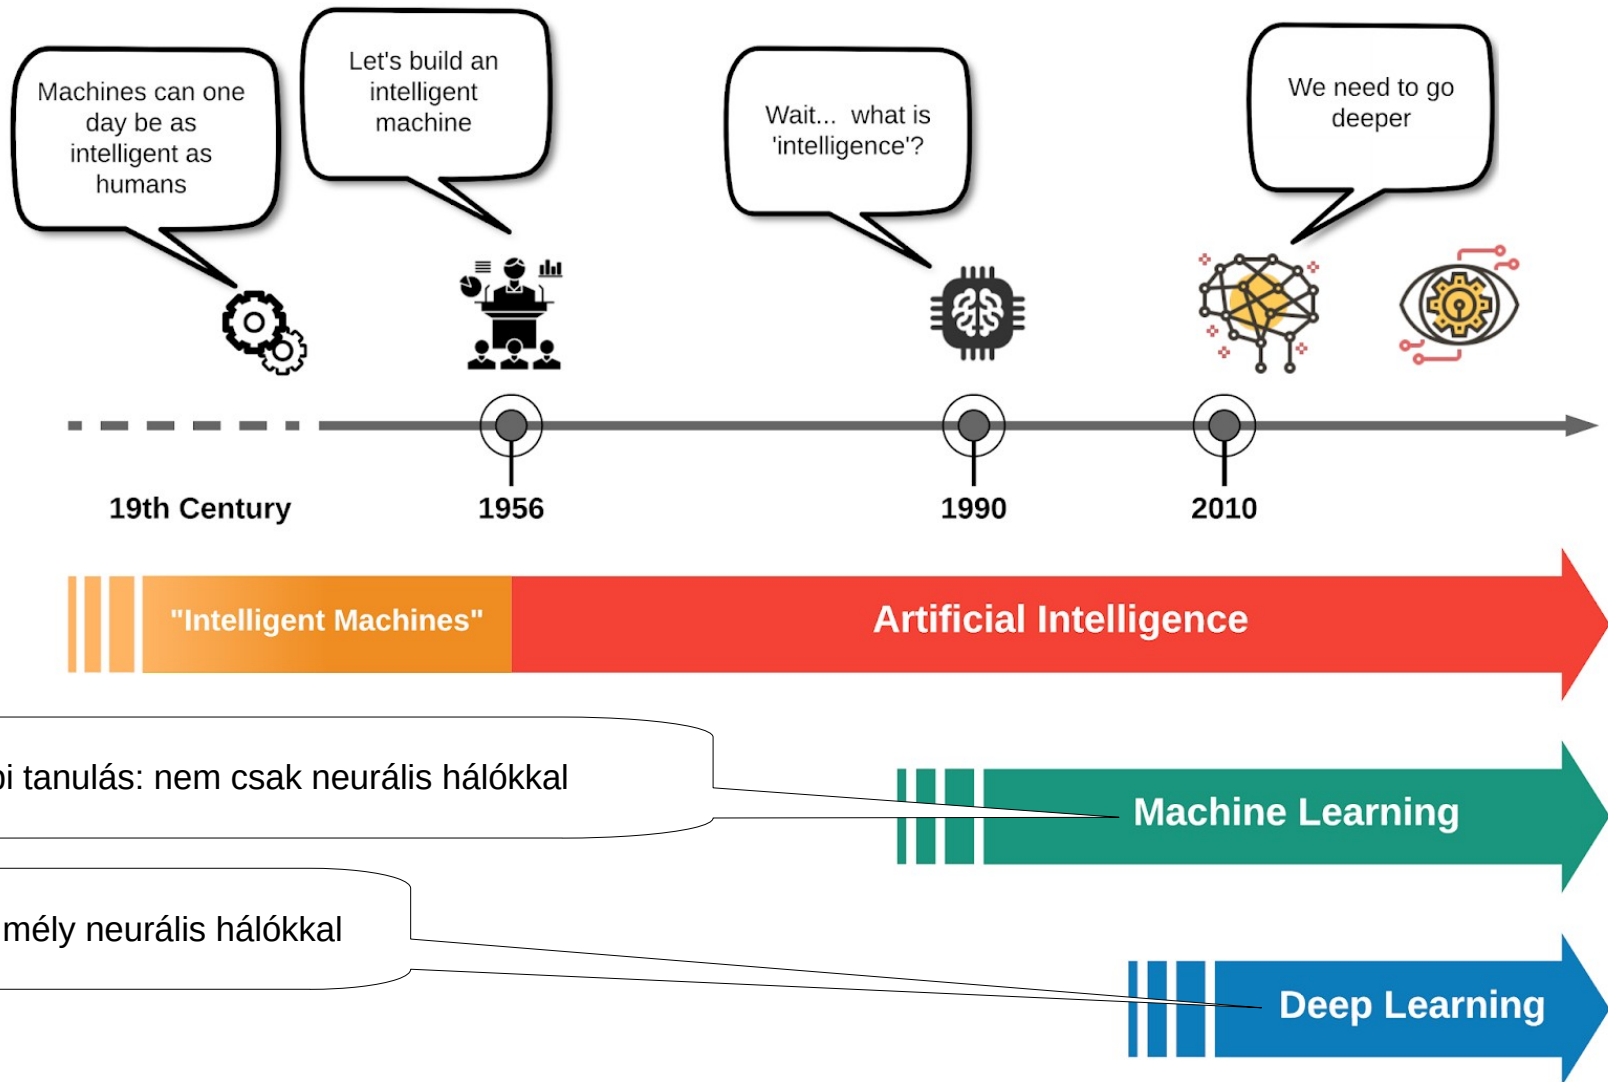


Mesterséges neurális hálózatok

Benyó Balázs, BME
bbenyo@iit.bme.hu

Mesterséges neurális hálózatok: **Neurális hálózatok története**

Fontos fogalmak



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.

