

„Mesterséges intelligencia az
orvosi gyakorlatban”
szabadon választható tantárgy
Kiemelt összefoglaló diák
2025. őszi félév


- Ismételten felhívom a figyelmet arra, hogy a Fazekas Szuzina és Budai Bettina előadások handout-jai kiemelt fontosságúak, a vizsga szempontjából is.

- Elérhetőségeim:

- Dr. Bérczi Viktor
- egyetemi tanár, az MTA doktora
- tanszékvezető helyettes
- Orvosi Képző Klinika, Radiológiai Tanszék, Semmelweis Egyetem
- 1082 Üllői út 78/a, Budapest, Hungary
- e-mail: berczi@hotmail.com; berczi.viktor@med.semmelweis-univ.hu;
- Budapest, Üllői út 78/a, tel: 210-0307
- mobil tel: 20-825-8091

Radiomika

„Radiomika a kép egy területéből származó kvantitatív adatokat alakítja át big data adathalmazokká és egy-egy eltérést több száz vagy több ezer numerikus paraméterrel jellemez”



plakk azonosítása

3D szegmentálás

numerikus paraméterek (big data)


Kolossváry / Maurovich-Horvat et al. *Jour Thor Img.* 2018




Manhattan plot - A Manhattan plot is a scatter plot used in genetics to visualize the results of a genome-wide association study (GWAS), showing the association of genetic variants (SNPs) with a trait.

Napking-ring jel radiomika alapú azonosítása


Vulnerábilis plakk



Stabil plakk



4440 radiomikai paraméter



Kolossvary / Maurovich-Horvat et al. Circulation CV Imaging, 2017 Dec



A jövő radiológusa

- Mesterséges intelligencia segítségével hatékonyabb munkavégzés válik lehetővé.
- A radiológusok orvosi képalkotó konzultánsokká válnak és a klinikusokkal szorosan együtt dolgozva a képalkotás előtt és után is konzultálnak, segítik a személyre szabott betegellátást.
- „Future radiologists will be far better than the radiologists of today because of machines, not in spite of them ...”



- Definition: **Artificial Intelligence** (Reference: Merriam-Webster)
 - „A machine's ability to make decisions and perform tasks that simulate human intelligence and behavior.
- Definition: **Machine Learning** (Source: Arkerdar: Business Intelligence for Business)
 - „A facet of AI that focuses on algorithms, allowing machines to learn and change without being programmed when exposed to new data.“
- Definition: **Deep Learning** (Source: HCIT Experts)
 - „The ability for machines to autonomously mimic human thought patterns through artificial neural networks composed of cascading layers of information.“

Artificial Intelligence

The field of computer science that seeks to create intelligent machines that can replicate or exceed human intelligence

Machine Learning


Subset of AI that enables machines to learn from existing data and improve upon that data to make decisions or predictions

Deep Learning

A machine learning technique in which layers of neural networks are used to process data and make decisions

Artificial intelligence (AI) and machine learning (ML) technologies

- methods



Machine learning algorithms used in the medical literature


Artificial intelligence in healthcare: past, present and future, svn-2017-000101

LLM – large language models: A large language model (LLM) is a type of AI trained on vast amounts of data to understand and generate human language.


The left screenshot shows a PDF editor window with a sidebar of tools and a main area displaying a table titled "AI in medicine – LLMs (Large Language Models)". The table lists various LLMs and their performance metrics. The middle screenshot shows a Windows desktop with various icons and a taskbar. The right screenshot shows a Microsoft PowerPoint presentation slide titled "Click to add title" with a bullet point "Click to add text".

