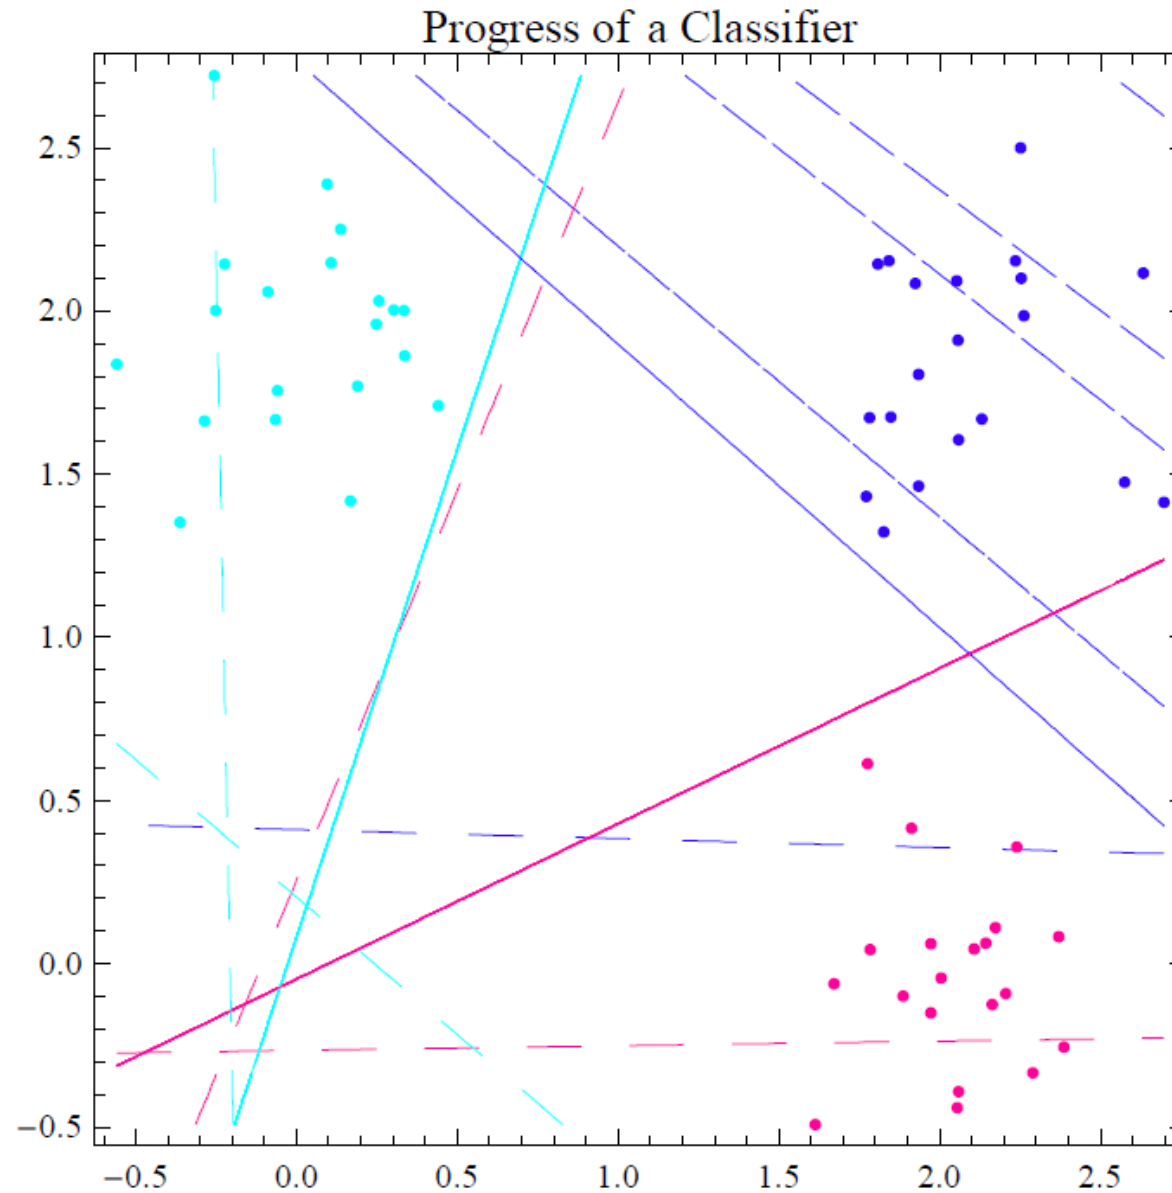
# Iteratív tanítás: hibafüggvény változása iterációnként