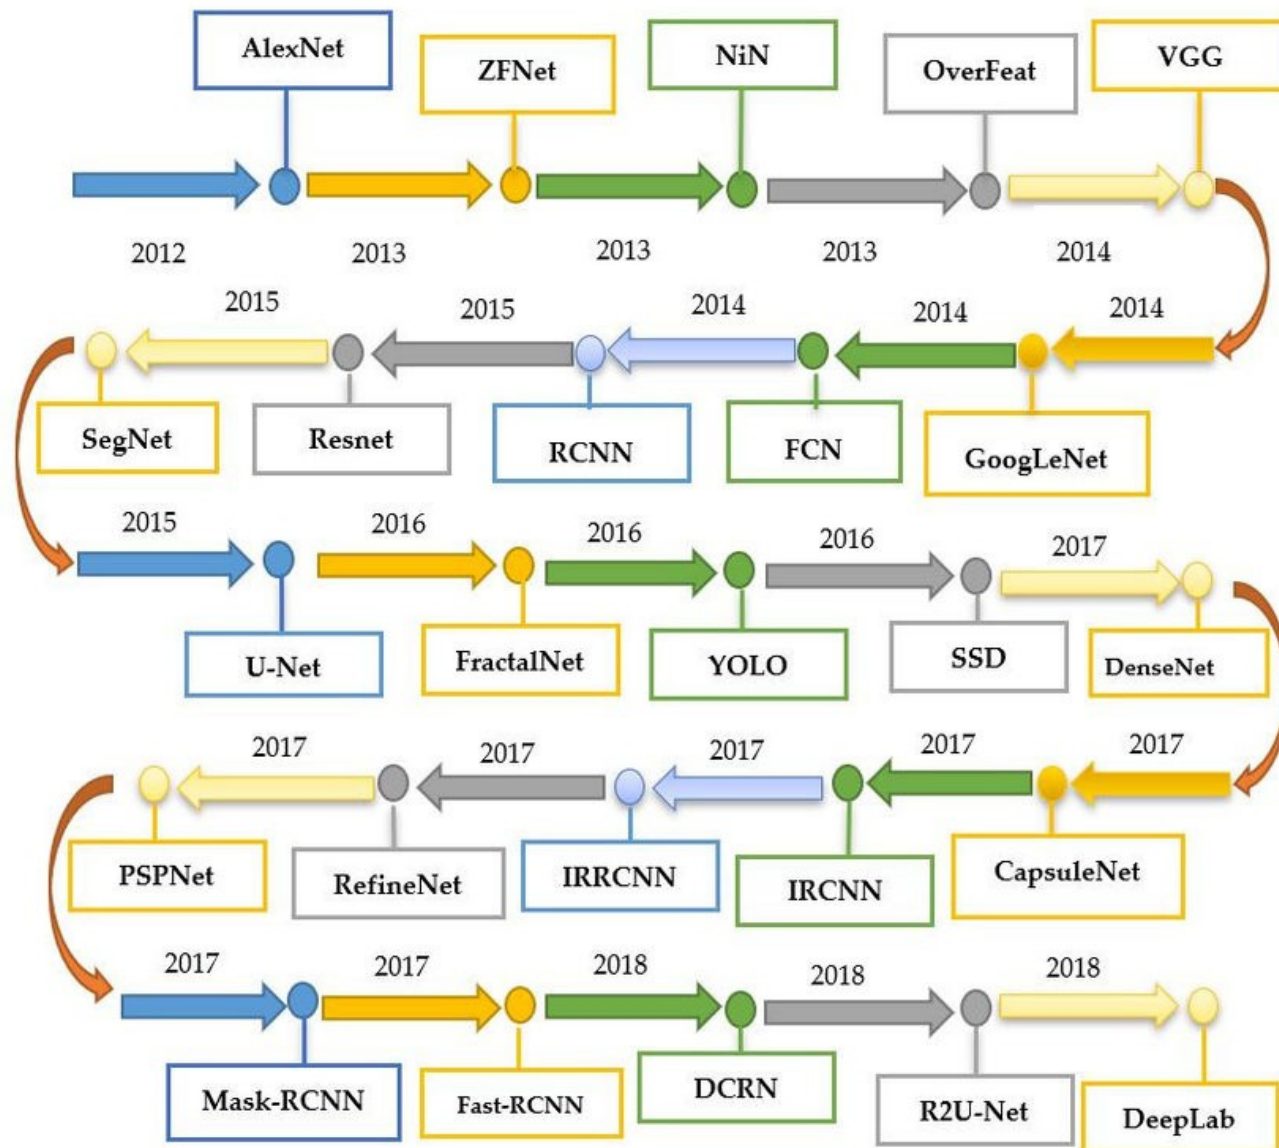
American Institute of Physics began what has become an annual meeting - **Neural Networks for Computing**.

