



Hálózatok alkalmazása a mesterséges intelligenciában - a lényeg és trükkök

Csermely Péter hálózatos kurzusa - Vassy Zsolt




“AI is like teenage sex: everyone talks about it, nobody knows how to do it, everyone thinks everyone else is doing it & so claims to do it”

"Az MI olyan, mint a tizenéves szex: mindenki beszél róla, senki sem tudja, hogyan kell csinálni, mindenki azt hiszi, hogy mindenki más csinálja és ezért azt állítja, hogy Ő is csinálja"

/ Dan Ariely prof. of Psychology and Behavioral Economics at Duke University/



Mesterséges Intelligencia, Gépi tanulás, Deep Learning



Since an early flush of optimism in the 1950s, smaller subsets of artificial intelligence – first machine learning, then deep learning, a subset of machine learning – have created ever larger disruptions.



Mi a mesterséges Intelligencia

Ideális esetben ez egy emberként viselkedő rendszer és / vagy egy emberként cselekvő rendszer.

Jelenleg racionálisan gondolkodó rendszerekről beszélhetünk, amelyek többnyire gépi tanuló rendszert jelentenek, vagyis a tapasztalatból történő tudás előállítását.

Egyszerűsítve: **A mesterséges intelligencia problémamegoldás változó körülmények között.**




Mesterséges intelligencia felhasználása

Algoritmusok, amelyek tanulnak az adatokból, és előrejelzéseket készítenek az adatok alapján.

Ha az algoritmus rendszer úgy optimalizálja a paramétereit, hogy az a teljesítmény javul, akkor ezt gépi tanulásnak tekintik.

Kétféle gépi tanulás van:

- **Felügyelt**
- **Felügyelet nélküli**



Legnépszerűbb tanuló algoritmusok


Support vector machine (SVM)

Nearest Neighbors

Decision tree és random forest - **Tartalmaz hálózatot**

Artificial neural networks - **Tartalmaz hálózatot**

Deep neural network / Deep learning - **Tartalmaz hálózatot**




Döntési fák

A fa egy olyan hálózat
(csomópontok és élek halmaza)
amely hierarchikusan rendezett.

A fa egy hurok nélküli gráf.

A general tree structure




Döntési fák

A döntési fa egy olyan fa, ahol minden belső csomópont egy döntési opciót (tesztet) tárol.

Minden levél tárolja a végleges választ.

Kép: kültéri vagy beltéri-e a fotó?


A decision tree





Döntési fák

A bemeneti adatok, pontokként jelennek meg egy d-dimenziós térben, amelyet a válaszokból építünk fel (2D ebben a példában).

A döntési fát a teljes tanító készlet építi fel a fába, és általában egy energia függvény segítségével optimalizálja a fa csomópontjainak döntési függvényeit.



Döntési fa tanítási példa



Bináris split funkció

A döntési csomópontra érkező $\mathbf{v}$ adatpont balra vagy jobbra kerül valamelyik gyermek-csomópontra a csomópont teszt-függvény eredményétől függően.







Fig. 3.4 Example weak learners. In this illustration the colors attached to each data point (circles) indicate different classes. (a) Axis-aligned hyperplane weak learner. (b) General oriented hyperplane. (c) Quadratic surface (conic in 2D). For ease of visualization here we have $\mathbf{v} = (x_1 \ x_2)^T \in \mathbb{R}^2$ and $\phi(\mathbf{v}) = (x_1 \ x_2 \ 1)^T$ in homogeneous coordinates. In general, a data point $\mathbf{v}$ may have a much higher dimensionality and $\phi(\mathbf{v})$ still a dimensionality ≤ 2

Döntési fa tanítása

Felügyelt esetben tanítás után minden levélhez (válasz nódushoz) hozzá lesz rendelve a tanítási adatok egy részhalmaza.


Tesztelés során egy korábban nem látott adat addig járja a fát amíg elér egy válasz-levelet.



Random forest - véletlen erdő

A random forest vagy magyarul véletlen erdő algoritmus együttes tanulás módszerét valósítja meg (ensemble learning), hogy klasszikus MI feladatokat oldjon meg: osztályozás (classification) vagy regresszió (regression).

A random forest algoritmus döntési fák sokaságának felépítésével működik.




Véletlenség - Randomness

A tanítás során kerül a véletlenszerűséget a fák köz.

Ennek két népszerű módja van:

- Véletlenszerű mintavétel (mintazsákolás - sample bagging)
- Véletlenszerű csomópont-optimalizálás (funkciócsomagolás - feature bagging)




Regressziós erdő

Regresszió: tanítási adatok és fa tanítás.

(a) A bemeneti jellemző tér ebben a példában egydimenziós. Y tengely mutatja az adathoz kapcsolt igazság címke értékét (mennyire tekintjük igaznak a bemeneti adathoz rendelt értéket).

(b) A tanítás után azkülönböző csomópontokhoz tartozó entrópia, ahogy haladunk lefelé a fa struktúrán csökken (ahogy a döntésben való meggyőződés - confidence - növekszik) .




THE PERCEPTRON — THE SIMPLEST MODEL


PERCEPTRON




ACTIVATION FUNCTIONS:



Step Function



Sign Function




Sigmoid Function


LEARNING:

$$y^{(t)} = f\left\{\sum_i w_i^{(t)} x_i^{(t)}\right\}$$
$$\text{Update} \begin{cases} \Delta w_i^{(t)} = \varepsilon (d^{(t)} - y^{(t)}) x_i^{(t)} \\ w_i^{(t+1)} = w_i^{(t)} + \Delta w_i^{(t)} \end{cases}$$

Igazi neuron



Mesterséges neuron



$$y_{in} = x_1 \cdot w_1 + x_2 \cdot w_2 + x_3 \cdot w_3 \dots x_m \cdot w_m$$

$$\text{i.e., Net input } y_{in} = \sum_i^m x_i \cdot w_i$$

Aktivációs függvény

Az aktivációs függvény határozza meg a csomópont válaszát (kimeneti adatsorát) egy adott ingerre (bemeneti adatsorra).


A mesterséges neurális hálózatok esetében gyakran nem lineáris aktivációs függvényeket használunk.

Előny ha folytonosan differenciálható (könnyebb vele tanítani).

Leggyakrabban használt aktivációs függvények:


- Sigmoid
- Tanh

Aktivációs függvények


Name ↕	Plot ↕	Equation ↕	Derivative (with respect to x) ↕
Identity		$f(x) = x$	$f'(x) = 1$
Binary step		$f(x) = \begin{cases} 0 & \text{for } x < 0 \\ 1 & \text{for } x \geq 0 \end{cases}$	$f'(x) = \begin{cases} 0 & \text{for } x \neq 0 \\ ? & \text{for } x = 0 \end{cases}$
Logistic (a.k.a. Sigmoid or Soft step)		$f(x) = \sigma(x) = \frac{1}{1 + e^{-x}}$ ^[1]	$f'(x) = f(x)(1 - f(x))$
TanH		$f(x) = \tanh(x) = \frac{(e^x - e^{-x})}{(e^x + e^{-x})}$	$f'(x) = 1 - f(x)^2$
ArcTan		$f(x) = \tan^{-1}(x)$	$f'(x) = \frac{1}{x^2 + 1}$
Softsign ^{[7][8]}		$f(x) = \frac{x}{1 + x }$	$f'(x) = \frac{1}{(1 + x)^2}$
Inverse square root unit (ISRU) ^[9]		$f(x) = \frac{x}{\sqrt{1 + \alpha x^2}}$	$f'(x) = \left(\frac{1}{\sqrt{1 + \alpha x^2}} \right)^3$
Rectified linear unit (ReLU) ^[10]		$f(x) = \begin{cases} 0 & \text{for } x < 0 \\ x & \text{for } x \geq 0 \end{cases}$	$f'(x) = \begin{cases} 0 & \text{for } x < 0 \\ 1 & \text{for } x \geq 0 \end{cases}$

Hogy lesz hálózat?

Ilyen egy biológiai:



Ilyesmi egy mesterséges:



Mesterséges neurális hálók és deep learning

DeepFace: Closing the Gap to Human-Level Performance in Face Verification




Figure 1: The model architecture of the encoder network, on the right the bottom encoder layer is bi-directional.

DeepDriving: Learning Affordance for Direct Perception in Autonomous Driving



Google AI Writes Dark Poetry after Reading Romantic Books

By IT Nings April 12, 2018

Share on Facebook Like on Twitter Google+ on Google+ LinkedIn on LinkedIn



amazon.com DeepMind Google



facebook IBM Microsoft

facebook IBM Microsoft


DeepLearning: Adat és GPU házassága



AI: Feature extraction + neural network




A deep learning mindent képes megtanulni




LeNet példa:


Convolutional Neural Networks



Alexnet: egyre bonyolultabb hálózati architektúrák



Kiváló példa hálózat: <https://playground.tensorflow.org>





Mesterséges Intelligencia az egészségügyben

Példákon keresztül
bemutatva:

- Melanoma Felismerés
- Hang alapján történő
diagnosztika

Miért melanóma felismerés? Van rá szabály!

ABCDE szabály

A - Asymmetry - Asszimetria


B - Border - Határvonal

C - Colour - Színek

D - Diameter - Átmérő

(E - Elevation - Magasság)

Humán hatékonyság 90% felett



A

symmetry

- One half is different from the other!



B

order


- Irregular, notched or blurry



C

olour

- More than one!



D


iameter

- Larger than 6mm (1/4 inch)



A deep learning kora


A tisztán deep learning-et alkalmazó rendszerek jobban teljesítettek, mint a hagyományos eljárások.

A közelmúltban a régi technikákat elkezdték kombinálni a deep learning-el (együttes tanulás vagy ensemble learning), és ezek a rendszerek a leghatékonyabbak.




ML: Feature extraction + mesterséges neurális hálózat





Hagyományos eljárások (fizika, it világából)

- Él keresés:
 - Lefedi az ABD szabályokat (Asymmetry, Border, Diameter)
 - Eljárás: Gaussian derivatives
- Szín keresés:
 - HSV (Hue, Saturation, Value)
 - DCD (Dominant Color Detection)
- Mina felismerés:
 - Gabor-filtering




A forradalmi deep learning

A deep learning valóban új, nagyságrendekkel jobb eredményeket ért el.

Ezeket az eredményeket azonban mindig fenntartásokkal kell elfogadni:

- A fekete doboz jellegű eljárás hibákhoz vezethet
- A gépi eljárás drasztikusan csökkenti a falcs pozitív eseteket (ami az egészségügyben problémás lehet)




Deep learning - black box

Nature folyóirat cikk 2017-ben, több mint 1000 alkalommal idézve.

A Deep learning alapú tanuló rendszer jobban teljesített mint 21 bőrgyógyász szakorvos.

BIAS vagyis hol ment félre: Valószínűbb volt a rosszindulatú rák kimutatása, ha vonalzó volt a képen.



A deep learning problémái

- Sok adatra és sok erőforrásra van szüksége a feldolgozásához (hosszú tanulási idő)
- Megtanulja, amit lát, nem alkalmaz logikát
- Fekete doboz, nem látod, mit csinál
- Könnyű átverni




Hang alapú diagnosztika Deep learning eljárással


Tudományos háttér: Érzelemfelismerés hangból

A hangban korábban használt jellemzők a hullámforma és a spektrogram.

A rendellenes hangzavarok tanulmányozására használt jellemzők: idő, frekvencia, zaj, spektrális szerkezeti tulajdonságok



COVID-19 hang alapú diagnózis



A COVID-19 egyedi módon módosítja a hangot és a köhögést is.

A betegség következtében megváltozott beszéd jellemzői:

- akusztikus hullám amplitúdó (befolyásolja a légzési koordináció)
- beszédsebesség és a cepstrum csúcsa (befolyásolja a gégemozgás)
- formáns középfrekvenciák (befolyásolja a gégemozgás és az artikuláció)



Miket lehet AI segítségével diagnosztizálni

Poszttraumás stressz diagnózis hangból.

A depresszió diagnosztizálása hang- és viselkedéselemzés alapján.

A depresszió és a szemmozgás összefüggései: a szem nyitásának mértéke, hosszan tartó pislogás (talán a szemkontaktus elkerülése miatt).

Az Alzheimer-kór diagnózisa akusztikus rendellenesség, szemantikai károsodás, szintaktikai károsodás és információ-romlás alapján. / A MI együttes alkalmazása és a nyelvi elemzés szükséges /



Milyen eredményeket ér el az AI?

Depresszió diagnózisa szemmozgás alapján 70-75%-os hatásfokkal / Eye movement analysis for depression detection, "IEEE International Conference on Image Processing, Melbourne, 2013 /

Alzheimer diagnózis átlag 7 évvel korábban és több mint 70%-os hatásfokkal. / Linguistic markers predict onset of Alzheimer's disease "The Lancet VOLUME 28, 2020 /

Poszttraumás stressz beszédből való diagnózisa 89%-os hatásfokkal / Speech - based markers for posttraumatic stress disorder in US veterans. Depress Anxiety. 2019 /

Pro és kontra



- Rengeteg diagnosztikai lehetőség: a terület gyors fejlődésével lehetőség nyílik a korai diagnózisra és a megelőzésre, akár otthonról, otthoni eszközökkel megvalósítva.
- Nem invazív, kis költségű eljárás: kis költséggel jár ezért sűrűn alkalmazható, hosszú távon költséghatékonyabbá téve az egészségügyi ellátást.
- Egy személy folyamatos megfigyelésével a változások azonnal észlelhetők.
- Fekete doboz működés: nem lehet pontosan tudni, hogy mit tanult a rendszer, hangminták esetén más paraméterek (életkor, testméret, fáradtság) félrevezetőek lehetnek
- Néhány mintát használnak tanításhoz / elemzéshez: 100-300 adat rekord egy olyan technológiához, amely sok adatot igényel, így a reprodukálhatóság kétséges lehet
- Adatvédelem: a beteg azonosítható lehet, érzékeny orvosi információk válhatnak elérhetővé



Összegzés

A mesterséges intelligencia rendszerek erős támogatást nyújthatnak a diagnosztikához

Az orvosoknak nem kell tartaniuk a munkájuk elvesztésétől

Az orvos - a mesterséges intelligencia együttműködés eredményes lehet



Köszönöm a figyelmet!

Vassy Zsolt
LinkGroup

