

Hogyan tanítsunk gépeket tanulni?

Modern fizikai eredmények alkalmazása a
gépi tanulás területén

Pósfay Péter

Wigner FK, Komputációs tudományok osztálya

A gépi tanulás ma

A gépi tanulás rövid története

- ▶ 1944: A neurális hálók ötlete, McCullough – Pitts [1]
- ▶ 1957: Az első tanítható neurális háló (Perceptron), Cornell University F. Rosenblatt
- ▶ 1959: Minsky, Papert: Perceptronok gyakorlati célokra nem alkalmasak
- ▶ 1969–ig: az MIT-n aktívan kutatott terület a Neurális hálók, majd elhal
- ▶ 1980–as évek: 2–3 rétegű hálók, ezekre már nem igazak Minsky és Papert kritikái, de nincsenek elég erős számítógépek, hogy növeljék a teljesítmény
- ▶ 1985: tanítási módszerek fejlődése, Rumelhart, Hinton, and Williams újra felfedezik a “**backpropagation**”-t (Paul Werbos pszichológiai inspiráció alapján 1974) [2]

A modellek fejlesztését gyakran inspirálta a pszichológia és a neurológia

Első machine learning “tél” kezdete

Második machine learning “tél” kezdete

Machine learning tél: a neurális hálók fejlesztésének üteme visszaesik. Általában a technológia túlreálmozása miatti túlzó elvárásokat nem tudják teljesíteni és a befektetők elfordulnak.

“Self Driving cars are less than a year away.” – Elon Musk, 2015

A gépi tanulás rövid története

- ▶ **1989:** LeCun, Bell Laboratóriumok, backpropagation demonstrációja, kézírott számjegyeket felismerő rendszer
- ▶ **1992:** Cortes és Vapnik “**Support vector machines**”, szebb matek jobban érthetőek, mint a neurális hálók [3]
- ▶ **1997:** **LSTM** (rövid –hosszú távú memória modellek) rekurrens neurális hálók fejlesztése Hochreiter, Schmidhuber [4] (nyelv felismerő, fordító rendszerek alapjai)
- ▶ **1999:** neurális hálók a GPU–knak köszönhetően kompetitívvé válnak a Support vector machine–okkal szemben
- ▶ **2012:** **DEEP Learning**, ALEXNet G. Hinton képfelismerő neurális háló, Sokkal több rétegű hálók megjelenése (10–50) [5]
- ▶ **Ma:** Big Data és mély neurális hálók korát éljük, ahol egyre komplexebb feladatok oldhatóak meg neurális hálókkal, akár társadalmi problémákat okozva:
Esszé generátorok, AI festés

Házi feladat:

<https://www.wombo.art/create>

Prompt:

Cat reading a book

Comic style

10 másodperc alatt !



- GPU teljesítmény nő
- BIG DATA
- Cloud Computing

Modern gépi tanulás főbb elemei

MÉLY
(DEEP LEARNING)