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

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

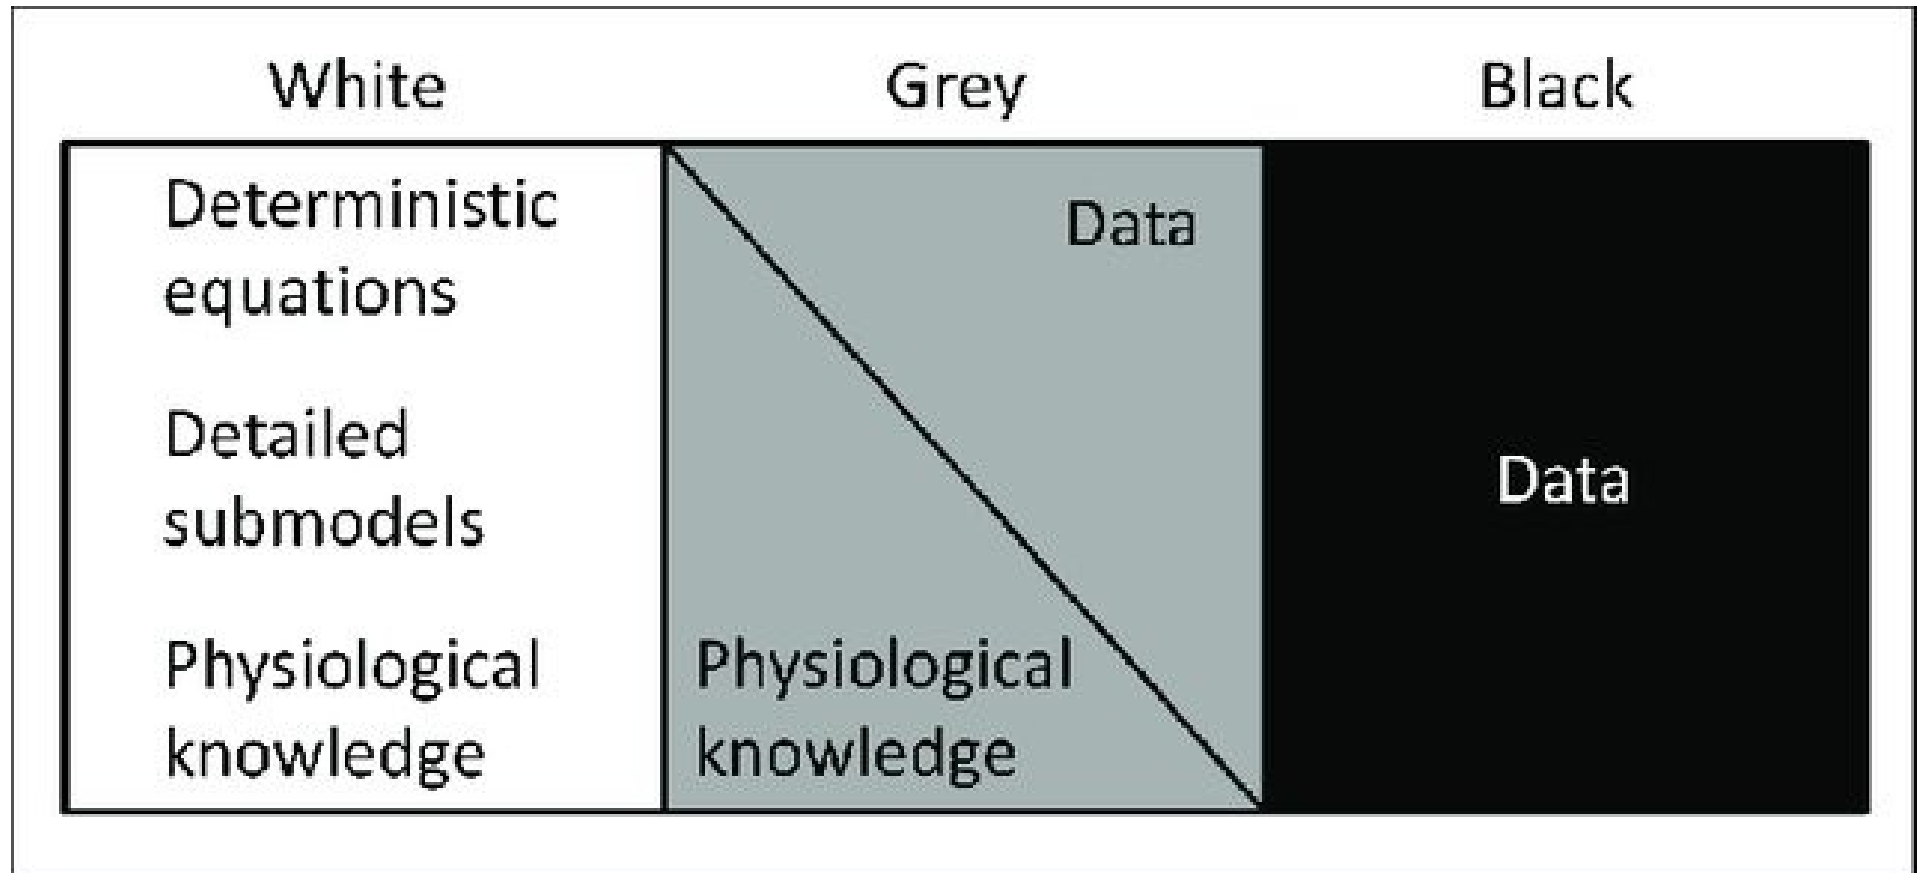
Neural networks discussions are prevalent; the future is here!

Konkrét neurális háló típusok megjelenési ideje a közelmúltban



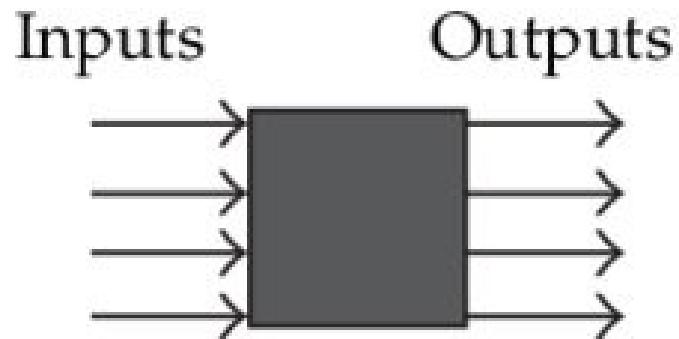
Mesterséges neurális hálózatok: **Modellek típusai**

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 vonatkozatható 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 vonatkozatható következtetések** levonása, a **hibák elemzése, javítása** általában **egyszerű**.

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

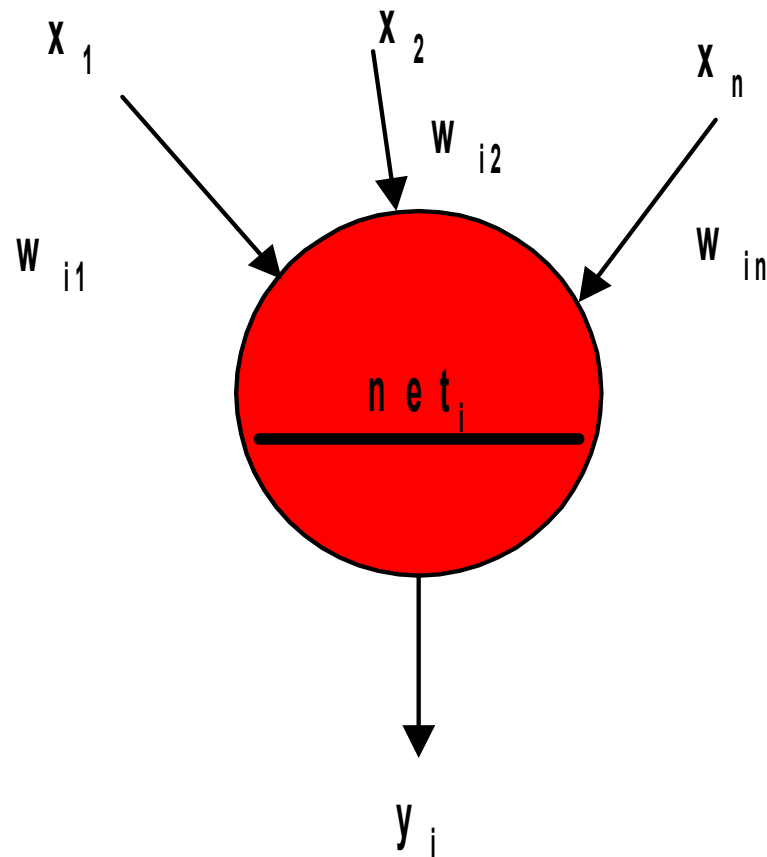
- **Gráf modell:** *irányított, súlyozott gráf*
 - **Csomópontok** (*~idegsejtek*)
 - **Irányított élek** (*~idegsejtek kapcsolatai, jelátvivő csatornák*)
 - **Súlyok** (*~neuronok kapcsolatának erősségére*)

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: $f()$**

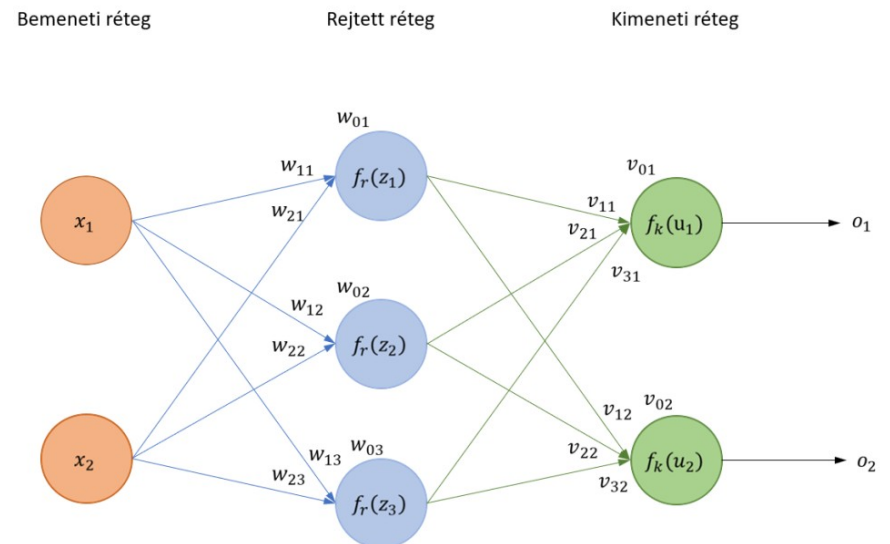
- *A hálózat az x vektort **leképezi** az y vektorba*

Neurális hálózat csomópontjának általános működése



Neurális hálózat felépítése (klasszikus előrecsatolt hálózat)

- **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)

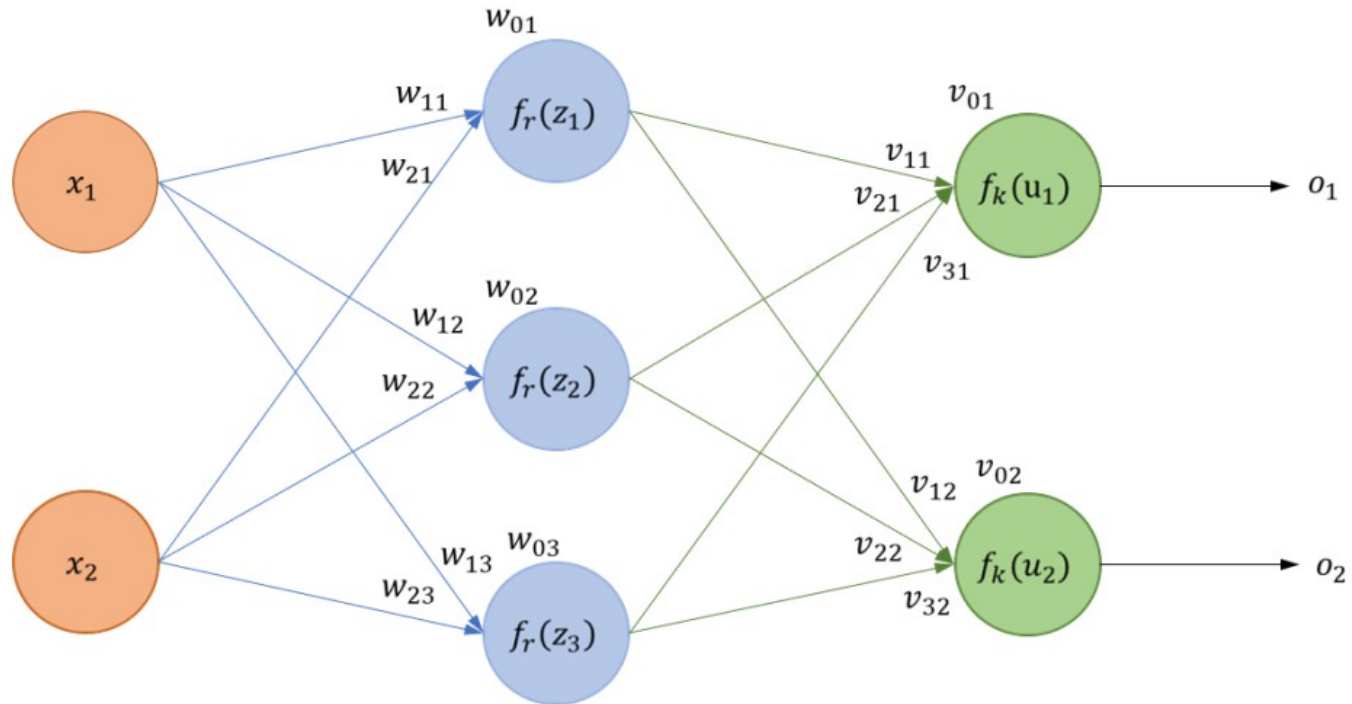


Három rétegű hálózat

Bemeneti réteg

Rejtett réteg

Kimeneti réteg




Aktivációs függvény ($f()$)

- A csomópont bemenetének és a kimenetének a **kapcsolatát** leíró függvény:
 - **aktivációs függvény** – általában nem lineáris
 - A hálózat **nem lineáris** viselkedését biztosítja
- Egyszerű aktivációs függvények:
 - 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

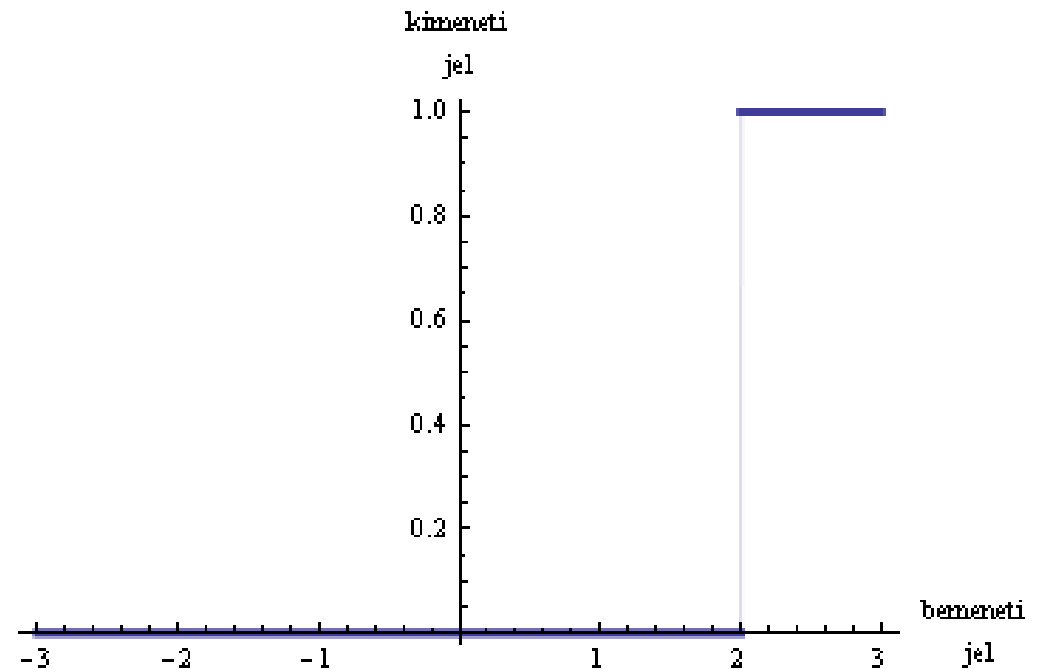
- **Signum függvény**

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



- **Egységugrás fv.**


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




Példa folytonos aktivációs függvényre

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


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



$\tanh()$




Relu




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: **a csomópontokat összekötő súlyok meghatározása**
 - Nagyon gyakran **iteratív** folyamat
 - Cél: teljesüljön a **kívánt bemenet/kimenet leképezés**
 - A tanításhoz **tanító mintahalmazt** használunk:
 - **Ismert** input-output adat-párok
 - Számuk **lényegesen nagyobb**, mint a súlyok száma
 - Tanítás ~ többváltozós **hibafüggvény** minimalizálása
 - **Hibafüggvény**: az ismert bemenetekre az aktuális hálózat által adott válaszok és az elvárt kimenetek közötti eltérés kvantitatív jellemzése:
 - 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



Hálózat tanításának jellemzése


- Hálózat **általánosító képessége**
 - Tanulásban **részt nem vett** bemenetekre milyen „mértékben” ad helyes kimenetet
 - Gyakorlati **mérése** (becslése): bemeneti mintahalmaz felosztása – hiba mértéke a **tanításban részt nem vett** bemeneti minták esetén
- Tanítás lehetséges gyakori hibái
 - **Túltanulás**: a hálózat hibája ugyan csökken a tanítás során, de a hálózat „megtanulja” a tanító halmaz elemeit
 - **Alultanulás**: a hálózat által biztosított leképzés hibája további tanulással csökkenthető

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:** a hálózat hibája csökken, így látszólag nő az általánosító képesség, de a hálózat „megtanulja” a tanító halmaz elemeire adandó választ, vagyis az általánosító képesség növekedése csak látszólagos
 - **Alultanulás:** a hálózat által biztosított leképzés hibája további tanulással csökkenthető


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**


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

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; τ eltolás

A eltolás (bias) alkalmazása a küszöbérték helyett

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




Az AND függvény input - output táblázata

x_1	x_2	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 paramétereit és a súlyok közötti összefüggéseket:
 $a = w_1/w_2, b = \tau/w_2 \leftrightarrow w_2 = \tau/b, w_1 = \tau \cdot a/b$

Hálózat megvalósítása bias alkalmazásával


- Aktivációs függvény küszöbértéke: 0, az un. **bias („eltolás”)** csomópont súlyával (τ) 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 $[0,1]$ ($\mathbf{w}(n) := \text{rand}()$;
 $\mathbf{k} := 1$ (k : lépés szám)
- 2) $\mathbf{x}^{(k)} \rightarrow \mathbf{y}^{(k)}$ kiszámítása (k -dik bemenetre adott válasz a $\mathbf{w}(n)$ alapján)
- 3) Ha $\mathbf{y}^{(k)} \neq \mathbf{d}^{(k)} \rightarrow \mathbf{w}(n+1) = \mathbf{w}(n) + \Delta \mathbf{w}$
 $\Delta \mathbf{w} = \nu \cdot \mathbf{d}^{(k)} \cdot \mathbf{x}^{(k)}$, $0 < \nu < 1$
(ν : 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) $\mathbf{k} := \mathbf{k} + 1$, 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




Perceptron demo

- Perceptron tanítása:
 - Két bemenet
 - Két osztály és három osztály esetén
- <https://colab.research.google.com/drive/1H8EWHqw5bmMqqBYezGWXbaTliWkShLIO?usp=sharing#scrollTo=eYQMkNcII-pC>

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.