Model	Company	Score
Olympus GPT-5	OpenAI	1000
Grok-3	xAI	1000
MAI-1	Microsoft	1000
2024 Grok-2	xAI	1000
2024 Llama 3.1	Meta AI	1000
2024 Claude 3.5	Anthropic	1000
2024 Gemini-4	NVIDIA	1000
2024 Llama 3.1	Meta AI	1000
2024 Grok-1.5	xAI	1000
2024 Claude 3	Anthropic	1000
2024 Gemini 1.5	Google	1000
2023 ERMIE 4.0	Baidu	1000
2023 Llama 2	Meta AI	1000
2023 Claude 2	Anthropic	1000
2023 GPT-4	OpenAI	1000
2023 Llama	Meta AI	1000
2022 GPT-3.5	OpenAI	1000
2022 PaLM	Google	1000
2021 ERMIE 3.0	Baidu	1000
2021 NLG	NVIDIA	1000
2020 GPT-3	OpenAI	1000
2020 BlenderBot 1.0	Facebook	1000
2019 GPT-2	OpenAI	1000
2018 BERT	Google	1000
2018 GPT-1	OpenAI	1000

Fontos fogalmak



Történeti áttekintés a kezdeteiktől



VERY BRIEF History OF Artificial Intelligence

1956 Dartmouth Conference: birth of the definiton/notion of AI


1974-2011 3x „AI winter” period with hype in between

1998 Yann LeCun (Facebook) Convolutional Neural Network (hand-written postal code reading)

AlexNet (2012) Geoffrey Hinton(Google): ImageNet contest winner(15.4 vs 26.2% error rate)

GoogLeNet (2015)

Microsoft ResNet (2015) 3.6% error rate (better than human)




Grudin, J. (2009). AI and HCI: Two fields divided by a common focus.

Frankish, K. & Ramsey, W.M. (2017). The Cambridge Handbook of Artificial Intelligence.

Non-deep learning

Deep learning+ convolutional neural networks

Cited by 9584



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

Neurális hálózat felépítése


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

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)

Példa folytonos aktivációs függvényre

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


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




Mesterséges neurális hálózatok:
**Tipikus neurális hálóval
megoldható feladatok**

Osztályozás:


adatok osztályokba sorolása



Függvényközelítés



Függvényközelítés




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**


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

„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 leállás módszere

- **tanuló-** és egy **validációs** halmaz,
- addig tanítunk, amíg a validációs halmazon **is csökken** a hiba.

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 „jósa” alapján

Felügyelt és felügyelet nélküli tanítás osztályozási feladat esetén




- A convolutional neural network (CNN) is a type of deep learning algorithm primarily used for image and visual data analysis. CNNs automatically learn and extract features from data with a grid-like structure, such as images, by using layers like convolutional, ReLU, and pooling layers. These extracted features are then fed into fully connected layers for tasks like image classification, object detection, and image segmentation.

Konvolúciós hálózatok

Pooling


- Klasszikus pooling művelet - a felbontás felezése:
 - Az eredeti kép pixeleit 2x2-es csoportokban kiátlagolják
- Klasszikus képfeldolgozási analógia:
 - ún. rank szűrők: pixelértékek statisztikai tulajdonságai alapján szűr
- **Pooling tulajdonságai:**
 - Exponenciálisan redukálja a dimenziószámot
 - A kernel méretével arányos csökkentés
- **Pooling típusai:**
 - **Avg Pooling:** a pixelcsoport átlagát veszi
 - **Max Pooling:** a pixelcsoport maximumát veszi
 - **Min Pooling:** a pixelcsoport minimumát veszi

A konvolúciós neurális hálózat (CNN) jellemző felépítése



Egy alap architektúra

- 1. réteg: konvolúciós
- 2. réteg: pooling
- 3-4. réteg: konvolúciós + pooling rétegpáros (ha szükséges még redukció)
- Eredmény kinyerése: (fully connected architektúra)
- ún. flatten réteg: a 2D --> 1D konverzió;
- ún. softmax réteg: eredmény normálása úgy (az összeg egy lesz)




What is kernel in CNN?

- In Convolutional neural network, the kernel is nothing but a filter that is used to extract the features from the images. The kernel is a matrix that moves over the input data, performs the dot product with the sub-region of input data, and gets the output as the matrix of dot products.


Unet

- Fully convolutional neural network: Teljesen **konvolúciós**, nem tartalmaz fully connected réteget
- Encoder-decoder részekre tagolódik
 - **Encoder** rész:
 - dimenzió csökkentés
 - **Decoder** rész:
 - Dimenzió növelés
- **Szemantikus** szegmentációs feladatok megoldására
- Kifejezetten **orvosi területre** szántál
- Alkalmazási példák:
 - Foggyökér szegmentáció
 - Máj szegmentáció
 - Vese szegmentáció



Vnet

- Ugyan az az elv, mint az U-net-nél
- 3D adatok feldolgozására optimális
- Bemenet és kimenet 3D adathalmaz




CE CERTIFICATION: CLASSES

- Software intended to provide information which is used to take decisions with diagnosis or therapeutic purposes is classified as **class IIa**, except if such decisions have an impact that may cause:
 - death or an irreversible deterioration of a person's state of health, in which case it is in **class III**; or
 - a serious deterioration of a person's state of health or a surgical intervention, in which case it is classified as **class IIb**.
- Software intended to monitor physiological processes is classified as **class IIa**,
 - except if it is intended for monitoring of vital physiological parameters, where the nature of variations of those parameters is such that it could result in immediate danger to the patient, in which case it is classified as **class IIb**.
- All other software is classified as **class I**.
- MDD vs **MDR**: European Medical Device Directives (soon to be replaced by the Medical Device Regulation)


CE CERTIFICATION: CLASSES

		Significance of Information provided by the MDSW to a healthcare situation related to diagnosis/therapy		
		High Treat or diagnose ~ <i>IMDRF 5.1.1</i>	Medium Drives clinical management ~ <i>IMDRF 5.1.2</i>	Low Informs clinical management (everything else)
State of Healthcare situation or patient condition	Critical situation or patient condition ~ <i>IMDRF 5.2.1</i>	Class III <i>Category IV.i</i>	Class IIb <i>Category III.i</i>	Class IIa <i>Category II.i</i>
	Serious situation or patient condition ~ <i>IMDRF 5.2.2</i>	Class IIb <i>Category III.ii</i>	Class IIa <i>Category II.ii</i>	Class IIa <i>Category I.ii</i>
	Non-serious situation or patient condition (everything else)	Class IIa <i>Category II.iii</i>	Class IIa <i>Category I.iii</i>	Class IIa <i>Category I.i</i>



<https://towardsdatascience.com/how-to-get-clinical-ai-tech-approved-by-regulators-fa16dfa1983b>

FDA CLEARED ALGORITHMS



STROKE








FDA clearance:
non- contrast CT ICH
detection
Sensitivity: 93.6% (95% CI:
86.6%-97.6%)
specificity: 92.3% (95%
CI: 85.4%-96.6%)."

Viz L

Using artificial intelligence to automatically

FDA CLEARANCE





Köszönet: Martos János 2018

CHEST XRAY ANALYSIS




Example results

Findings


- There is volume loss in both lungs. Ill defined opacities are present bilaterally.
- A left sided pleural effusion is seen filling the costophrenic sulcus.
- The hilar area is enlarged.
- The mediastinum is within normal limits.
- Central venous cathether is observed with tip at the superior vena cava.

Impression

Bilateral consolidation. Left pleural effusion.



RADIOTHERAPY: ORGAN/LESION SEGMENTATION/DELINEATION



Automatic segmentation



Pseudo CT generation

Dose prediction and automatic planning

Motion tracking

Outcome prediction

CAD OUTPERFORMING MAMMOGRAPHERS?




Performance of CAD software vs. radiologists by false-positive rates

	Radiologists	CAD software (at 100% sensitivity threshold for cancer detection)	Potential reduction in breast biopsies from use of CAD software
Academic radiology department	80%	35%	57%

Alyssa Watanabe of the University of Southern California (USC) Keck School of Medicine, ECR 2017



Mia™
CE



McKinney, S. M. *et al. Nature* 577, 89–94 (2020).

CONCLUSION


ML can surpass human level performance in certain, **narrowly defined** areas (narrow AI)

- Diagnostic/imaging reports **accelerated**, **precision** improved (segmentation, ECG)
- Correlation/regression information exploration (prediction, age assessment)
- Requirements: big database, standardized protocols, unified annotation

Ethical issues:

- low cost vs. narrow solution
- Responsibility?

Classification:



Segmentation:

