

Mit látnak a robotok?

Bányai Mihály
Matemorfózis, 2017.

Vizuális feldolgozórendszerek feladatai

Mesterséges intelligencia és idegtudomány

Mesterséges intelligencia és idegtudomány

- Párhuzamos problémák

Mesterséges intelligencia és idegtudomány

- Párhuzamos problémák
- MI: hogyan lehet leghatékonyabban megoldani?

Mesterséges intelligencia és idegtudomány

- Párhuzamos problémák
 - MI: hogyan lehet leghatékonyabban megoldani?
 - Idegtudomány: hogyan oldja meg az agy?

Mesterséges intelligencia és idegtudomány

- Párhuzamos problémák
 - MI: hogyan lehet leghatékonyabban megoldani?
 - Idegtudomány: hogyan oldja meg az agy?
 - a hatékonyság a biológiai rendszereknél is fontos szempont



Mesterséges intelligencia és idegtudomány

- Párhuzamos problémák
 - MI: hogyan lehet leghatékonyabban megoldani?
 - Idegtudomány: hogyan oldja meg az agy?
 - a hatékonyság a biológiai rendszereknél is fontos szempont
- Ötletek áramolnak mindkét irányba




Mi a látórendszer feladata?







Mi a látórendszer feladata?



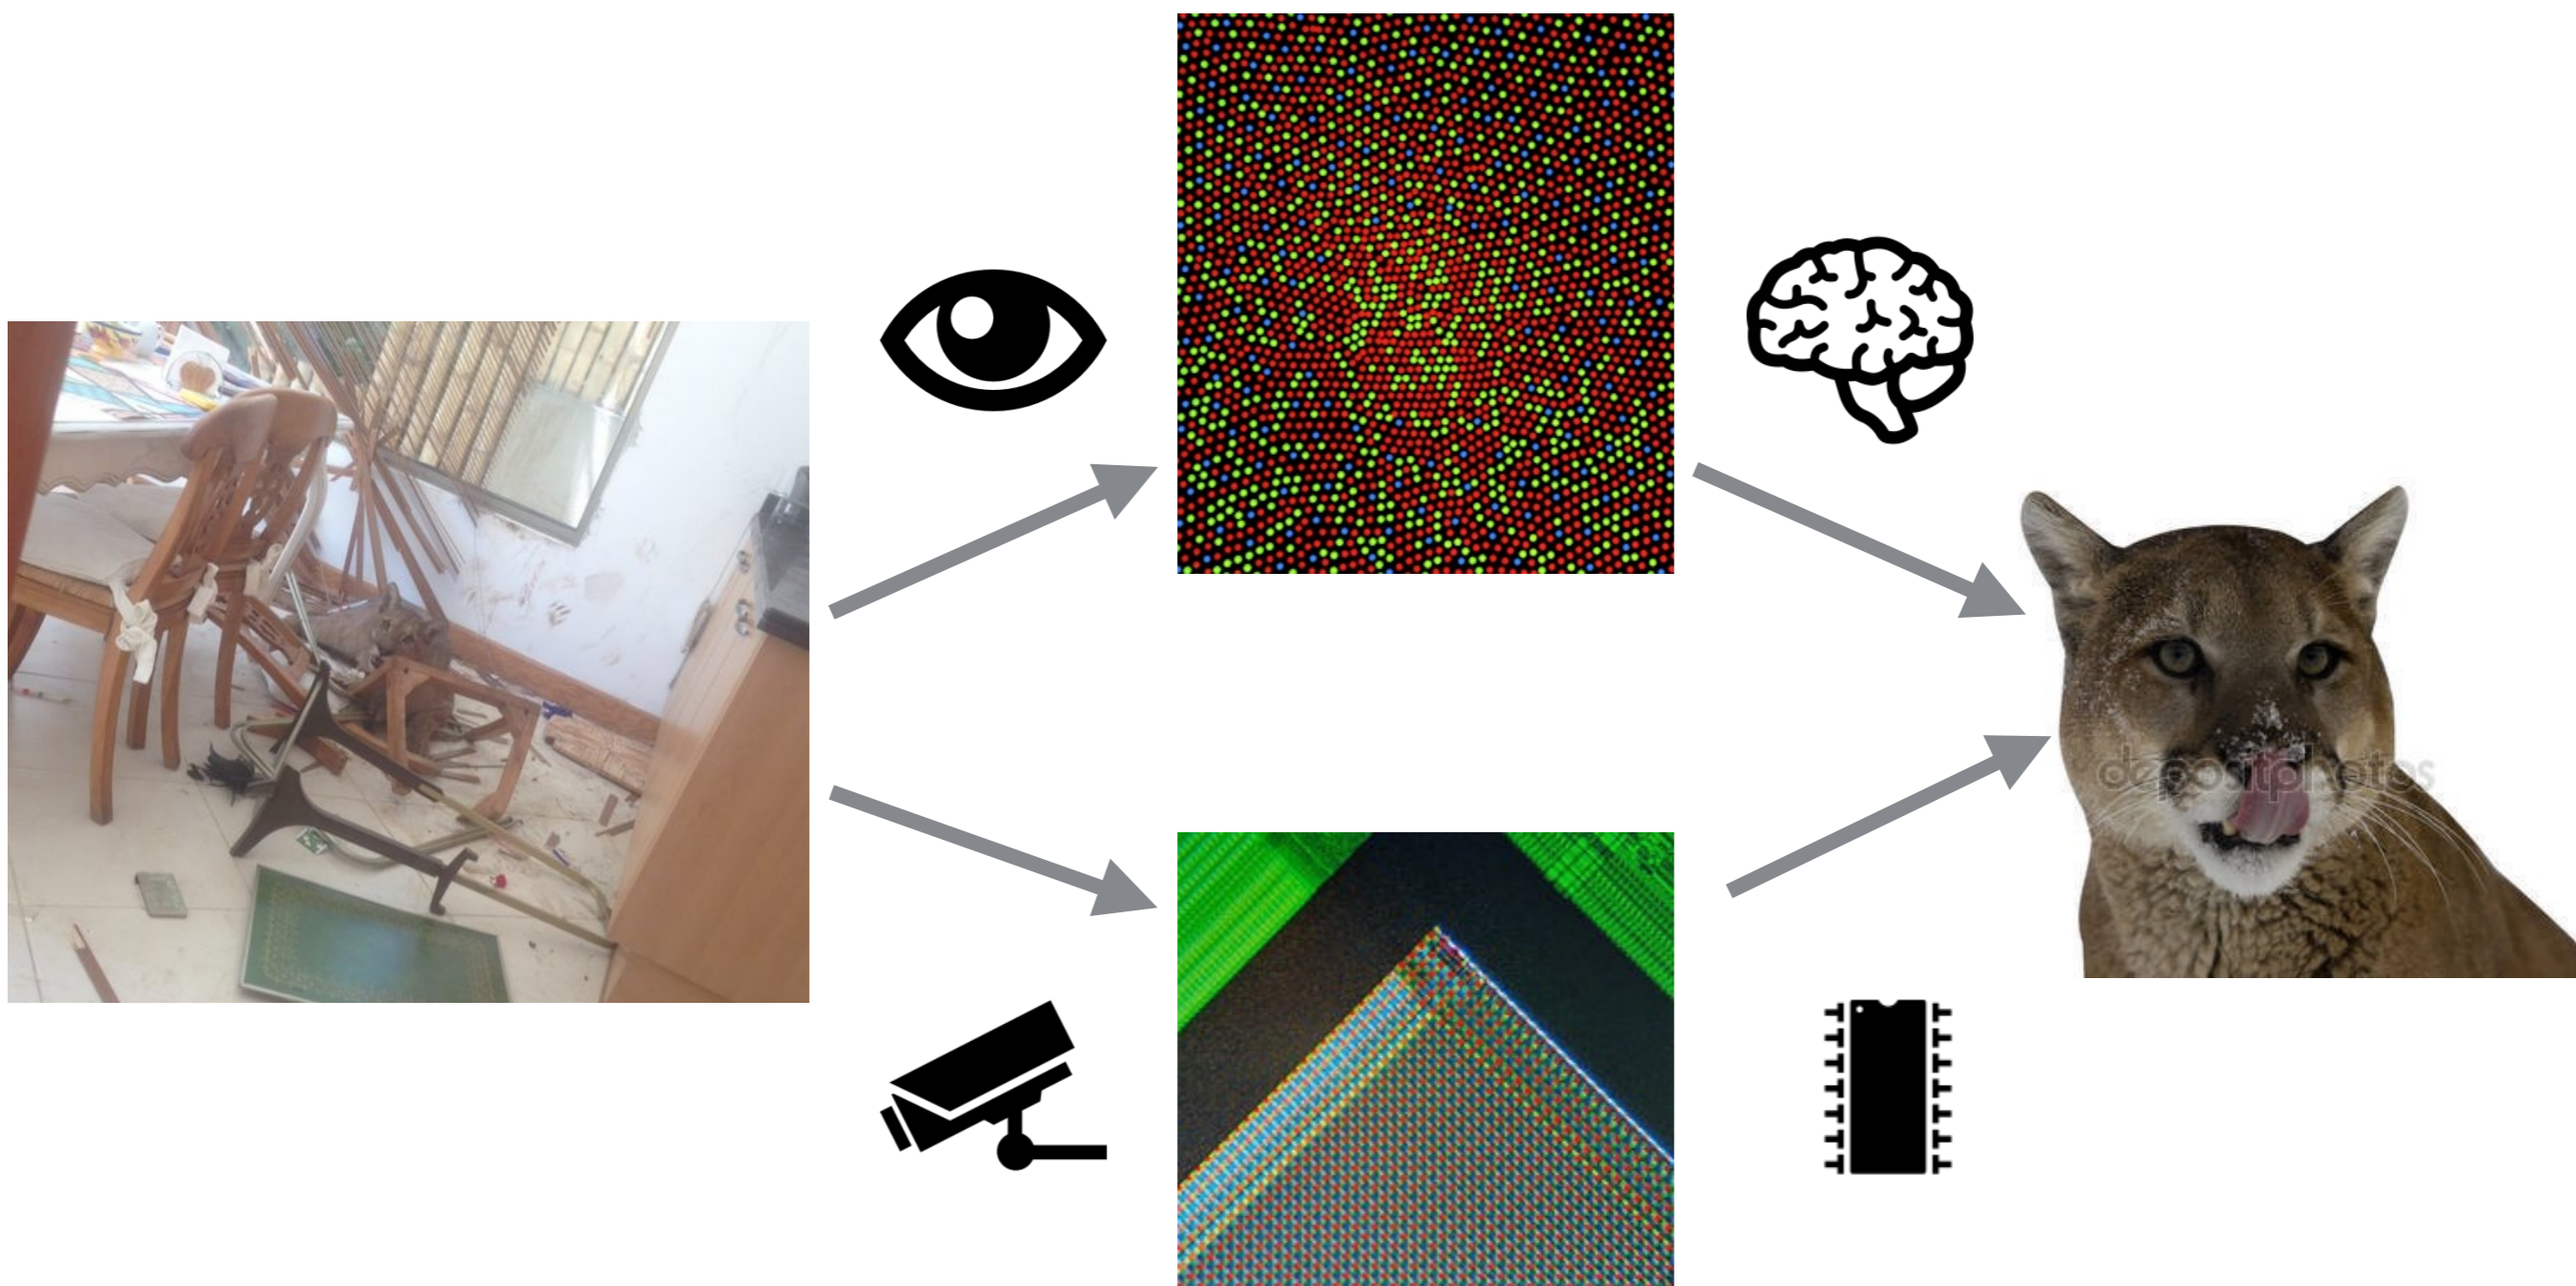
Mi a látórendszer feladata?



Mi a látórendszer feladata?



Mi a látórendszer feladata?



Mi a látórendszer feladata?

- Objektumfelismerés, besorolás

Mi a látórendszer feladata?

- Objektumfelismerés, besorolás
- Tömörítés, memóriában tároláshoz

Mi a látórendszer feladata?

- Objektumfelismerés, besorolás
- Tömörítés, memóriában tároláshoz
- Képek generálása, elképzélése

A képek szerkezete

- Kompozicionalitás

A képek szerkezete

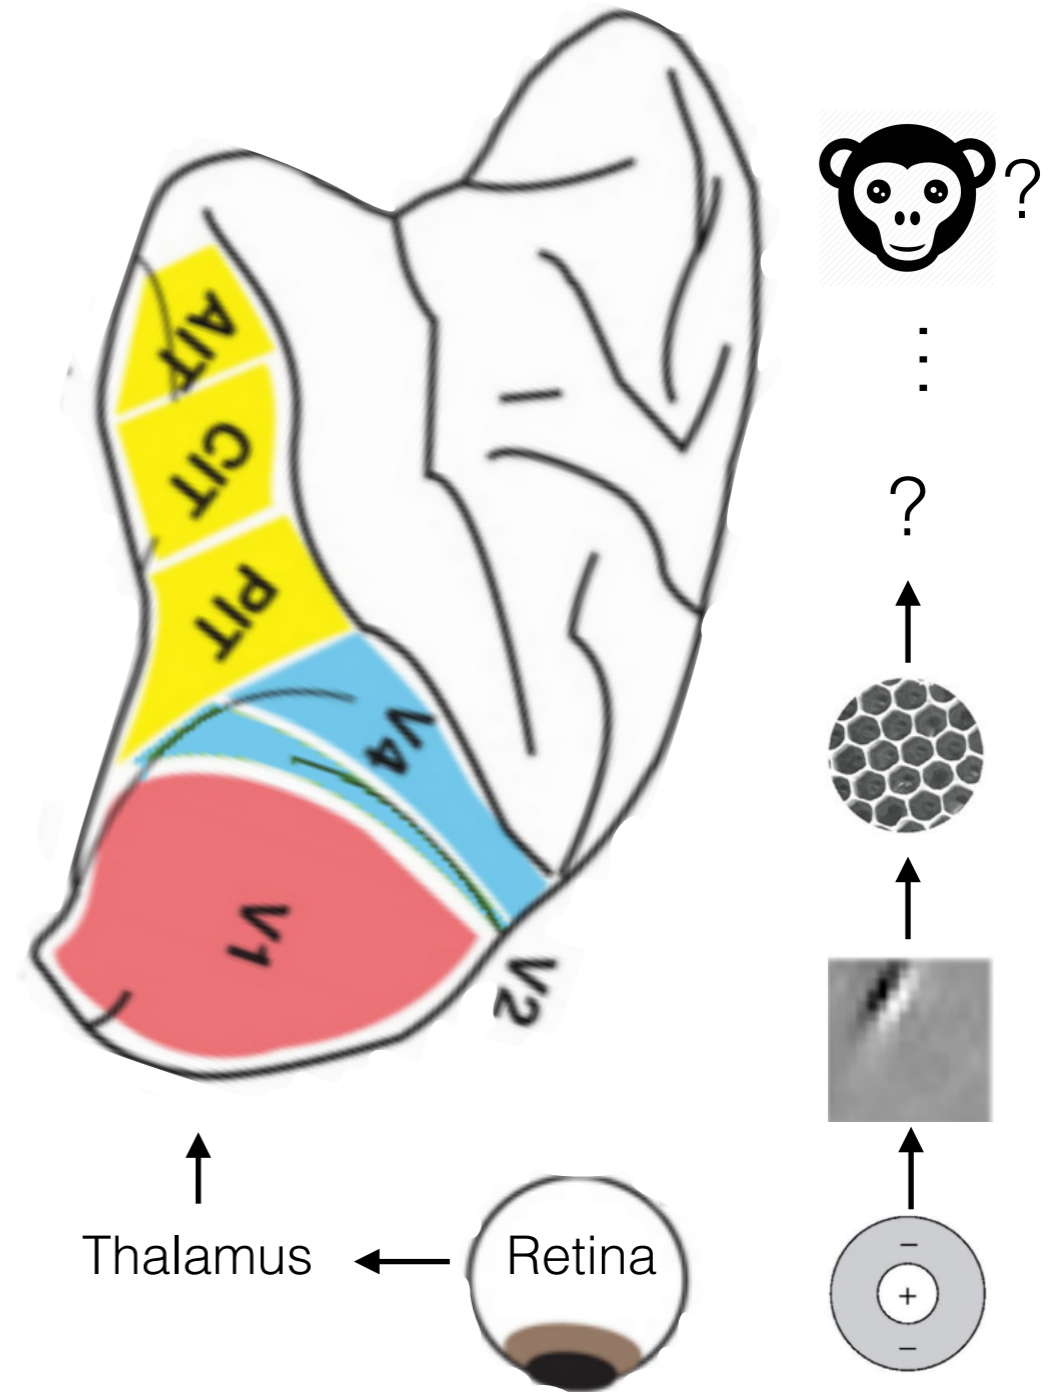
- Kompozicionalitás
 - alapvető képelemek kombinációiból állnak elő az összetettebbek

A képek szerkezete

- Kompozicionalitás
 - alapvető képelemek kombinációiból állnak elő az összetettebbek
- élek -> formák -> objektumok -> szituációk

A képek szerkezete

- Kompozicionalitás
 - alapvető képelemek kombinációiból állnak elő az összetettebbek
- élek -> formák -> objektumok -> situációk






A mesterséges neurális hálózatok kialakulása és működése


Az MI kezdetei

logikai eredmények




Az MI kezdetei

logikai eredmények




digitális számítógép




Az MI kezdetei


logikai eredmények



digitális számítógép




idegrendszeri mérések




Az MI kezdetei


logikai eredmények





digitális számítógép



idegrendszeri mérések



kibernetika




Az MI kezdetei

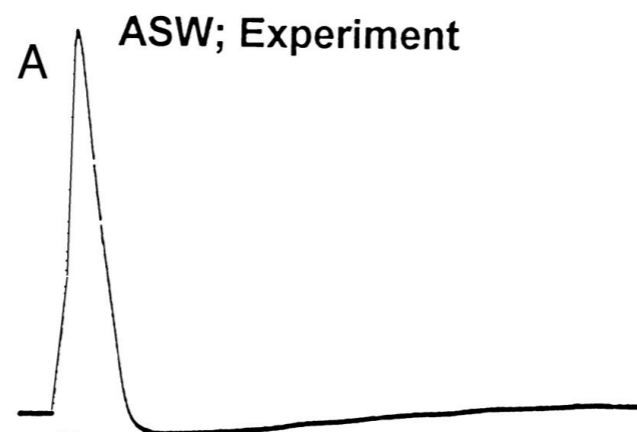
logikai eredmények





digitális számítógép



idegrendszeri mérések




kibernetika



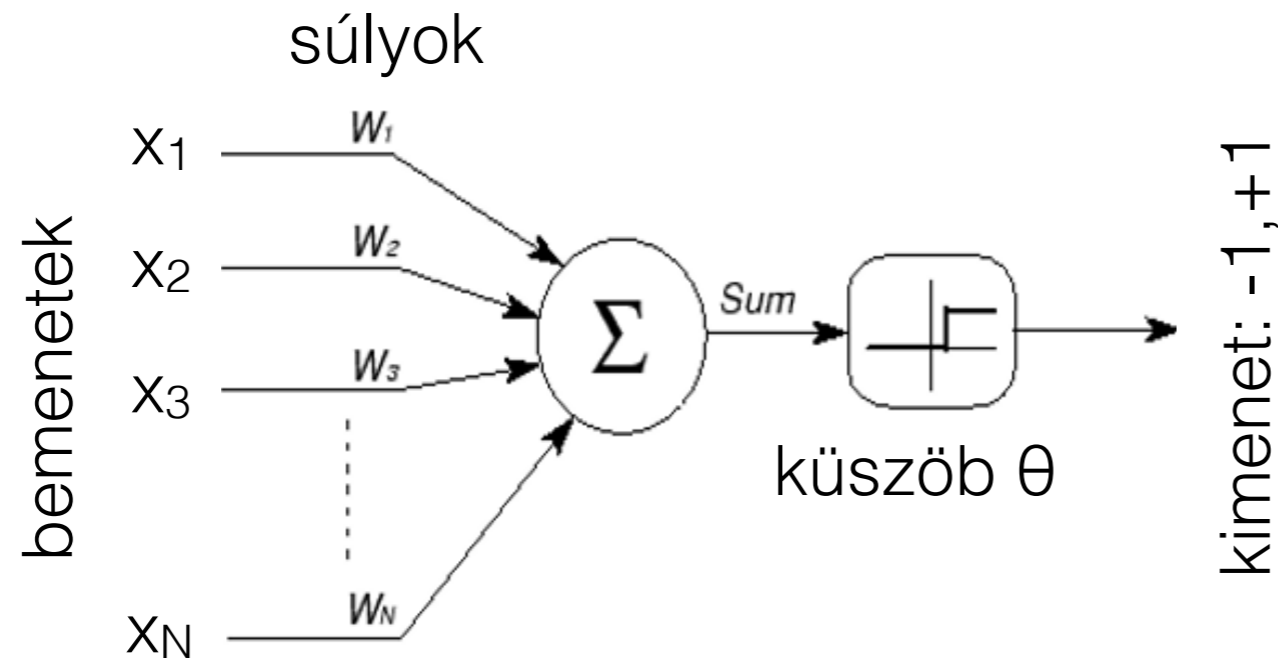
mesterséges idegsejt

Mesterséges neuron





- bemenetek súlyozott összegét egy küszöbhez hasonlítjuk

Mesterséges neuron




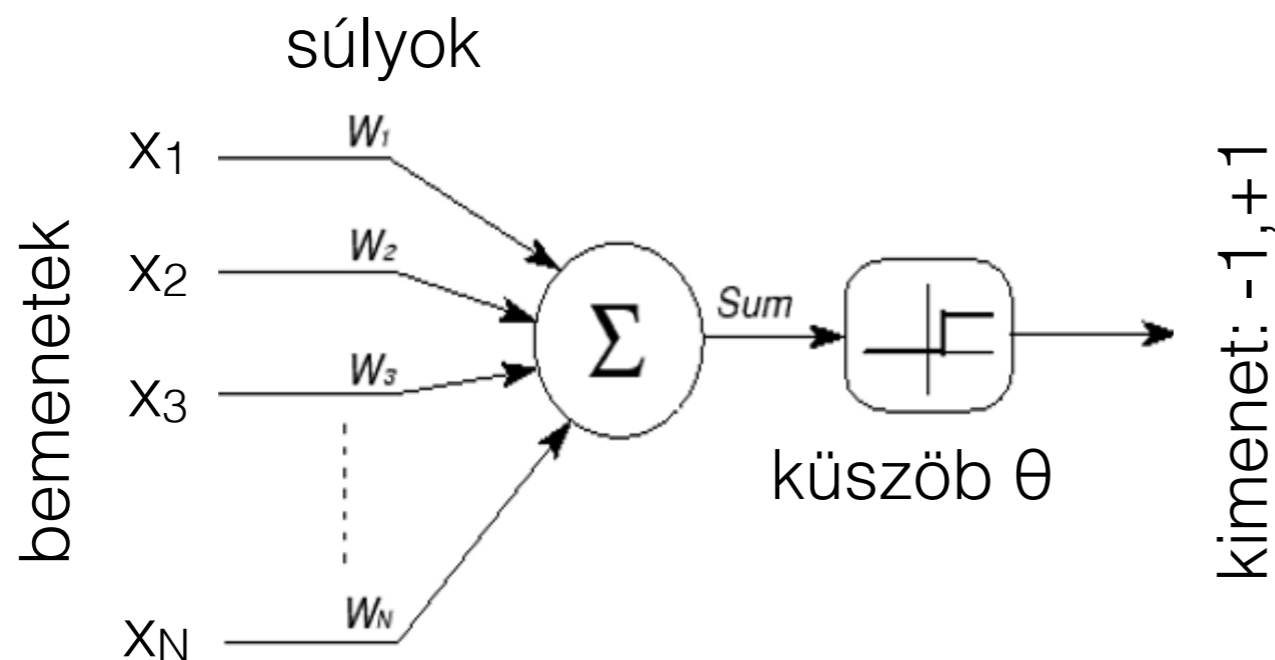
- bemenetek súlyozott összegét egy küszöbhez hasonlítjuk
- kétféle kimenet - a bemeneti kombinációk bináris osztályozása

Mesterséges neuron



- bemenetek súlyozott összegét egy küszöbhez hasonlítjuk
- kétféle kimenet - a bemeneti kombinációk bináris osztályozása
- lineáris szétválasztás


Mesterséges neuron




- bemenetek súlyozott összegét egy küszöbhez hasonlítjuk
- kétféle kimenet - a bemeneti kombinációk bináris osztályozása
- lineáris szétválasztás

$$\theta = x_1 w_1 + x_2 w_2 \longrightarrow x_2 = \frac{-w_1}{w_2} x_1 + \frac{\theta}{w_2}$$

Logikai műveletek mesterséges idegsejttel




(a) I_1 **and** I_2




(b) I_1 **or** I_2


Logikai műveletek mesterséges idegsejttel



(a) I_1 **and** I_2



(b) I_1 **or** I_2



(c) I_1 **xor** I_2

Első MI-tél

- A túlzott lelkesedés a 70-es évekre kiábrándulást eredményez



Első MI-tél

- A túlzott lelkesedés a 70-es évekre kiábrándulást eredményez
- Nyárra feladott házi feladat a 60-as évekből: olyan programot írni, ami felismeri, hogy milyen tárgy van egy képen



Első MI-tél

- A túlzott lelkesedés a 70-es évekre kiábrándulást eredményez
- Nyárra feladott házi feladat a 60-as évekből: olyan programot írni, ami felismeri, hogy milyen tárgy van egy képen
 - nem jött össze




Első MI-tél



- A túlzott lelkesedés a 70-es évekre kiábrándulást eredményez
- Nyárra feladott házi feladat a 60-as évekből: olyan programot írni, ami felismeri, hogy milyen tárgy van egy képen
 - nem jött össze
- Lineárisan nem szeparálható problémák hatékony kezelése problémás volt





Kizáró vagy megoldása



Kizáró vagy megoldása



Többretegű neurális hálózat



A megfelelő súlyértékek keresése


- adott adathalmazon a hálózat a súlyainak egy beállításával vét valamennyi hibát

A megfelelő súlyértékek keresése

- adott adathalmazon a hálózat a súlyainak egy beállításával vét valamennyi hibát
- azokat a súlyértékeket keressük, amelyekre ez a hiba a legkisebb


A megfelelő súlyértékek keresése

- adott adathalmazon a hálózat a súlyainak egy beállításával vét valamennyi hibát
- azokat a súlyértékeket keressük, amelyekre ez a hiba a legkisebb
- a sok súly együttes beállítása nehéz optimalizálási feladat




A megfelelő súlyértékek keresése

- adott adathalmazon a hálózat a súlyainak egy beállításával vét valamennyi hibát
- azokat a súlyértékeket keressük, amelyekre ez a hiba a legkisebb
- a sok súly együttes beállítása nehéz optimalizálási feladat
- van algoritmus közelítő megoldás keresésére



Problémák tanulórendszerekben

- Különféle hibák kiegyensúlyozása
 - Strukturális hiba: a modell optimális paraméterekkel is eltérhet a közelítő függvénytől (pl legjobban illeszkedő polinom szinuszfüggvényből származó adatra)
 - Közelítési hiba: a paraméterek pontos hangolásához végtelen adatra lehet szükség

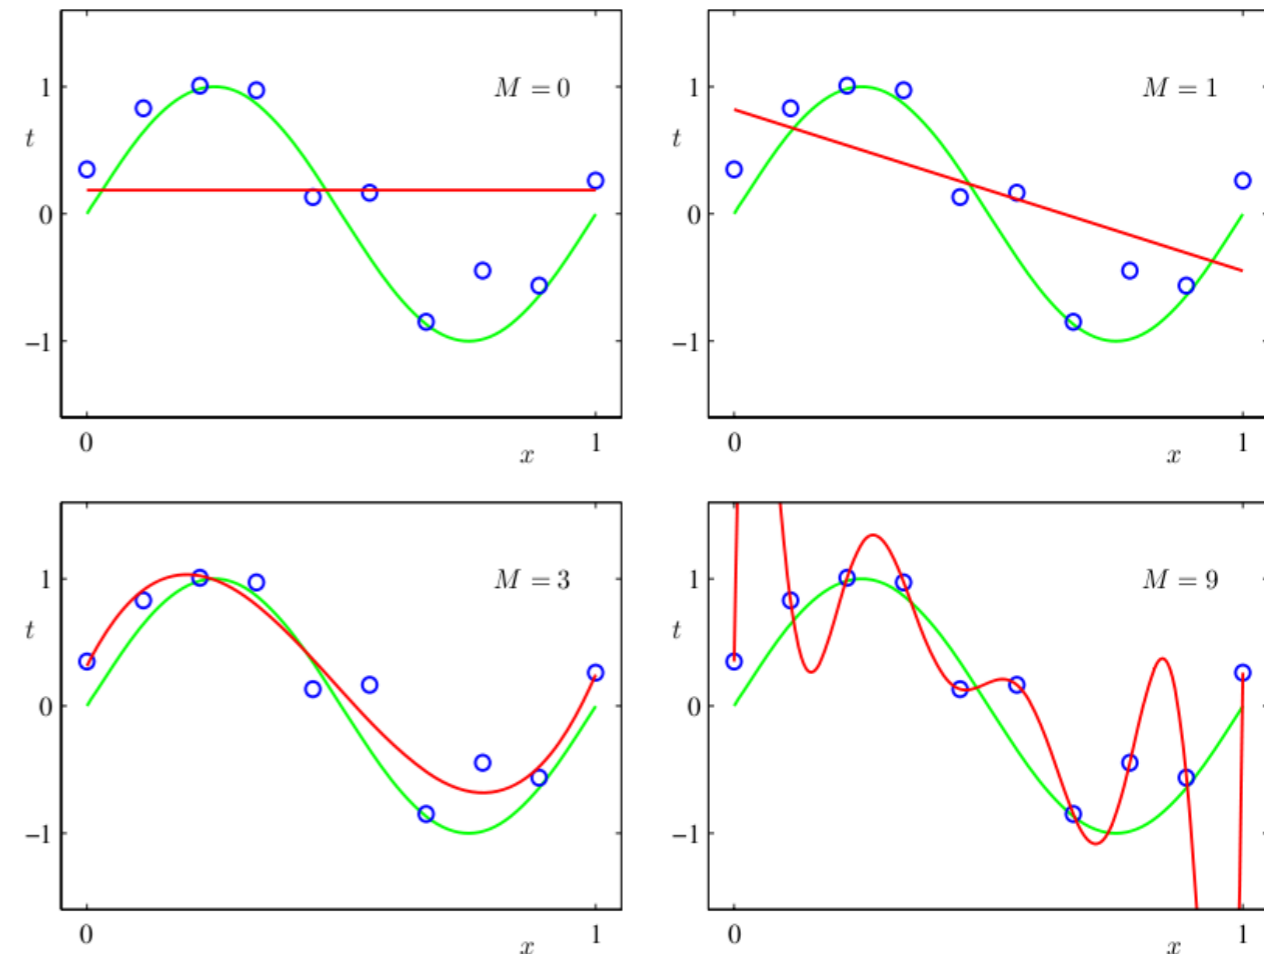


Problémák tanulórendszerekben

- Különféle hibák kiegyensúlyozása
 - Strukturális hiba: a modell optimális paraméterekkel is eltérhet a közelítő függvénytől (pl legjobban illeszkedő polinom szinuszfüggvényből származó adatra)
 - Közelítési hiba: a paraméterek pontos hangolásához végtelen adatra lehet szükség


- Pontosság vs. általánosítás

- A sokparaméteres modellek jól illeszkednek a meglévő adatra, de rosszul általánosítanak
- A magyarázó képességük is kisebb (lehet): Ockham borotvája



A második tél

- A 90-es évekre a súlytanuló algoritmusok erőforráskorlátokba futnak



A második tél

- A 90-es évekre a súlytanuló algoritmusok erőforráskorlátokba futnak
- számítási kapacitás




A második tél

- A 90-es évekre a súlytanuló algoritmusok erőforráskorlátokba futnak
 - számítási kapacitás
 - adatmennyiség



A második tél


- A 90-es évekre a súlytanuló algoritmusok erőforráskorlátokba futnak
 - számítási kapacitás
 - adatmennyiség
- Csak egy kanadai ügynökség ad neurális hálózatokra pénzt




A deep learning alkalmazásai vizuális feldolgozásra

Deep learning és képosztályozás

- A deep learning többrétegű neuronhálózatok súlyainak optimalizációja



Deep learning és képosztályozás



- A deep learning többrétegű neuronhálózatok súlyainak optimalizációja
- Ugyanaz, mint a 80-as években, jobb számítógépeken, több adattal és valamelyest fejlesztett algoritmusokkal

Deep learning és képosztályozás

- A deep learning többrétegű neuronhálózatok súlyainak optimalizációja
- Ugyanaz, mint a 80-as években, jobb számítógépeken, több adattal és valamelyest fejlesztett algoritmusokkal
- tipikus feladat: képek besorolása kategóriákba




Image classification

Easiest classes




Hardest classes




Deep learninggel tanult képelemek


Training samples




1st layer




2nd layer




HDP high-level features



Training samples



1st layer




2nd layer



HDP high-level features



Konvolúciós háló



A Full Convolutional Neural Network (LeNet)














- Térbeli elhelyezkedésre érzéketlen elemzési
- és térbeli összegzési lépések ismétlődése

Tanult elemekből generált kép




Neural Networks


©2016 Fjodor van Veen - asimovinstitute.org

-  Backfed Input Cell
-  Input Cell
-  Noisy Input Cell
-  Hidden Cell
-  Probabilistic Hidden Cell
-  Spiking Hidden Cell
-  Output Cell
-  Match Input Output Cell
-  Recurrent Cell
-  Memory Cell
-  Different Memory Cell
-  Kernel
-  Convolution or Pool


Deep Feed Forward (DFF)




Perceptron (P)




Feed Forward (FF)




Radial Basis Network (RBF)




Recurrent Neural Network (RNN)




Long / Short Term Memory (LSTM)




Gated Recurrent Unit (GRU)




Auto Encoder (AE)



Variational AE (VAE)




Denosing AE (DAE)




Sparse AE (SAE)



Markov Chain (MC)




Hopfield Network (HN)




Boltzmann Machine (BM)




Restricted BM (RBM)




Deep Belief Network (DBN)




Deep Convolutional Network (DCN)




Deconvolutional Network (DN)




Deep Convolutional Inverse Graphics Network (DCIGN)




Generative Adversarial Network (GAN)




Liquid State Machine (LSM)




Extreme Learning Machine (ELM)




Echo State Network (ESN)




Deep Residual Network (DRN)




Kohonen Network (KN)









Support Vector Machine (SVM)



Neural Turing Machine (NTM)



Szemantikai elemzés




(a) Input image

(b) Segmentation output


(c) Instance output

(d) Depth output


Stílus és tartalom dekomponálása



Tömörítés neurális hálózattal



Tömörítés neurális hálózattal



original

bicubic
(21.59dB/0.6423)

SRGAN
(20.34dB/0.6562)



Rajz struktúrájának tanulása


Human Input



Reconstructions



Generatív és klasszifikációs hálózatok egymás ellen tanítva



Real images (ImageNet)



Generated images

Szövegből kép generálása

this small bird has a pink breast and crown, and black primaries and secondaries.



this magnificent fellow is almost all black with a red crest, and white cheek patch.



the flower has petals that are bright pinkish purple with white stigma



this white and yellow flower have thin white petals and a round yellow stamen





(Reed et al 2016)

Létezik-e általános célú MI?



Optimális döntések tanulása neurális hálózattal

- Gerald Tesauro: TD-Gammon
- Többrétegű neuronhálózat





Optimális döntések tanulása neurális hálózattal

- Gerald Tesauro: TD-Gammon
- Többrétegű neuronhálózat
- Bemenet: a lehetséges lépések nyomán elért állapotok





Optimális döntések tanulása neurális hálózattal

- Gerald Tesauro: TD-Gammon
 - Többrétegű neuronhálózat
 - Bemenet: a lehetséges lépések nyomán elért állapotok
 - Kimenet: a nyeresé valószínűsége az adott állapotból





Optimális döntések tanulása neurális hálózattal

- Gerald Tesauro: TD-Gammon
 - Többrétegű neuronhálózat
 - Bemenet: a lehetséges lépések nyomán elért állapotok
 - Kimenet: a nyeres valószínűsége az adott állapotból
- Ez alapján ki lehet választani, hogy melyik állapotba szeretnénk kerülni





Optimális döntések tanulása neurális hálózattal


- Gerald Tesauro: TD-Gammon
 - Többrétegű neuronhálózat
 - Bemenet: a lehetséges lépések nyomán elért állapotok
 - Kimenet: a nyereség valószínűsége az adott állapotból
- Ez alapján ki lehet választani, hogy melyik állapotba szeretnénk kerülni





Számítógépes játékok tanulása



Mnih et al, 2015



Mozgás tanulása









?



Hogyan segítik az MI
alkalmazások az agy megértését?

Hasonlóságok az agy vizuális rendszerével

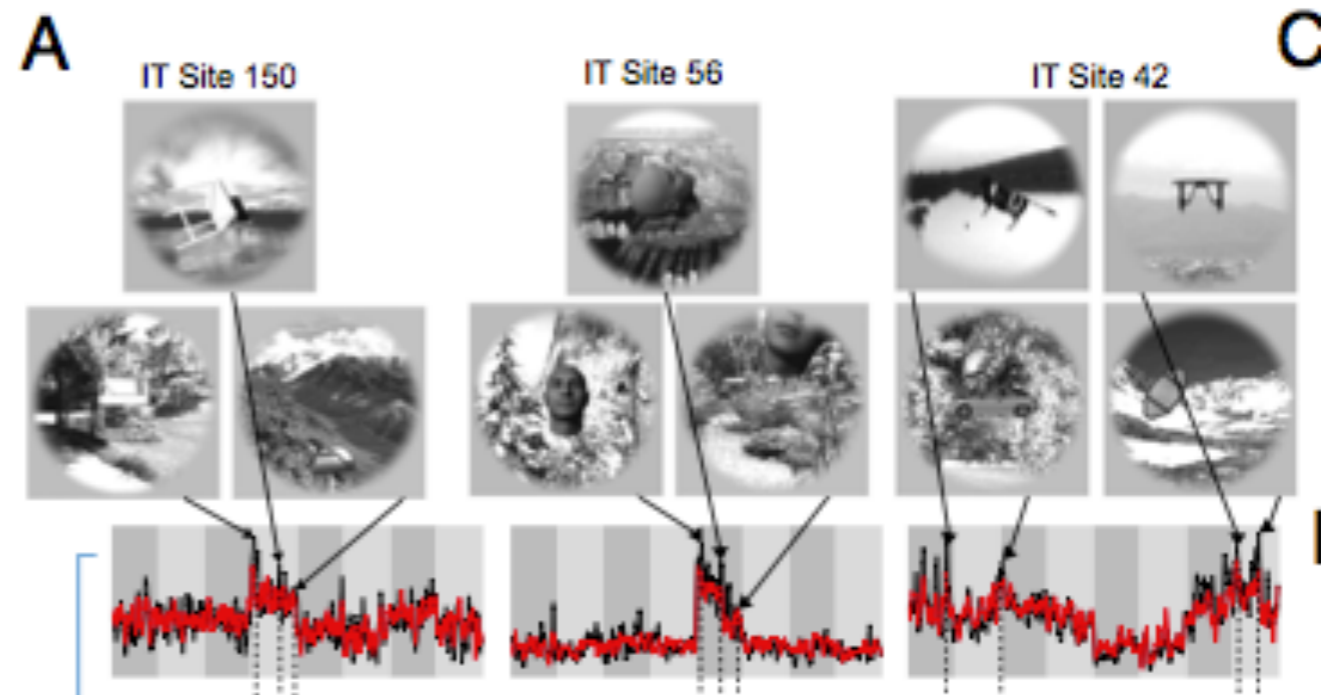


Különbségek a mesterséges és természetes neuronhálóknál között

- a deep learning hálózatokban általában egyirányú a feldolgozás, az agyban vannak visszacsatolások
- a súlyok beállításához használt algoritmus által megkövetelt információáramlás neurális megfelelőjét nem ismerjük

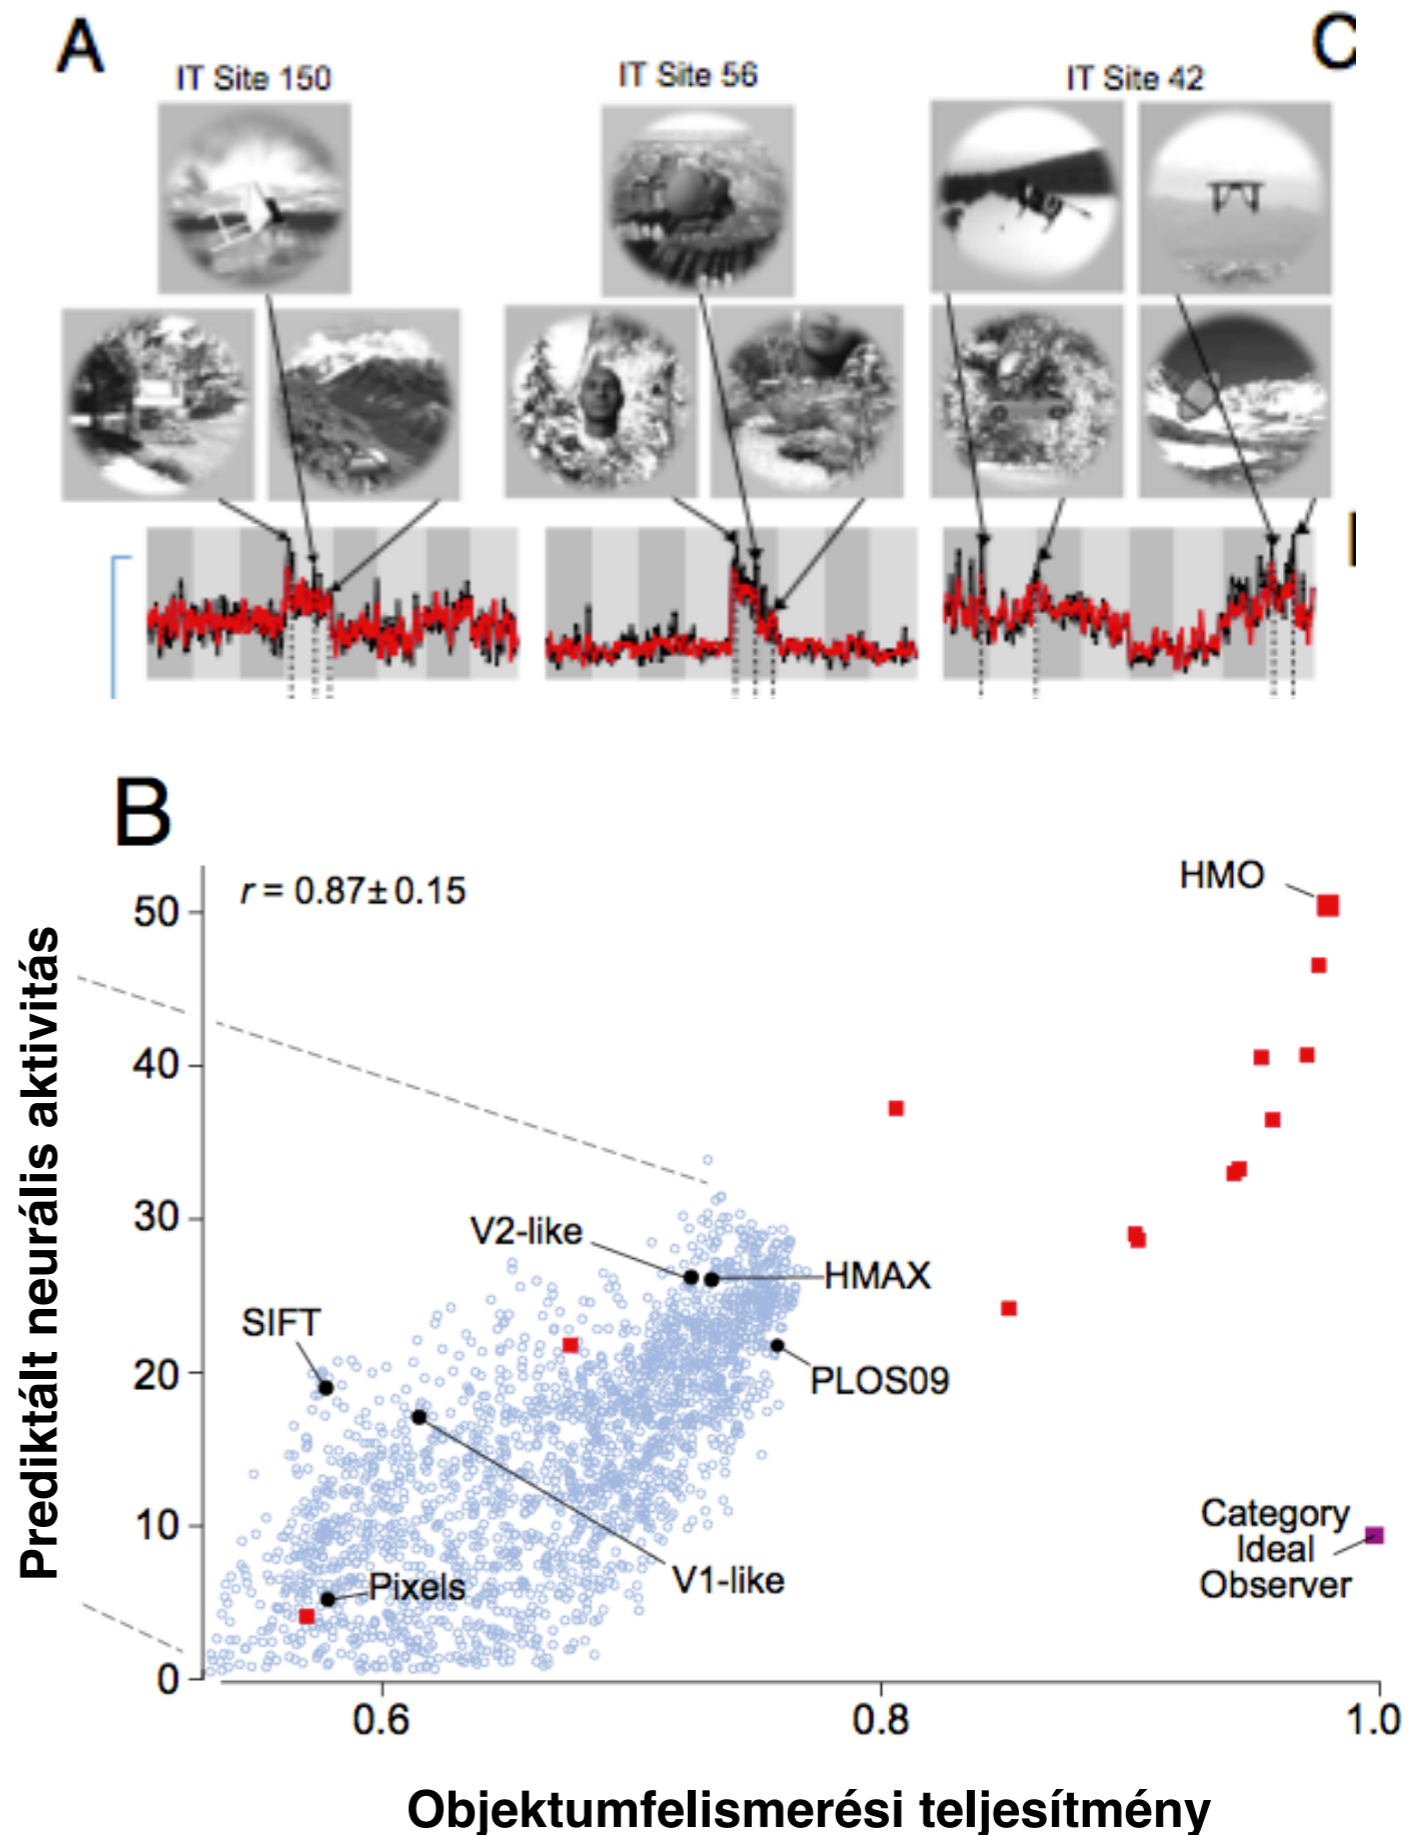
Neurális aktivitás predikciója konvolúciós hálókkal

- Az agy objektumfelismerésben résztvevő neuronjainak átlagos aktivitását prediktáljuk
 - a mesterséges háló mélyebb rétegeinek aktivációjával



Neurális aktivitás predikciója konvolúciós hálókkal

- Az agy objektumfelismerésben résztvevő neuronjainak átlagos aktivitását prediktáljuk
 - a mesterséges háló mélyebb rétegeinek aktivációjával
- Minél jobban teljesít a hálózat az objektumfelismerésben, annál jobban prediktálja a neurális aktivitást



Összefoglalás

- A mesterséges és természetes látórendszerek feladatai azonosak

Összefoglalás

- A mesterséges és természetes látórendszerek feladatai azonosak
- Az adatok legfontosabb tulajdonsága a kompozicionalitás

Összefoglalás

- A mesterséges és természetes látórendszerek feladatai azonosak
- Az adatok legfontosabb tulajdonsága a kompozicionalitás
 - A rétegzett neurális hálózatok ezt használják ki

Összefoglalás

- A mesterséges és természetes látórendszerek feladatai azonosak
- Az adatok legfontosabb tulajdonsága a kompozicionalitás
 - A rétegzett neurális hálózatok ezt használják ki
- A deep learning modellek jól teljesítenek képklasszifikációban, de alkalmasak képgenerálásra, tömörítésre is

Összefoglalás

- A mesterséges és természetes látórendszerek feladatai azonosak
- Az adatok legfontosabb tulajdonsága a kompozicionalitás
 - A rétegzett neurális hálózatok ezt használják ki
- A deep learning modellek jól teljesítenek képklasszifikációban, de alkalmasak képgenerálásra, tömörítésre is
- Sok specifikus problémára adnak jó megoldást a legújabb módszerek

Összefoglalás

- A mesterséges és természetes látórendszerek feladatai azonosak
- Az adatok legfontosabb tulajdonsága a kompozicionalitás
 - A rétegzett neurális hálózatok ezt használják ki
- A deep learning modellek jól teljesítenek képklasszifikációban, de alkalmasak képgenerálásra, tömörítésre is
- Sok specifikus problémára adnak jó megoldást a legújabb módszerek
 - Lehet optimális cselekvéseket is tanulni neurális hálózatokkal

Összefoglalás

- A mesterséges és természetes látórendszerek feladatai azonosak
- Az adatok legfontosabb tulajdonsága a kompozicionalitás
 - A rétegzett neurális hálózatok ezt használják ki
- A deep learning modellek jól teljesítenek képklasszifikációban, de alkalmasak képgenerálásra, tömörítésre is
- Sok specifikus problémára adnak jó megoldást a legújabb módszerek
 - Lehet optimális cselekvéseket is tanulni neurális hálózatokkal
 - De általános célú MI jelenleg nincs

Összefoglalás

- A mesterséges és természetes látórendszerek feladatai azonosak
- Az adatok legfontosabb tulajdonsága a kompozicionalitás
 - A rétegzett neurális hálózatok ezt használják ki
- A deep learning modellek jól teljesítenek képklasszifikációban, de alkalmasak képgenerálásra, tömörítésre is
- Sok specifikus problémára adnak jó megoldást a legújabb módszerek
 - Lehet optimális cselekvéseket is tanulni neurális hálózatokkal
 - De általános célú MI jelenleg nincs
- Bár a mesterséges neuronhálók csak nagyon közvetetten merítenek ötletet biológiai rendszerekből, mégis használhatóak neurális aktivitás predikciójára