# Az eredményül kapott vágási síkok



# Vágási síkok változása az iterációk során



# Tanító és validációs pontok a vágási síkokkal




# Perceptron hálózat értékelése


- **Sikeres** osztályozás:
  - Jól definiált tartományok az egyes osztályokhoz
- **Hátrány:** A paraméter térben (síkon) bizonyos tartományok **nem tartoznak egyértelműen** a megkülönböztetett osztályokhoz
- Csak **lineárisan szeparábilis** (szeparálható) problémák megoldására alkalmazható

# Mesterséges neurális hálózatok: **Perceptron hálózat demó**

# Perceptron példa három osztályra: bemeneti adathalmaz




# Perceptron példa három osztályra: eredmény - szeparációs hipersíkok







# Perceptron példa három osztályra: eredmény - szeparációs hipersíkok




# Perceptron példa három osztályra: eredmény - tartományok




# Perceptron példa két osztályra: bemeneti adathalmaz



# Perceptron példa két osztályra: osztályozás függése a kezdeti értékektől




# Perceptron példa két osztályra: osztályozás függése a kezdeti értékektől



# Mesterséges neurális hálózatok: **Döntési felület**

# Döntési sík: egy egyszerű példán keresztül

- Osztályozási probléma
- Bemenetek:
  - $x_1, x_2$
- Kimenet:
  - $y$
- Perceptron hálózat, súlyok:
  - $w_1=0,5$
  - $w_2=0,25$
- Eltolás:
  - $Z=2$
- $\{x_1, x_2\}$  síkon két kimeneti értéktartomány:
  - $y=0$
  - $y=1$
- Elválasztó felület:
  - Egyenes
- Magasabb dimenzióban:
  - **Döntési felület:**  
*Hálózat kimeneti értékei alapján meghatározható bemeneti értéktartományokat elválasztó felület*



# Lineárisan szeparálható probléma

- Adott:
  - egy  $n$  dimenziós térben,
  - különböző osztályokba tartozó pontok.
- **Lineárisan szeparálható** az adott probléma:
  - Az egyes osztályok elkülönítése lehetséges egy  $n-1$  dimenziós hipersíkkal.




# Backpropagáció (backpropagation) hálózatok

# Backpropagation hálózatok jellemzői

- Folytonos kimeneti értékek előállítására:
  - Aktivációs függvény általában: **szigmoid függvény**
  - Általában  $\alpha = 1$

$$\sigma(x, \alpha) = \frac{1}{1 + e^{-\alpha x}}$$




# Backpropagation hálózatok jellemzői

- **Rejtett rétegek száma:**
  - Egy vagy több
  - Erősen **nemlineáris** viselkedés
- **Gyakori alkalmazásai:**
  - Nemlineáris folytonos **függvények közelítése**
  - Nemlineáris **osztályozási feladatok**


# Példa: Függvény közelítése diszkrét pontok alapján

- Függvény:


$$y(x) = \sin(x) \cos\left(\frac{x}{4}\right)$$




# Tanításhoz használt pontok



# Hálózati topológia



# Hibafüggvény a tanítás során




# A függvény közelítése

- A tanítás utáni **súlyok**:
  - Bemeneti, kimeneti súlyok, bias
- **Aktivációs függvény** behelyettesítése:
  - hálózat leképzése
- A **hálózat leképzése** adja a **függvény közelítés** analitikus alakját:

$$y = 24.7998 - \frac{5.88779}{1 + e^{8.10076 - 1.10901x}} - \frac{9.85332}{1 + e^{2.69175 - 0.990433x}} - \frac{44.0739}{1 + e^{-0.194443 + 0.156156x}}$$




# Lokális hiba változása




# Nemlineáris osztályozási példa

- Hálózat: *Backpropagation* hálózat *sigmoid* aktivációs függvénnel
- Topológia:
  - 2 rejtett réteg
  - 1 réteg: 3 neuron
  - 2. réteg: 5 neuron
- Osztályozandó pontok:



# Tanítás eredménye



# Backpropagation hálózat tanítása

- **Backpropagation** módszer
  - Hibafüggvény minimumkeresése
    - Legmeredekebb csökkenés módszere
    - Második derivált konstans
  - Szigmoid aktivizálós függvény:
    - Deriváltja kifejezhető magával a függvénnyel