**NEURÁLIS
HÁLÓK**



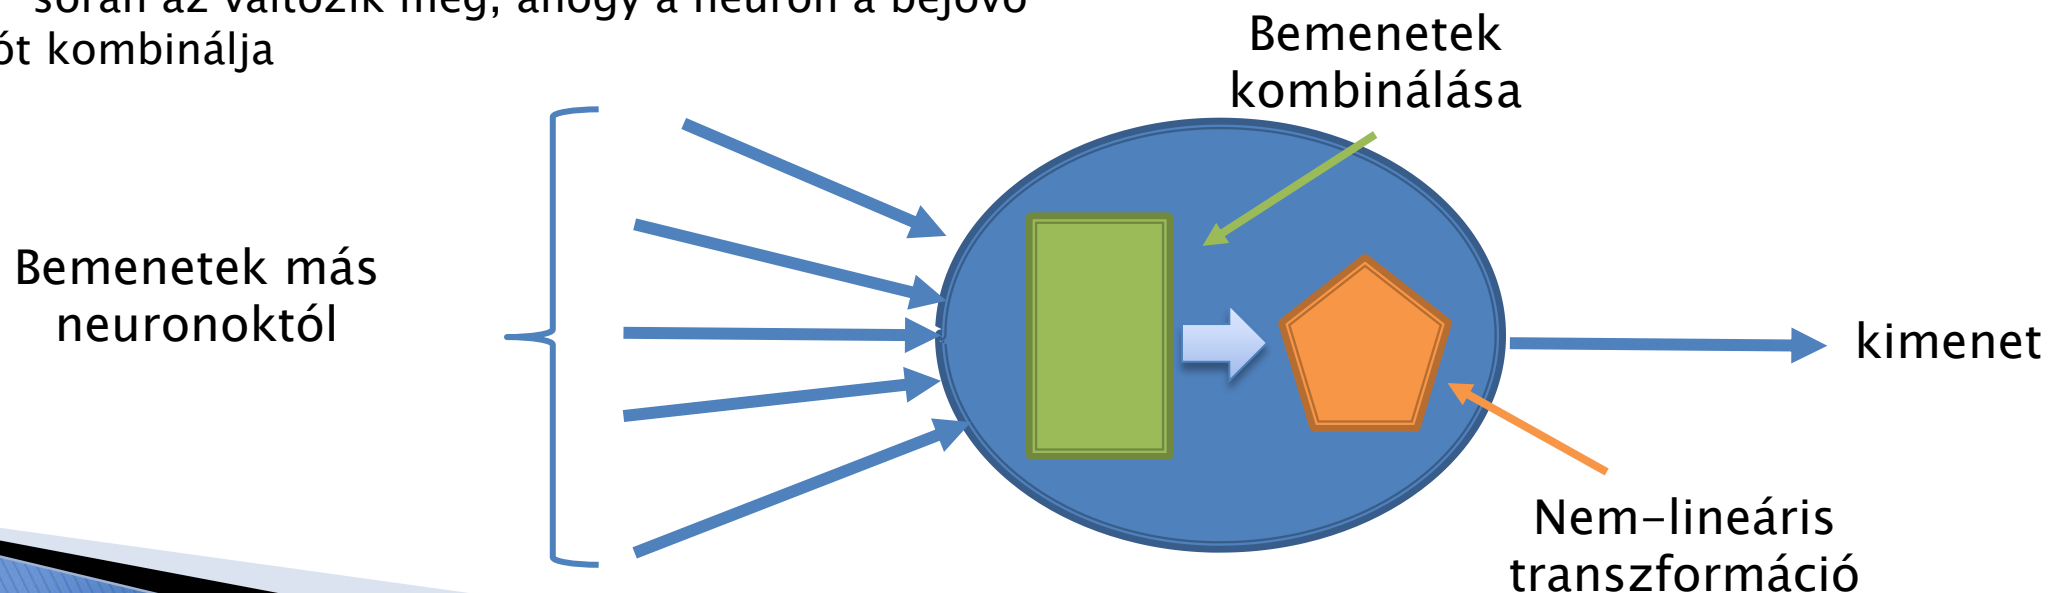
**TANÍTÓ
HALMAZOK**

Neurális háló

- ▶ Az idegsejtek működése által inspirált számítási hálózat
- ▶ “Neuronokból” áll, ami egy számítási egység ami kombinálja a bemenő információt és kimenetet képez belőle
 - A kombinációs lépés “egyszerű” : Lineáris kombinálás
 - Nem-lineáris transzformáció: Aktivációs függvény
- ▶ A neuronokat hálózatba rendezik általában rétegenként szervezve.
- ▶ A “tanulás” során az változik meg, ahogy a neuron a bejövő információt kombinálja

