

Neurális hálózatok, avagy mit is hívunk többnyire mesterséges intelligenciának?

Az atomoktól a csillagokig
17. évad
2021-2022. tanév

Pataki Bálint Ármin

ELTE, Komplex Rendszerek Fizikája Tanszék

2022.03.10.

A világ megismerése

Szervi limitációk miatt önmagában a gondolkodás nem elég.

Rossz a memóriánk → papír

Nem tudunk gyorsan számolni → számológép


Nem látunk jól kis dolgokat → mikroszkóp

Nem látunk jól távoli objektumokat → teleszkóp

Nem látunk át az szöveten → röntgen

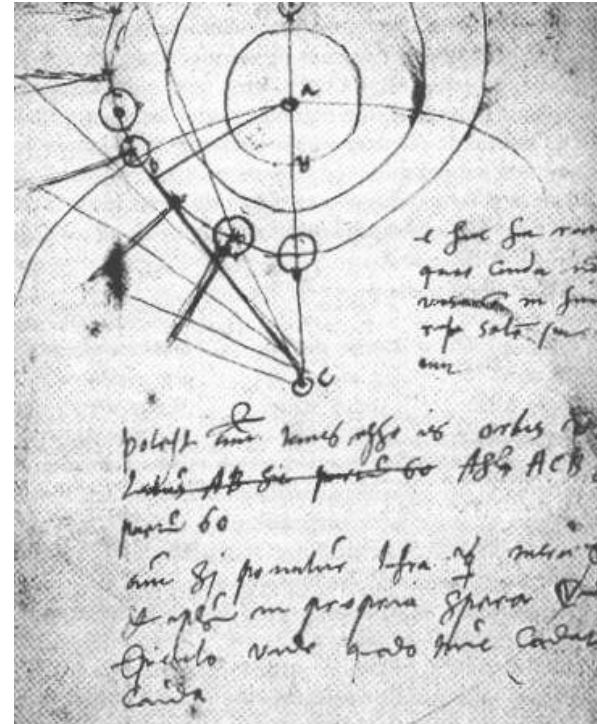
Nem érezzük pontosan a hőmérsékletet, nyomást, pH-t, időt,
távolságot, gyorsulást, sebességet stb.

“Mankók” szükségesek a világ megismeréséhez.




Leonardo da Vinci: Vitruvius-tanulmány


Fizika régebben...