# Tanítás módszere: rejtett réteg nélküli hálózat esetén

- Delta szabály (rejtett réteg nélküli hálózat esetén)

$$R(w) = (y - \sigma(wx))^2$$

$$w_{i+1} = w_i - \left( \frac{dR(w)}{dw} \right)_{w=w_i} \xi$$




$$w_{i+1} = w_i + \eta \delta_i X$$

$$\delta_i = (y - y_i)(1 - y_i)y_i$$

$$y_i = \sigma(w_i X)$$

$$w_{i+1} = w_i + 2(y - \sigma(w_i X))(1 - \sigma(w_i X))\sigma(w_i X)X\xi$$

- $R(w)$ : négyzetes hibafüggvény (ezt szeretnénk iteratív algoritmussal minimalizálni)
- $W(i+1)$ : alkalmazandó súly az  $(i+1)$ -dik iterációban
  - legmeredekebb csökkentés módszerével számoljuk, második deriváltat konstansnak feltételezve
- $W(i)$ : súly az  $(i)$ -dik iterációban ( $\eta=2\xi$ )
- $y(i)$ : az  $i$ -dik iterációban számolt súllyal a kimenet
- $y$  az elvárt kimenet  $x$  bemenet esetén



### 1. Forward




### 2. Backpropagation

Taking the derivative of the loss with respect to each weight parameters in the network.


Increase  $b$

Increase  $w_i$   
in proportion to  $a_i$

Change  $a_i$   
in proportion to  $w_i$



### 3. Stepping the optimizer




----- epochs: 0

# Backpropagation hálózat tanítása: általános eset

- **Backpropagation** módszer
  - Általánosított tanuló eljárás
- **Delta szabály** alapján
  - Sigmoid aktivizálós függvényt alkalmazó hálózatok esetén
- Súlyok meghatározása akár nagyméretű nemlineáris optimalizációs problémák esetén
- **Lépések:**
  - **A) Propagation:** bemenet  $x(i) \rightarrow w(i) \rightarrow$  kimenet:  $y(i)$
  - **B) Backpropagation:**  $w(i+1) \leftarrow w(i) \leftarrow (y-y(i))$
  - Több réteg esetén a sorrend:
    - output rétegtől az input réteg felé


# Backpropagation alkalmazása több réteg esetén






Mesterséges neurális hálózatok:  
**Hálózat tanításának általános problémái**


# Közelítendő függvény



# „Túltanulás” esete



# „Alultanulás” esete



# Megfelelő tanulás biztosítása: módszerek I.

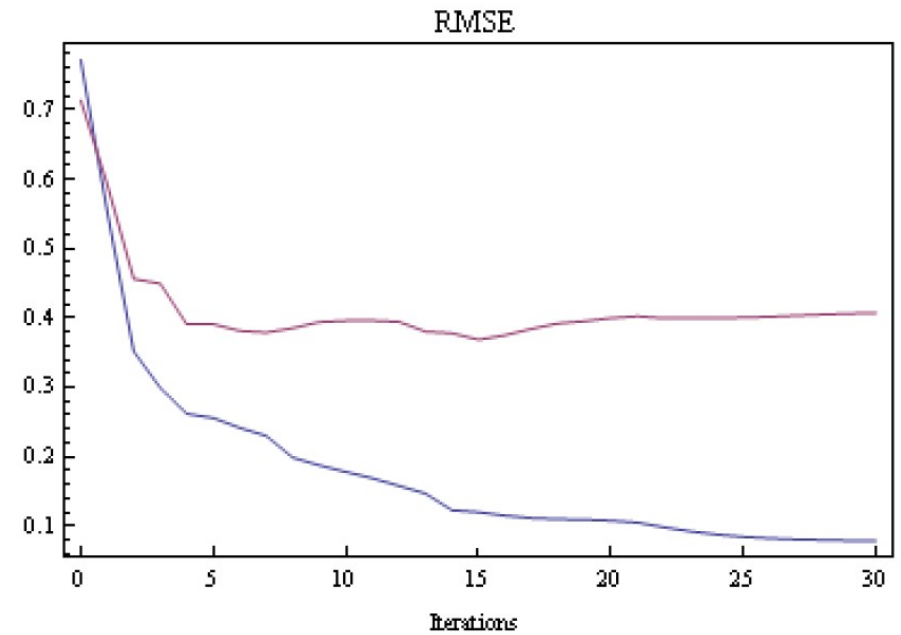

**A)** Alul-, ill. túltanulás elkerülése **megfelelő hálózati topológia** választásával:

- megfelelően választott rejtett rétegbeli csomópont-szám;
- tanulás után validáció.

**B)** **Korai leállítás** módszere

- **tanuló-** és egy **validációs** halmaz,
- addig tanítunk, amíg a validációs halmazon **is csökken** a hiba.

# Korai leállítás módszere: hiba a tanító és a validációs halmazon



# Megfelelő tanulás biztosítása: módszerek II.

## C) Regularizáció a túltanulás elkerülésére

- Túltanulás esetén a leképzés gradiense általában nagy
- A hibafüggvény megváltoztatása
  - **Cél 1)** hálózat **hibájának** csökkentése

$$R(w) = \sum_{j=1}^n \left( y_j - \sigma(w^T x_j + b) \right)^2$$

- **Cél 2)** hálózat által megvalósított függvény **gradiensének minimalizálása**

$$R(w) = \sum_{j=1}^n \left( y_j - \sigma(w^T x_j + b) \right)^2 + \delta_w w^T w$$

# Radiál Bázis Függvény (RBF) hálózatok




# RBF hálózat

- Aktivációs függvény
  - **Radiál Bázis Függvény**

$$y(x) = e^{-\lambda(x-c)^2}$$


- Harang alakú görbe
- Paraméterek:
  - $\lambda$  harang „nyílásszöge”,  $c$  középpontja (~eltolás)
- Jól alkalmazható hálózat **függvény közelítésre.**

# Példák RBF aktivációs függvényre



# Általános RBF hálózat felépítése

- **Nincs rejtett réteg**
- Rétegek:
  - **Bemeneti réteg:**
    - $n$  db csomópont ( $n$  bemenet)
  - **Aktív réteg:**
    - $nb$  db csomópont
- Bias csomópont
  - Súlyozható eltolás a kimeneten
- Egy kimeneti csomópont
  - Az aktív réteg kimenetek (és a bias) összege
- Lehetséges lineáris tag




RBF példa: kétváltozós függvény  
közelítése

# Kétváltozós függvény közelítése

- Közelítendő függvény: *Franke teszt függvény*

$$f(x, y) = \frac{3}{4} e^{-\frac{1}{4}((9x-2)^2+(9y-2)^2)} + \frac{3}{4} e^{-\frac{1}{49}(9x+1)^2-\frac{1}{10}(9y+1)^2} +$$
$$\frac{1}{2} e^{-\frac{1}{4}((9x-7)^2+(9y-3)^2)} - \frac{1}{5} e^{-(9x-4)^2-(9y-7)^2}$$


# Közelítendő függvény



# Mintavételi pontok választása


- Valóság: általában **nem szabályosan mintavételezett** ismert mintáim vannak
- Cél:
  - „egyenletes” mintavételezés
- **Pseudo-random ponthalmaz**
  - Gyakran vannak „csomósodási” pontok
- **Halton-féle pontok:**
  - egyenletesen elosztott pontok egy adott tartományban

$$x, y \in [0, 1]$$




# Háromszögfelbontáson alapuló spline függvény közelítés eredménye

$x, y \in [0, 1]$





# A hiba alakulása a tanítás során




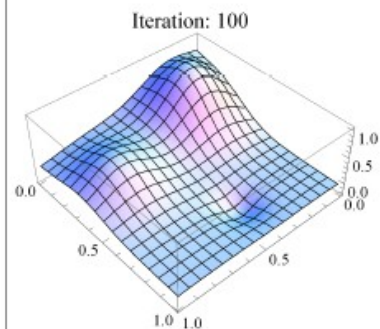



# A tanítás eredményeként kapott leképzés

- Hálózati topológia:
  - 6 csomópont
- Leképzés:

$$\begin{aligned} & -15.3348 - 392.858 e^{-1.81497 (0.412253+x)^4 - 1.81497 (-0.795555+y)^4} + \\ & 388.71 e^{-1.82951 (0.409158+x)^2 - 1.82951 (-0.795431+y)^2} - \\ & 0.187153 e^{-94.7028 (-0.444808+x)^2 - 94.7028 (-0.775338+y)^2} + \\ & 0.446418 e^{-22.3538 (-0.77959+x)^2 - 22.3538 (-0.335169+y)^2} + \\ & 0.770331 e^{-20.2089 (-0.216997+x)^2 - 20.2089 (-0.212042+y)^2} + \\ & 1237.5 e^{-0.00746198 (-23.8598+x)^2 - 0.00746198 (0.822984+y)^2} - 9.40744 x + 0.51159 y \end{aligned}$$


# Kezdeti leképzés tanítás előtt






A leképzés a  
tanítás egyes  
lépései után


# Az eredményül kapott leképzés



# A leképzés hibája



# A leképzés hibája



# Összefoglalás

- **RBF hálózatok**

- Jól használhatók **folytonos függvények** közelítésére

- RBF hálózatok univerzális approximátorok

- Megfelelő számú – és eloszlású – tanító elem esetén a hiba leszorítható

- Hálózat tanítása:

- Viszonylag egyszerű tanítás

- Tanító pontokat egyszer alkalmazzuk