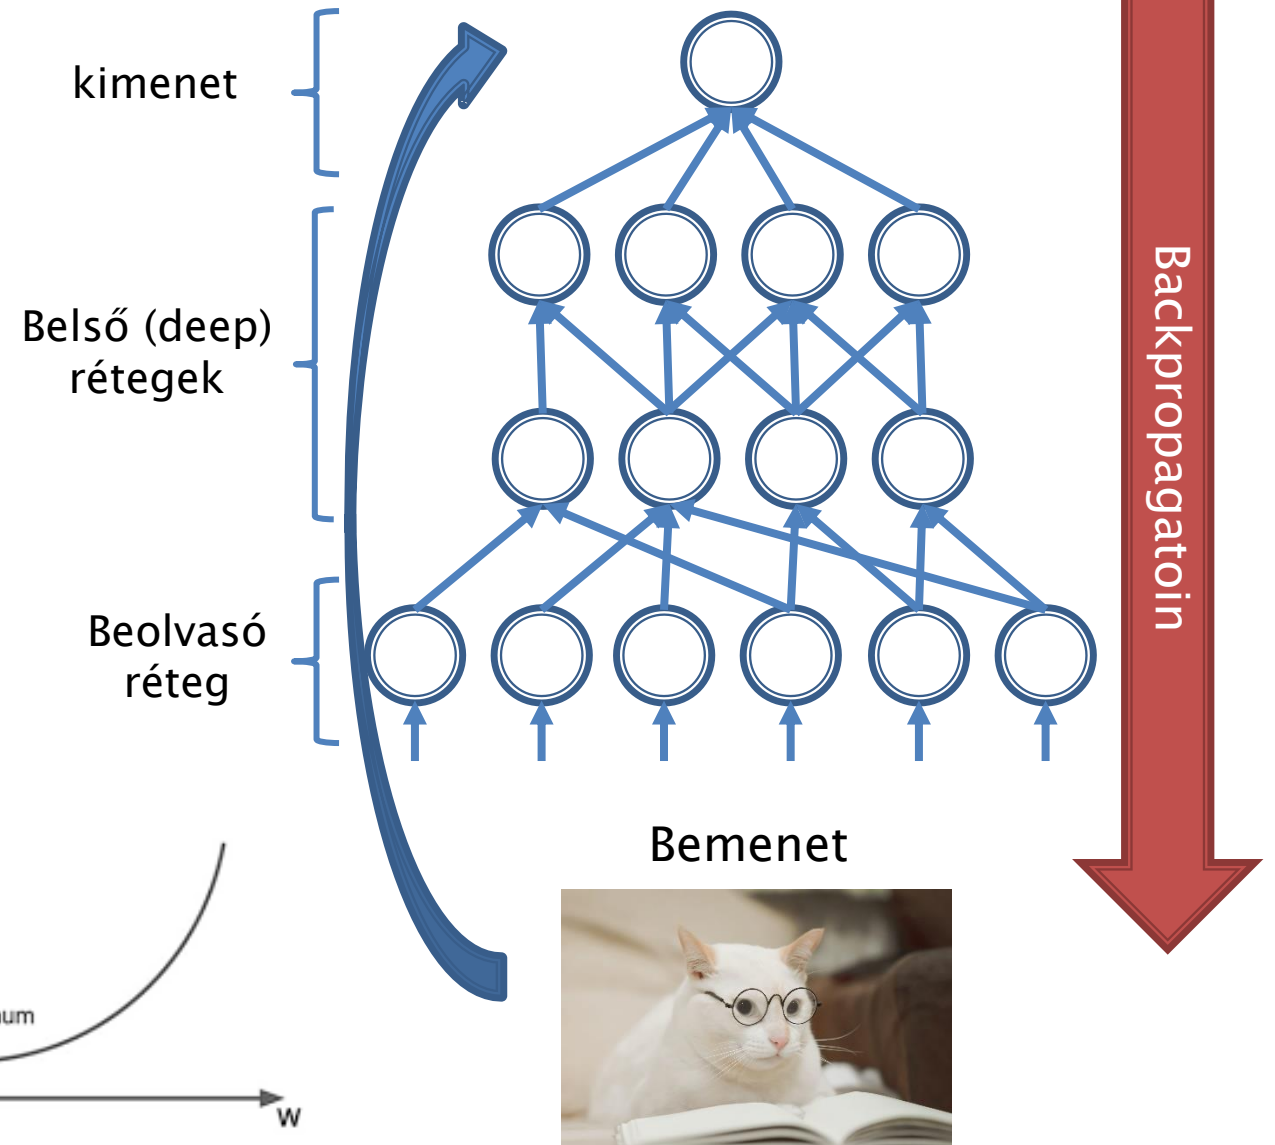



Itt történik a tanulás !!



Hogyan “tanul” a neurális háló?


- ▶ A beolvasó réteg kap egy ismert mintát amihez előre tudjuk milyen kimenet tartozik
- ▶ A háló feldolgozza az adatokat és ad egy kimenetet, amit összehasonlítunk az elvárt értékkel
 - Összehasonlítás: **COST** függvény. Számszerűen megmondja mennyire hasonlóak.
- ▶ A kettő különbsége alapján módosítjuk a háló belső paramétereit úgy, hogy közelebb legyen a kimenethez.
 - **Backpropagation**: megmutatja, hogy a háló paramétereinek kis változtatás milyen hatással lenne a kimenetre
 - **Gradient descent**: Felhasználva a backpropagation eredményét megmutatja, hogyan kell változtatni a paramétereiket, hogy az elvárt kimenethez közelebbi eredményt kapjunk



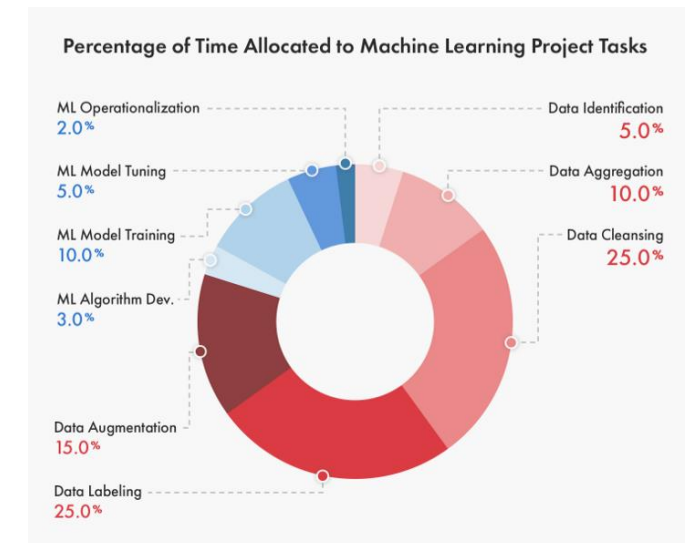
Miért ilyen sikeresek a neurális hálók?

- ▶ A neurális hálók lényegében nagyon sok paraméteres függvények
- ▶ A tanulás a függvény “fittelése”, illesztése az adatokra.
- ▶ Bizonyítható, hogy **univerzális approximátorok**, azaz nagyon bonyolult összefüggéseket is le tudnak írni [6,7].
 - A bizonyítás nem konstruktív, azaz nincs egy általános módszer tetszőleges adatok leírására.
- ▶ Nagyon jó tanító halmazokkal rendelkezünk.
 - Előállításuk drága és emberi munkaerőt igényel.
 - Nem elhanyagolható tényező, nagy cégek sikere mögött sokszor az “adatvásárlás áll”.
 - Az adattisztítás és címkézés teszi ki a legtöbb project időt kb (65%) még a tényleges fejlesztés kb. 20%. [8]
- ▶ A neurális hálók achilles-sarka pont az tanulási halmaz:
 - Bonyolult dolgok fitteléséhez egyre nagyobb tanító halmazokra van szükség (**kombinatorikai robbanás**) és ezt már nem tudjuk előállítani.
 - Nem tudunk minden furcsa esetre elég sok példát hozni. (a szemüveget viselő macskát eltérő esetekben eléterő módon kellene kategorizálni.