Tycho Brahe, 1500-as évek vége MB-nyi adat




Johannes Kepler, cc 1600






SDSS, 2000-es évek, 116 TB



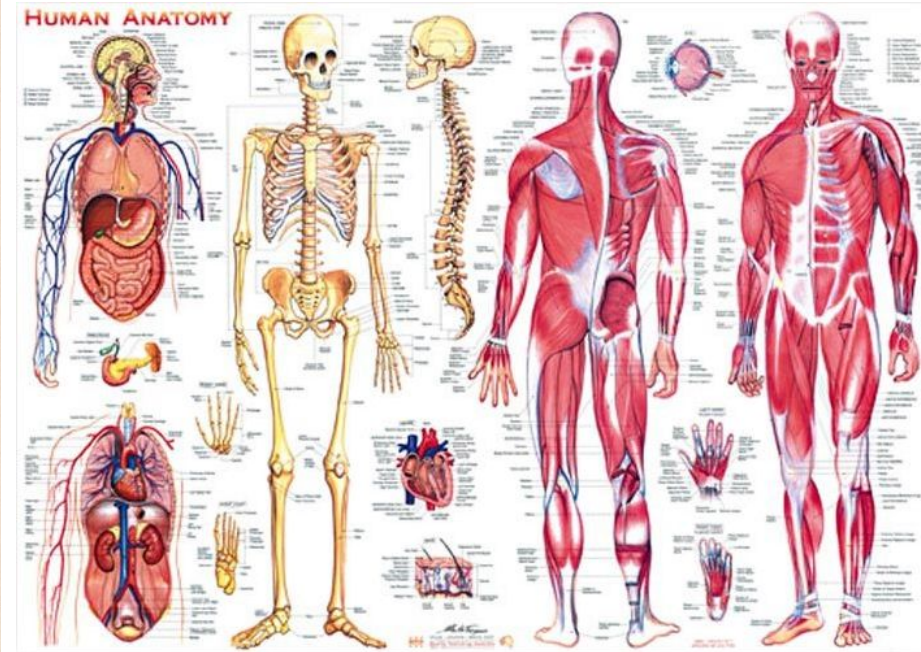
LIGO, napjaink, 1 TB naponta


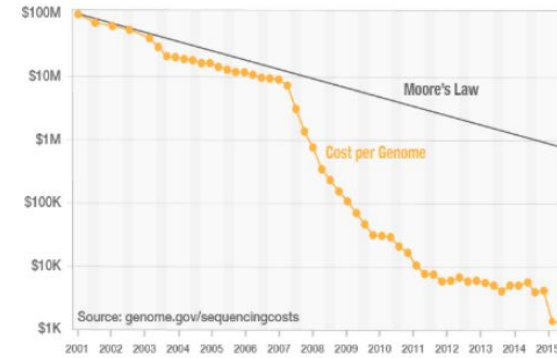



CERN, napjaink, 1000 TB naponta

Új eszközök kellene! Tollal papíron ennyi adat kezelhetetlen!


Élettudományok régebben...






Új eszközök kellene, pipetta és mikroszkóp nem elég.

Új eszköz: adatfeldolgozás (programozás)



Apollo Guidance Computer and DSKY



Raspberry Pi 3



Szerverpark

Programozás

Előre definiált lépések gyors végrehajtása adatokon (újabb “mankó”).

Példa: adott N pozitív egész, N prímszám-e?

```
1 isPrime = True
2 for i in [2, 3, ... N-1]:
3     if divisible(N, i):
4         isPrime = False
5
6 print(isPrime)
```

Lehet észszerűsíteni, gyorsítani a programot.

Vannak esetek, amit egy kisgyerek meg tud oldani, de programot nem tudunk rá írni.
Ötlet?

Programozás

Előre definiált lépések gyors végrehajtása adatokon (újabb “mankó”).

Példa: adott N pozitív egész, N prímszám-e?

```
1 isPrime = True
2 for i in [2, 3, ... N-1]:
3     if divisible(N, i):
4         isPrime = False
5
6 print(isPrime)|
```

Lehet észszerűsíteni, gyorsítani a programot.

Vannak esetek, amit egy kisgyerek meg tud oldani, de programot nem tudunk rá írni.
Ötlet?



Új eszközre lenne igény!
Sok területen kell képeket felismerni.
Milyen típusú a galaxis? Rákos-e az anyajegy?

Fizikai modell


- összhangban van a korábbi mérésekkel
- összhangban van az új mérésekkel
- adaton (kísérleteken) és emberi intuíción alapszik
- cél a jelenség mély megértése
- megértett limitációk (Newtoni mechanika)
- a megértés tömörített kivonata

vs


gépi tanulási modell

- összhangban van a korábbi mérésekkel
- összhangban van az új mérésekkel
- adaton alapszik
- bonyolult modell (akár több száz M paraméter)
- a miért és hogyan (megértés) másodlagos

Fő cél: mély és pontos megértése a folyamatnak



Fő cél: pontosan működjön, használható legyen



És hogy ráférjen egy pólóra: 3 betűs képletek preferáltak:

- $E = mc^2$, $F = ma$


Fizikusi megközelítés

vs

gépi tanulási megközelítés


- számos kísérlet
- koncepciók
 - gravitáció
 - tehetetlenség
 - sebesség
 - gyorsulás
- Newton
 - egyszerű egyenletek pár paraméterrel

- több száz/ezer kísérlet
- eltárolni minden adatot
 - kezdeti sebesség, szög
 - tömeg, hol esett le
 - levegő hőmérséklete, szél
 - milyen színű/szagú/ízű volt
- egy összetett modell illesztése
 - kevés intuíció
 - pontosan működhet

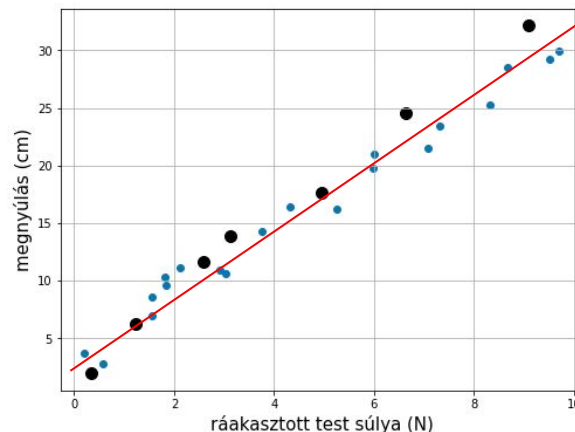


Ha megérthető módon tudunk valamit modellezni, akkor nem kell hozzá gépi tanulás!

Legegyszerűbb gépi tanulási modell - egyenesillesztés



<https://fizikappt9.blogspot.com/2019/08/14-rugoero.html>



Cél: mennyire nyúlik ki a rugó, ha 7.8 N-al húzom?

x - ráakasztott test súlya, y - a rugó kinyúlt hossza

$$y = f(x) = C \cdot x + L_0$$

kék pontok: (x_i, y_i) mérési pontok (korábbi kísérletek)

fekete pontok: ezeket ne használjuk az illesztéshez, ezeken nézzük majd meg, mennyire pontos a modell (új kísérletek)!

Legkisebb négyzetek módszere:

$$D, L_0, \text{ ami minimalizálja: } \sum_i (y_i - f(x_i))^2 = \sum_i (y_i - (C \cdot x_i + L_0))^2$$

Definiáltunk egy paraméterekkel (C, L_0) rendelkező függvényt, majd a paramétereket adatok alapján optimalizáltuk.

$$y = f(\text{, w)$$


Mi szerepel a képen?

Illesszünk erre is egy gépi tanulási modellt sok-sok tanító adattal (kép-címke párok)!

- f ne egy egyenes legyen
- w ne csak két paraméterből álljon (sokszor 10-100 millió paraméter)

Nem egy 'sima' függvényillesztés, mert nem a tanító adatokon akarunk pontosak lenni, hanem a még nem látott példákon!
A fel nem címkézett képeken legyen pontos, amiket akár holnap/jövő héten is készíthetek!

Hogyan néz ki egy fekete-fehér kép?



0	0	85	221	153	17	0	0
0	0	221	255	170	255	85	0
0	51	255	34	0	187	136	0
0	68	204	0	0	136	136	0
0	85	136	0	0	153	136	0
0	68	187	0	17	204	119	0
0	34	238	85	170	204	0	0
0	0	102	221	170	0	0	0


Mátrix, intenzitás értékek

Színes kép = 3 ilyen térkép (kék-zöld-piros intenzitás)

Neuron

Biológiai (egyszerűsített):


- bemenet más neuronoktól (dendritek)
- összegzés (soma)
- összegzésfüggő tüzelés - kimenet
- kimenet továbbítása (axon)




David Baillot/ UC San Diego

Model:

- bemenet más neuronok aktivációja (A_j)
- súlyozott átlag
- aktivációs függvény (f)
- kimenet = aktiváció = $A_i = f(A_1 * W_{i1} + A_2 * w_{i2} + \dots + B_i)$



Neurális hálózat




$$z_0^{[1]} = w_{0,0}^{[1]}x_0 + w_{0,1}^{[1]}x_1 + w_{0,2}^{[1]}x_2 + b_0^{[1]}$$
$$a_0^{[1]} = g(z_0^{[1]})$$

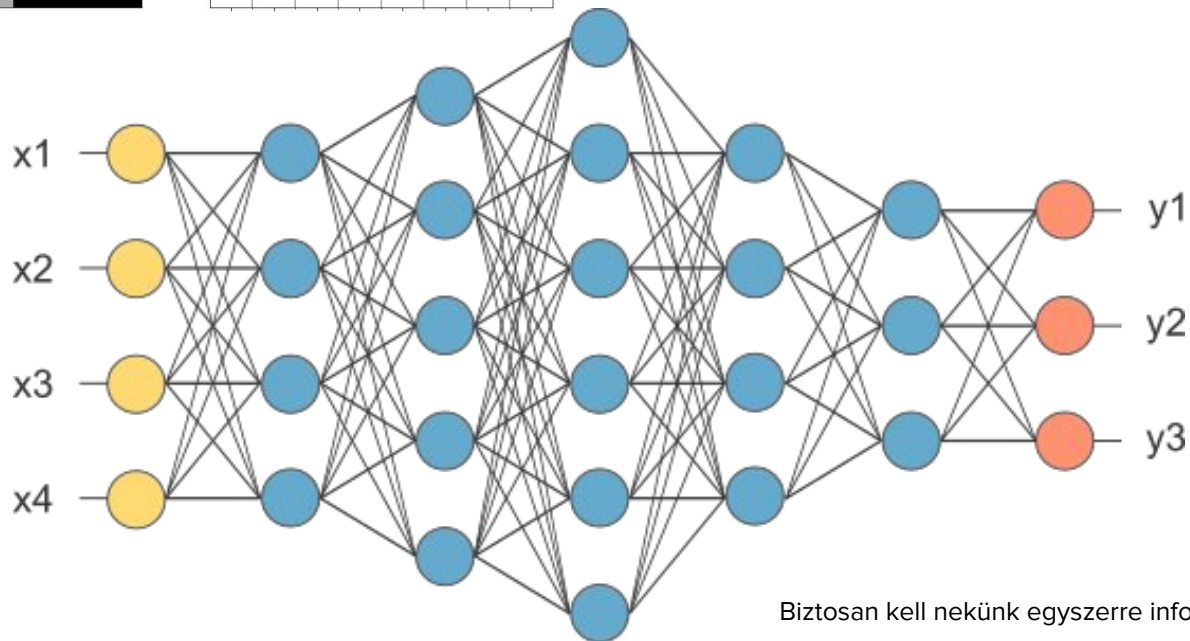
$$z_1^{[1]} = w_{1,0}^{[1]}x_0 + w_{1,1}^{[1]}x_1 + w_{1,2}^{[1]}x_2 + b_1^{[1]}$$
$$a_1^{[1]} = g(z_1^{[1]})$$

$$z_0^{[2]} = w_{0,0}^{[2]}a_0 + w_{0,1}^{[2]}a_1 + b_0^{[2]}$$
$$a_0^{[2]} = g(z_0^{[2]})$$

Neurális hálózat



0	0	85	221	153	17	0	0
0	0	221	255	170	255	85	0
0	51	255	34	0	187	136	0
0	68	204	0	0	136	136	0
0	85	136	0	0	153	136	0
0	68	187	0	17	204	119	0
0	34	238	85	170	204	0	0
0	0	102	221	170	0	0	0



Kimenet:
minden kategória egy-egy neuron
pl. 0-s számjegy van a képen?

Biztosan kell nekünk egyszerre információ a balfelső és a jobbalsó sarokból?

konvolúciós kernel

w_{00}	w_{01}	w_{02}
w_{10}	w_{11}	w_{12}
w_{20}	w_{21}	w_{22}

#parameters:

$$3 \cdot 3 + 1 = 10 \text{ (9 w súly +1 bias b)}$$

$$p'_{11} = w_{00} \cdot p_{00} + w_{01} \cdot p_{01} + w_{02} \cdot p_{02} + w_{10} \cdot p_{10} + w_{11} \cdot p_{11} + w_{12} \cdot p_{12} + w_{20} \cdot p_{20} + w_{21} \cdot p_{21} + w_{22} \cdot p_{22} + b$$

eredeti kép

p_{00}	p_{01}	p_{02}	p_{03}	p_{04}	p_{05}
p_{10}	p_{11}	p_{12}	p_{13}	p_{14}	p_{15}
p_{20}	p_{21}	p_{22}	p_{23}	p_{24}	p_{25}
p_{30}	p_{31}	p_{32}	p_{33}	p_{34}	p_{35}
p_{40}	p_{41}	p_{42}	p_{43}	p_{44}	p_{45}
p_{50}	p_{51}	p_{52}	p_{53}	p_{54}	p_{55}

Megjegyzés: a hagyományos képfeldolgozási konvolúció kissé eltér ettől.
Ott a kernel tükrözve van mindkét tengely mentén először.

konvolúciós kernel

w_{00}	w_{01}	w_{02}
w_{10}	w_{11}	w_{12}
w_{20}	w_{21}	w_{22}


eredeti kép

p_{00}	p_{01}	p_{02}	p_{03}	p_{04}	p_{05}
p_{10}	p_{11}	p_{12}	p_{13}	p_{14}	p_{15}
p_{20}	p_{21}	p_{22}	p_{23}	p_{24}	p_{25}
p_{30}	p_{31}	p_{32}	p_{33}	p_{34}	p_{35}
p_{40}	p_{41}	p_{42}	p_{43}	p_{44}	p_{45}
p_{50}	p_{51}	p_{52}	p_{53}	p_{54}	p_{55}


$$p'_{12} = w_{00} \cdot p_{01} + w_{01} \cdot p_{02} + w_{02} \cdot p_{03} + w_{10} \cdot p_{11} + w_{11} \cdot p_{12} + w_{12} \cdot p_{13} + w_{20} \cdot p_{21} + w_{21} \cdot p_{22} + w_{22} \cdot p_{23} + b$$

Note: traditional image-processing/math convolution is slightly different. The kernel/filter is flipped around both axes before the multiplication.


konvolúciós kernel




eredeti kép




konvolúciós kernel




eredeti kép



konvolúciós kernel




eredeti kép




Konvolúció


konvolúciós kernel




eredeti kép




konvolúciós kernel




eredeti kép



konvolúciós kernel




új kép



Eredmény:

- Egy új reprezentáció (új kép)
- 1 px-el kisebb minden irányban

Konvolúció



konvolúciós kernel


-1	-1	-1
0	0	0
1	1	1

*

=

?

Konvolúció




konvolúciós kernel

-1	-1	-1
0	0	0
1	1	1

*


=




Eltolás invariancia - egy él/kutya többnyire ugyanúgy néz ki, bárhol is van a képen.

Hubel, Wiesel & Sperry

- Macskák & majmok látása
 - hogyan reagál az agyuk optikai stimulusra
- kísérletek
- 1981 Nobel díj




Hubel & Wiesel kísérlete



Hubel & Wiesel: RECEPTIVE FIELDS, BINOCULAR INTERACTION AND FUNCTIONAL ARCHITECTURE IN THE CAT'S VISUAL CORTEX, 1961

Ez az agyi régió egy vízszintes éldetektor.
Tudunk hasonlót mesterséges neuronhálózatokkal?

Konvolúciós neurális hálózat




Minden konvolúciós kernel paramétere tanult a példák alapján! Az élkiemelő csak egy példa volt.

Első rétegek élkiemelők, mélyebb rétegekben egy-egy kernel összetettebb objektumokra aktiválódik.

Neurális hálózat tanítása - DJ pult

A minimalizálási egyenletet nem lehet megoldani, apró lépésekben változtatjuk (optimalizáljuk) a súlyokat.
Tanulás a tanítóhalmaz példái alapján.




Helikopter analógia

History of the helicopter

1100

Chinese flying top



1483

Leonardo da Vinci's helical airscrew



1784

Launoy and Bienvenu's feather model



1843

Sir George Cayley's steam-powered model




1907

Paul Cornu's first man-carrying helicopter



1916

István Petróczy and Theodore von Kármán's tethered helicopter




1923

Juan de la Cierva's autogiro



1936

Focke Achgelis Fa 61, the first successful helicopter



1939

Sikorsky VS-300, the first practical helicopter in the U.S.



© 2012 Encyclopædia Britannica, Inc.

Kulcsfontosságú komponens hiánya: erős belső égésű motor.



Article | [Open Access](#) | [Published: 15 March 2018](#)

Detecting and classifying lesions in mammograms with Deep Learning


[Dezsó Ribli](#) , [Anna Horváth](#), [Zsuzsa Unger](#), [Péter Pollner](#) & [István Csabai](#)

[Scientific Reports](#) 8, Article number: 4165 (2018) | [Cite this article](#)

38k Accesses | 264 Citations | 57 Altmetric | [Metrics](#)


Abstract

In the last two decades, Computer Aided Detection (CAD) systems were developed to help radiologists analyse screening mammograms, however benefits of current CAD technologies appear to be contradictory, therefore they should be improved to be ultimately considered useful. Since 2012, deep convolutional neural networks (CNN) have been a tremendous success in image recognition, reaching human performance. These methods have greatly surpassed the traditional approaches, which are similar to currently used CAD solutions. Deep CNN-s have the potential to revolutionize medical image analysis. We propose a CAD system based on one of the most successful object detection frameworks, Faster R-CNN. The system detects and classifies malignant or benign lesions on a mammogram without any human intervention. The proposed method sets the state of the art classification performance on the public INbreast database, AUC = 0.95. The approach described here has achieved 2nd place in the Digital Mammography DREAM Challenge with AUC = 0.85. When used as a detector, the system reaches high sensitivity with very few false positive marks per image on the INbreast dataset. Source code, the trained model and an OsiriX plugin are published online at https://github.com/riblidezso/frcnn_cad.



Néhány téma a kutatócsoportunkból

ELTE Komplex Rendszerek Fizikája Tanszék, Csabai István csoportja



Patológiai adatok, publikálás folyamatban.



Article | [Open Access](#) | [Published: 14 September 2020](#)

Understanding and predicting ciprofloxacin minimum inhibitory concentration in *Escherichia coli* with machine learning

[Bálint Ármin Pataki](#) [✉](#), [Sébastien Matamoros](#), [Boas C. L. van der Putten](#), [Daniel Remondini](#), [Enrico Giampieri](#), [Derya Aytan-Aktug](#), [Rene S. Hendriksen](#), [Ole Lund](#), [István Csabai](#), [Constance Schultz](#) & [SPS COMPARE ML-AMR group](#)

[Scientific Reports](#) **10**, Article number: 15026 (2020) | [Cite this article](#)

3574 Accesses | 10 Citations | [Metrics](#)



Néhány eredmény - önvezető autók környezetérzékelése

Néhány cégnél lidar is van, de a Tesla pl csak kamerák képe alapján.



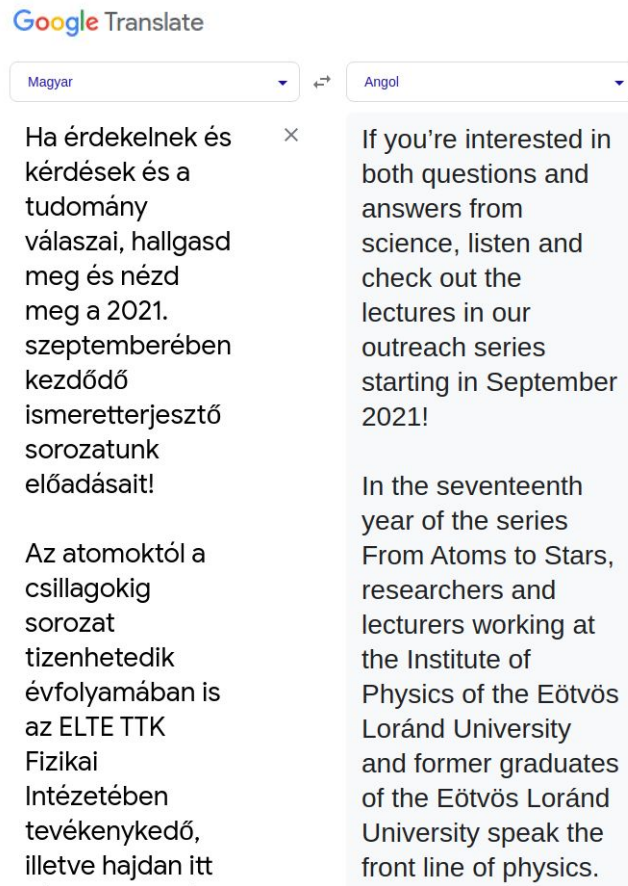
Kaiming He et al, 2018: Mask R-CNN

Néhány eredmény - nyelvi modellek

Más megközelítésű gépi tanulási modellek.

Kérdés - válasz, fordítás

A képeknél kellett címkézés, itt nem.



Google Translate

Magyar → Angol

Ha érdekelnek és kérdések és a tudomány válaszai, hallgasd meg és nézd meg a 2021. szeptemberében kezdődő ismeretterjesztő sorozatunk előadásait!

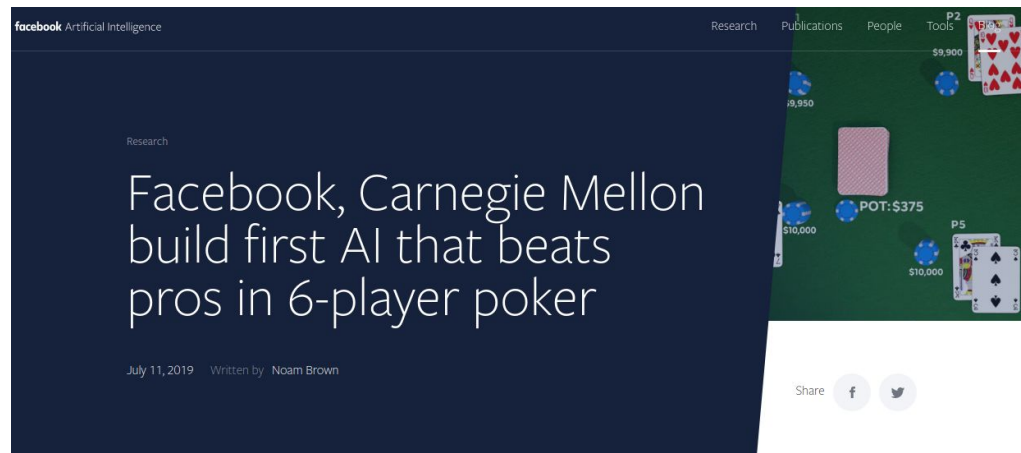
Az atomoktól a csillagokig sorozat tizenhetedik évfolyamában is az ELTE TTK Fizikai Intézetében tevékenykedő, illetve hajdan itt

If you're interested in both questions and answers from science, listen and check out the lectures in our outreach series starting in September 2021!

In the seventeenth year of the series From Atoms to Stars, researchers and lecturers working at the Institute of Physics of the Eötvös Loránd University and former graduates of the Eötvös Loránd University speak the front line of physics.

Néhány eredmény - reinforcement learning


Más megközelítésű gépi tanulási modellek.



AlphaGo - The Movie | Full award-winning documentary

YouTube · DeepMind
2020. márc. 13.

A gépi tanulás széles körben alkalmazható módszer.



vizsla



barna medve

Neurális háló:

- célzottan át lehet verni neurális hálózatokat
- csak egy-egy szűk szegmensben működnek jól
 - “narrow AI”
 - sok tanítóadat kell
 - az ember nem ilyen
 - nagy számítási kapacitás kell többnyire
- fekete doboz
 - túl bonyolult ahhoz, hogy teljesen meg lehessen érteni mit miért prediktál ← a problémák is komplexek
 - ha van jól működő, érthető megoldás, azt célszerűbb választani

Recap

1. "Mankók" kellenek
2. Adatintenzív tudományok
3. Egyenesílesztés (rugóerő) - tanulás példák alapján
4. Képek számítógépes tárolása
5. Neuron, neurális hálózatok
6. Éldetektor, konvolúció
7. Eredmények

The image shows a page of handwritten physics notes with various equations and diagrams. Key sections include:

- Mechanics:** Equations for velocity $v = 2g \sin \theta \cdot x$, $v^2 = 2gh$, and $v_3 = \sqrt{2g}$. It also shows energy calculations like $E_{pot} = \frac{1}{2} \frac{F \cdot R}{4\pi \epsilon_0 r}$ and $E_{kin} = \frac{1}{2} m v^2$.
- Optics:** Ray diagrams for a lens and a mirror, with focal lengths f and F . Equations include $\frac{1}{A} = \frac{1}{B} + \frac{1}{C}$ and $\frac{1}{f} = \frac{1}{u} + \frac{1}{v}$.
- Waves:** A sinusoidal wave diagram with $y(x,t) = A \sin(2\pi \frac{x}{\lambda} + \delta)$ and $y(x,t) = A \sin(kx - \omega t)$. It also shows wave speed $v = \frac{\omega}{k}$ and $\lambda = 2.75 \text{ m}$.
- Other:** A diagram of a pulley system, a diagram of a sphere with forces, and a diagram of a circular path with forces $F_c = F \sin \phi$.

<http://blog.cambridgecoaching.com/what-physics-equation-sheets-can-do-for-you-and-what-they-really-really-cant>

Hol lehet ilyet tanulni?

Neurális hálózatok, avagy mit is hívunk többnyire mesterséges intelligenciának?

Az atomoktól a csillagokig
17. évad
2021-2022. tanév

Pataki Bálint Ármin

ELTE, Komplex Rendszerek Fizikája Tanszék

2022.03.10.