$$f(x) = \frac{1}{1 + e^{-\left(\frac{w_{21}}{1+e^{-(w_{11}x+b_{11})}} + \frac{w_{22}}{1+e^{-(w_{12}x+b_{12})}} + b_2\right)}}$$



Két neuronos “hálózat”, mint függvény



A neurális hálók problémái

- ▶ A bonyolultabb feladatokhoz szükséges tanító halmazok mérete túl nagyra nő
- ▶ Nem tudjuk, hogy pontosan hogyan valósítják meg a feladatot, mit tanulnak meg.
 - Nagyon más módon tanulnak mint az emberi agy: a bemenet–kimenet függvény nagyon nem folytonos [9]
 - Pontos hibabecslés szinte lehetetlen
 - Nem alkalmazhatóak biztonsági előírásokat alkalmazó rendszerekben
- ▶ Nincs visszajelzés arra vonatkozóan, hogy egy döntés mennyire biztos
 - Az ember számára detektálhatatlan különbségek katasztrófális hibákat okoznak [10]
 - Az ember számára nyilvánvaló különbségeket nem detektálja
- ▶ Ha a tanítási folyamat befejeződött már nehéz új információt hozzáadni a rendszerhez (Catastrophic forgetting)

A módosított képeket mind “strucc”-ként ismeri fel a NN



Eredeti kép

különbség

Módosított kép

Fizika a gépi tanulásban

Miben segíthet a fizika?

▶ Neurális hálók működésének megértése

- Tanítási folyamat optimalizálása
- Hálók szerkezetének optimalizálása
- Jobban megérthetjük miért hibáznak a hálók bizonyos esetekben
- Megérthetjük milyen problémákra optimális neurális hálókat használni

▶ Új algoritmusok kifejlesztése

- Kiszóró minták detektálása (a ML rendszer jelezzen ha valami nagyon ismeretlent lát) – > biztonságtechnikai alkalmazások
- Egyszerű kategorizálás helyett valamilyen becslést adni arra, hogy mennyire biztos a rendszer az eredményben.

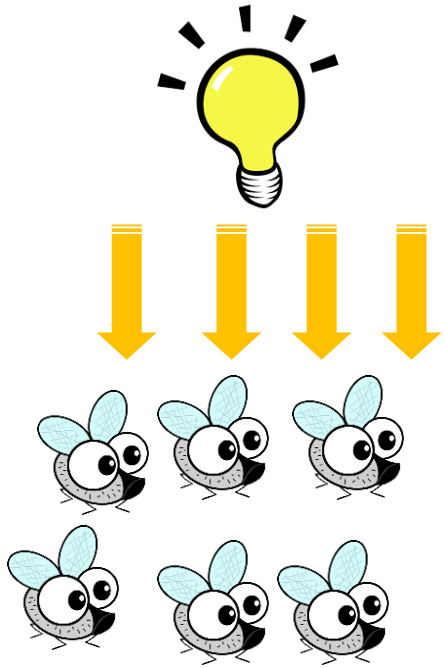
▶ A gépi tanulási feladatok pontos matematikai definiálása

- Mit jelent a “tanulás”
- Mit jelent a megértés?

Renormálás

- A récssecskefizika és statisztikus fizika területén fejlődött ki
- Fázisátalakulások leírása
- Annak leírása hogyan alakulnak ki a mérhető mennyiségek a mikroszkópikus törvényekből
- A mikroszkópikus és makroszkópikus mennyiségek közötti kapcsolat vizsgálata

Renormálás = Árnyékolás

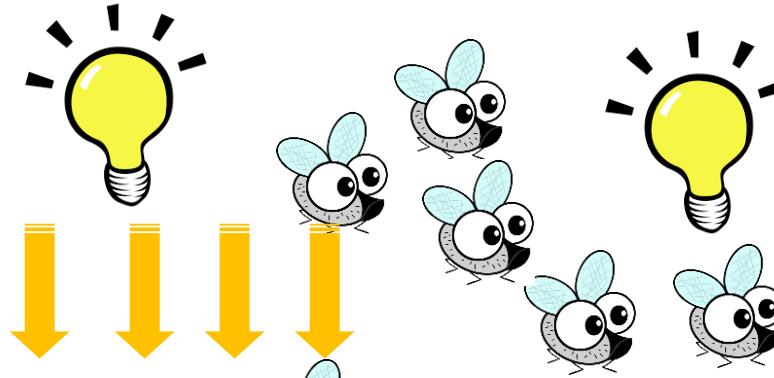


1.
Legyek reagálnak
a fényre és köré
gyűlnek




2.
A fényt árnyékolja
az aktív "közeg"

3.
A mért fény kisebb
erősségű, mintha
nem lennének
legyek.



5.
A legyek
elrendeződése
megváltozik

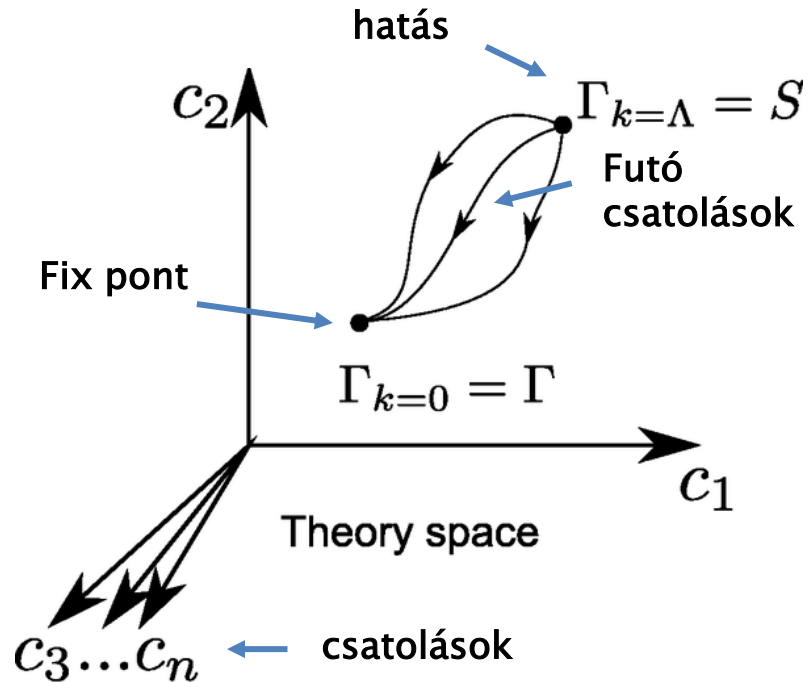
4.
Bekapcsol egy
másik lámpa



6.
A fényerősség amit mérünk
szintén megváltozik.

- Legyek: a mikroszkópikus mennyiségek: amiket közvetlenül nem látunk de a kölcsönhatást írják le
- Fényerősség, izzók helyzete: makroszkópikus mennyiség amit mérünk

Modern formalizmus – Elméletek tere



Analógia

Csatolások – neurális háló paraméterei

Hatás – COST függvény

Fix pontok: a háló tanult állapota


- ▶ **Skálafüggő effektív hatás (Γ_k):**
 - A rendszert jellemző kölcsönhatásokat írja le
 - A skálafüggő módon változik
- ▶ **Scale (k):**
 - Energia, impulzus, felbontás
 - Az a mennyiség ami befolyásolja a rendszer viselkedését
- ▶ **Fixed point:**
 - A hatás futása megáll
 - **Méréseket** a fix pontok körül teszünk
 - **Releváns operátorok:** Azok a kölcsönhatások amik meghatározzák a rendszer viselkedését a fix pont körül
 - **Irreleváns operátorok:** Az adott fix pontban nincsenek hatással a rendszer működésére
 - **NOTE:** más fixpontban más hatások lesznek relevánsak vagy irrelevánsak

A gépi megértés renormálás alapú megközelítése

- ▶ **X** : Véges halmaz aminek az elemeit vizsgáljuk
 - PL: Minden 1 MP -es kép
- ▶ **C**: Részhalmaz amit meg akarunk érteni
 - PL: 1 MP-es macskás képek
- ▶ **Koordinátázás**: $\xi: X \rightarrow B^N$ (bijekció)
 - Minden X-beli elem egy B halmaz beli vektornak felel meg
 - B : R részhalmaza, pl $B = \{0,1\}$ - monokróm képek
- ▶ Példa:

Megértés:

A releváns és irreleváns koordináták megkülönböztetése a C halmaz azonosításának céljából.



Megértés – a koordinátázás tulajdonságai

▶ A koordináták feltételes valószínűségi eloszlása:

- C: megérteni kívánt halmaz
- I: indexek listája
- σ : fix koordináta vektor
- Vegyük az elemeket C-ből és nézzük meg, hogy I-ben szereplő koordinátáknak milyen a hisztogramja.

$$p_i^{(C)}(\xi = \sigma)$$

▶ **faktorizáció:** adott I szet eloszlása független a többtől

▶ **Determinisztikus koordináta:** C minden elemére ugyanaz az értéke – RELEVÁNS KOORDINÁTÁK

▶ **Egyenletes eloszlás:** C-n a koordináta minden értéke felvehet – IRRELEVÁNS KOORDINÁTÁK

Megértés

C olyan koordinátázása ahol a koordináták függetlenek és a $p_i^{(C)}(\xi = \sigma)$ eloszlások vagy determinisztikusak vagy egyenletesek C-felett

Szokásos AI feladatok–átfogalmazva

- ▶ **Klasszifikáció** $C = \cup_a C_a$
 - Minden C_a halmazhoz meg kell találni a releváns (determinisztikus) koordinátákat, melyek más halmazokra nézve nem azok.
 - Kiszóró minták detektálás: a koordináták alapján még akkor is lehetséges ha nincs a tanító halmazban
- ▶ **Regresszió**
 - Speciális klasszifikáció: C_a -halmazok függvény értékek amiket az illesztendő paraméterek koordinátáznak.
- ▶ **Dekódolás**
 - Egy C halmaz eleme egyszerűen generálható: a koordináták teljesen megadják az elemet. A determinisztikusak adottak, az egyenletes eloszlásúakból pedig véletlenszerűen választunk.
- ▶ **Tömörítés**
 - Mivel a releváns koordináták állandóak, azokat nem kell külön tárolni csak az irrelevánsakat.

Szemléltetés

Értsük meg a macskás képeket

Releváns koordináták: Ezek minden macskás képre ugyanazok függetlenül a részletektől. A “macskaságot” ragadják meg.

Irreleváns koordináták: A macskás kép részletei, hol van a macska milyen szögben, milyenek a fények stb...

Alkalmazások


Mechanikai mozgások rekonstrukciója [12]

A feladat

- ▶ Adott egy mechanikai mozgás
- ▶ $r(t)$, $v(t)$, $a(t)$ adatok elérhetőek
- ▶ Ezek alapján folytassuk a mozgást.
- ▶ Azaz az idősorok alapján keressük meg a mozgástörvényt
- ▶ Határozzunk meg megmaradó mennyiséget.

Megoldási stratégia

- ▶ Tipikus LSTM feladat, de ehelyett a fentebb bemutatott módszert követjük
- ▶ Konstans mennyiségeket keresünk, amik a tanító halmaz minden elemére igazak. Ezek a determinisztikus koordináták.
- ▶ A mozgás folytatásához felhasználjuk az így megtalált összefüggéseket:
 - A jósolt mozgás koordinátáinak teljesíteniük kell ezeket az összefüggéseket – analógia a megmaradási törvényekkel. Ezeket a megmaradó mennyiségeket használjuk a rekurzió numerikus pontatlanságának javítására.



Gravitációs inga

Mechanikai mozgások rekonstrukciója II

Megoldás menete

- ▶ Newton 2. törvénye alapján a mozgás: $a_n = f_{\Delta t}(x_n, v_n)$
- ▶ Ha a diszkrét erőtvény ismert a mozgás már folytatható
- ▶ **Extreme learning machine**: csak egy rejtett réteg van
- ▶ h : folytonos függvény (feature). A neurális háló megtanulja, hogy kell ezeket kombinálni, hogy megkapjuk az erőtvényt.

Tanítás


- ▶ Az **Extreme learning machine** tanításához nem kell backpropagation, nagyon gyors.
- ▶ Numerikus esetben a kényszerek és az erő nem feltétlen következnek egymásból, ezért az erőtvényt, és a kényszereket (megmaradó mennyiségeket) külön tanítjuk.
- ▶ A tanítás a **PCA technikával** analóg műveletekre vezet – **Sajátérték egyenletek**

$$F^T F \bar{w} = F^T a.$$

Erőtvény


$$dF^T dF w = \lambda w$$

Megmaradó mennyiség


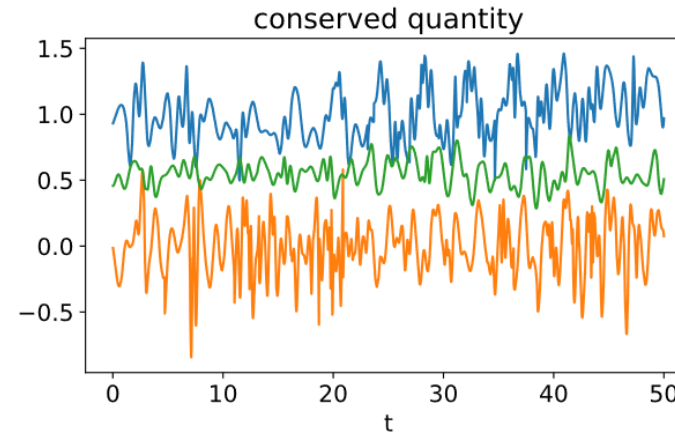


Extreme learning machine

Mechanikai mozgások rekonstrukciója – eredmények



Gravitációs ingára
vonalvastagságon belül
pontos eredmény



Kettős inga (kaotikus rendszer)

- Pontos rekonstrukció
- A mozgás véges marad nincs megszaladó megoldás
- A megmaradó mennyiségek stabilizálják az iterációt


Mozgástípusok osztályozása [12]

A feladat

- ▶ Adottak kísérleti alanyok mozgásszenzoros adatai.
- ▶ Formátum: Több féle szenzor jeleinek időSORA.
- ▶ Ezt felhasználva készítünk egy ML rendszert ami sikeresen kategorizálja az ilyen jeleket mozgástípusok szerint.

Megoldási stratégia

- ▶ Az előzőhöz hasonlóan időSOROKÉNT konstans mennyiségeket keresünk (Releváns koordináták) majd ezeket használjuk osztályozásra.
- ▶ Ezzel transzformáltuk a bejövő adatokat, azaz olyan koordináta rendszerre váltottunk amiben a feladat egyszerűbb.
- ▶ Akkor működik jól, ha az időSOROKHOZ rendelt megmaradó mennyiségek különbözőek, és ezért diszjunkt koordináták.
- ▶ Ezeken a transzformált releváns koordinátákon egyszerűbb osztályozó algoritmussal is nagy sikert lehet elérni.



	Applied feature space			
	Original		Transformed by LLT	
	Accuracy (%)	Time (sec)	Accuracy (%)	Time (sec)
Ensemble	75.7	238.4	99.7	313.4
KNN	75.6	40.5	100.0	59.2
DT	71.5	32.2	98.8	33.6
SVM	73.0	1379.2	100.0	1726.3

Köszönöm a figyelmet!

Referenciák

- ▶ [1] Mcculloch, Warren S. & Pitts, Walter (1943). A Logical Calculus of the Ideas Immanent in Nervous Activity. *Journal of Symbolic Logic*, 9 (2):49–50.
- ▶ [2] Rumelhart, D., Hinton, G. & Williams, R. Learning representations by back-propagating errors. *Nature* 323, 533–536 (1986). <https://doi.org/10.1038/323533a0>
- ▶ [3] Cortes, C., Vapnik, V. Support-vector networks. *Mach Learn* 20, 273–297 (1995). <https://doi.org/10.1007/BF00994018>
- ▶ [4] Sepp Hochreiter and Jürgen Schmidhuber. 1997. Long Short-Term Memory. *Neural Comput.* 9, 8 (November 15, 1997), 1735–1780. <https://doi.org/10.1162/neco.1997.9.8.1735>
- ▶ [5] Alex Krizhevsky, Ilya Sutskever, and Geoffrey E. Hinton. 2017. ImageNet classification with deep convolutional neural networks. *Commun. ACM* 60, 6 (June 2017), 84–90. <https://doi.org/10.1145/3065386>
- ▶ [6] Cybenko, G. Approximation by superpositions of a sigmoidal function. *Math. Control Signal Systems* 2, 303–314 (1989). <https://doi.org/10.1007/BF02551274>
- ▶ [7] Zhou, D. X. (2020). Universality of deep convolutional neural networks. *Applied and computational harmonic analysis*, 48(2), 787–794.
- ▶ [8] <https://towardsdatascience.com/data-labeling-is-chinas-secret-weapon-in-the-connected-car-battle-e8e395965380>
- ▶ [9] Szegedy, Christian & Zaremba, Wojciech & Sutskever, Ilya & Bruna, Joan & Erhan, Dumitru & Goodfellow, Ian & Fergus, Rob. (2013). Intriguing properties of neural networks.

Referenciák

- ▶ [10] Biggio, B. et al. (2013). Evasion Attacks against Machine Learning at Test Time. In: Blockeel, H., Kersting, K., Nijssen, S., Železný, F. (eds) Machine Learning and Knowledge Discovery in Databases. ECML PKDD 2013. Lecture Notes in Computer Science(), vol 8190. Springer, Berlin, Heidelberg. https://doi.org/10.1007/978-3-642-40994-3_25
- ▶ [11] Understanding understanding: a renormalization group inspired model of (artificial) intelligence A. Jakovac (Wigner RCP, Budapest), D. Berenyi (Wigner RCP, Budapest), P. Posfay (Wigner RCP, Budapest) e-Print: 2010.13482 [cs.AI]
- ▶ [12] Reconstruction of observed mechanical motions with artificial intelligence tools, Antal Jakovác,¹, Marcell T Kurucz and Péter Pósfay, 2022 New J. Phys. 24 073021
- ▶ [13] Kurucz, Marcell Tamás and Pósfay, Péter and Jakovác, Antal, Facilitating Time Series Classification by Linear Law-Based Feature Space Transformations (July 7, 2022). Available at SSRN: <https://ssrn.com/abstract=4161139> or <http://dx.doi.org/10.2139/ssrn.4161139>

Backup diák

Scientific understanding and neural networks

Understanding natural Phenomena


▶ Key Concepts in natural sciences

- Experiment, Phenomena
- Environment, measurement
- Isolation of measurement
- Neglecting certain aspects of the measurements (idealization)


▶ These can be more precisely understood in this framework

- X: all possible configurations of the world
 - There are infinitely many facts and possible measurements
- Subset C: singles out the phenomena we are interested in (experimental setup)
 - Defined by relevant coordinates over C
 - Neglecting irrelevant coordinates – idealizations, isolation, defining the measurement

Irrelevant



Relevant



Understanding natural Phenomena

▶ More precisely:

- Phenomena is defined by the **relevant (deterministic) coordinates** over C
 - They define the experimental setup (the slope, balls parameters etc..)
- **Irrelevant coordinates**: Do not influence the experiment (temperature, pressure etc..)
- $C = \cup_a C_a$ where C_a -s collect all the states of the world where the experiment results in measurement with a value a .
- **Partially relevant coordinates**: These are the most important ones, they decide that a given C_a corresponds to which parameter value, they fix the connection between measurement and the state of the world.

▶ Scientific method:

- A lot of experiments of the same kind to generate C
- Search for **relevant coordinates**: any measurement can be expressed as their function
- **Non-independent** relevant coordinates: their connections are physical laws
- Typically scientific theories have a **small number of relevant parameters**

Connection to renormalization


▶ Measurements have finite precision:

- At a given precision we can differentiate a given number of different outcomes
- C_a -s correspond to **interval of measurement results** (not a discrete value).
- C_a collects configurations of the system which produce „similar” measurements
- Changing the resolution changes which configurations are in one interval (C_a) and how many intervals (C_a -s) we have.

▶ Renormalization view:

- Precision is taken into account by a **scale: k**
- We **coarse-grain** the configurations at a given scale: We average configurations which are „similar”: differences are smaller than the scale
- This results in scale dependent $C_a(k)$ -s which form series as the scale changes
- At a given scale we have different relevant and irrelevant coordinates as C_a -s change.



Configurations in one box produce the same measurement value (a) at a given precision



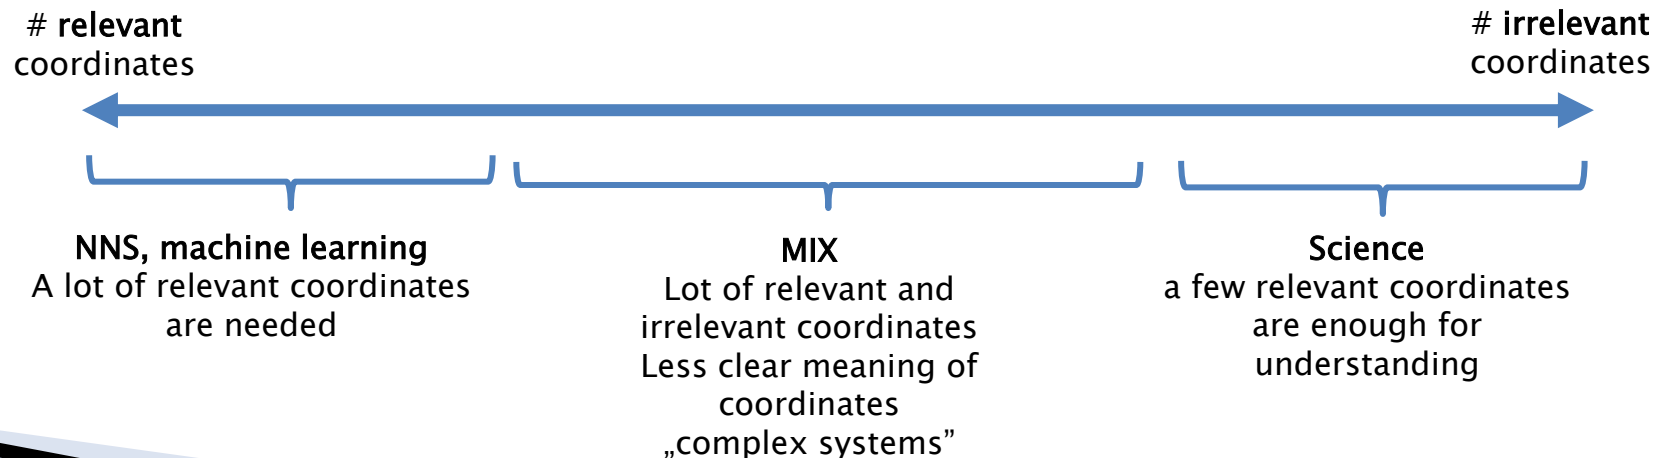
Scientific understanding vs neural networks

▶ Image classification as a typical task:

- Take all 256x256 pixel binary images
- A general picture has 65536 bits of information (irrelevant bits)
- Single out a subset of pictures which depict a **black square**
 - 3 irrelevant coordinates: square coordinates and size
 $3 \times 8 = 24$ bits
 - **All other 65512 bits are relevant!**



Scientific problems has only few relevant parameters!



Example: 3-bit image

- ▶ $X = \{000, 001, 010, 011, 100, 101, 110, 111\}$ $|X| = 8$
 - Coordinatization: $B = \{1,0\}$, $N = 3$
- ▶ $C = \{001, 010, 100, 111\}$ $|C| = 4$
- ▶ Probability distribution of the first coordinate over C:
 - $p_1^C(\xi_1 = 1) = \frac{2}{4} = \frac{1}{2} = p_1^C(\xi_1 = 0)$ (This is true for all other coordinates too $i = 2,3$)
- ▶ Expectation values
 - $\mathbb{E}(\xi_i | C) = \frac{1}{2}$
 - $\mathbb{E}(\xi_1 \xi_2 | C) = \frac{1}{4} = \mathbb{E}(\xi_1 | C) \mathbb{E}(\xi_2 | C)$ $C = \{\overset{0}{\underbrace{0}01}, \overset{0}{\underbrace{0}1}0, \overset{0}{\underbrace{1}0}0, \overset{1}{\underbrace{1}1}1\}$ FACTORIZES
 - $\mathbb{E}(\xi_1 \xi_2 \xi_3 | C) = \frac{1}{4} \neq \mathbb{E}(\xi_1 | C) \mathbb{E}(\xi_2 | C) \mathbb{E}(\xi_3 | C)$ NOT independent!
- ▶ It is easy to deal with cases when coordinates factorize
 - If coordinates factorize over a set, we can select them randomly and generate an element from the set
 - If they are not independent we this is not true, like above: