

RIBLI DEZSŐ


KOMPLEX RENDSZEREK FIZIKÁJA TANSZÉK, ELTE
TÉMAVEZETŐ CSABAI ISTVÁN

MAMMOGRÁFIAI DIAGNOSZTIKAI MESTERSÉGES INTELLIGENCIA RENDSZER

MIÉRT VAGYUNK ITT?



MESTERSÉGES INTELLIGENCIA LÁZ

- ▶ “Sorra verte a mesterséges intelligencia a világ legjobb gojátékosait”
- ▶ “Jobban látnak a Google gépei, mint az emberek”
- ▶ “Mesterséges intelligencia fog segíteni a bőrrák diagnosztizálásában”
- ▶ “Mesterséges intelligencia = harmadik világháború”
- ▶ Nagy remények és nagy túlzások médiában




NEURÁLIS HÁLÓK



- ▶ Teljesen összekötött neurális hálók
- ▶ Hubel és Wiesel: látókéregben lévő neuronoknak receptív mezeje van!
 - ▶ Ötlet: ne kössünk össze mindent mindennel!
- ▶ Fukushima: Neocognitron
 - ▶ Mesterséges neuronok kis receptív mezővel végigpásztázzák a képet.
 - ▶ A képekre jellemző "eltolás invarianciát" fogja meg
 - ▶ A keresett osztály a képen bárhol lehet, nem csak egy adott x-y pozícióban
 - ▶ A kép minden pontját hasonló jellemzőkkel lehet jól leírni: intenzitások, élek, sarkok textúrák mindenhol közel azonosan fontosak, nem csak a jobb alsó sarokban pl.
- ▶ Többrétegű neurális háló a vizuális percepció hierarchikus folyamatát fogja meg: élek, sarkok, egyszerű formák,..., lábak -> kutya



source: [Deep Learning book](#)



Fukushima, K., 1980




Lee, H. Et al. 2009



KONVOLÚCIÓS NEURÁLIS HÁLÓ (CNN)

- ▶ Praktikusan működő megvalósítása a kis receptív mezejű, csuszó ablakos neuronhálónak



forrás: Deep Learning könyv



- ▶ Konvolúciós neuron:
 - ▶ kis receptív mező (pl.:térben csak az első szomszéddal van kapcsolatban)





- ▶ Replikált súlyok, neuronok: a bemenetet minden pontban ugyanazokkal a paraméterekkel értékeli ki




[képek forrása](#)

KONVOLÚCIÓS NEURÁLIS HÁLÓ


- ▶ Praktikusan működő megvalósítása a kis receptív mezejű, csuszó ablakos neuronhálónak
- ▶ Konvolúciós neuronháló:
 - ▶ Egy paraméterű konvolúciós neuron aktivációs kimenetei egy aktivációs térképet alkotnak
 - ▶ Sok különböző paraméterű neuron egy rétegben: a kép reprezentációja az aktivációs térképek összessége
- ▶ Térképek leskálázása, következő neuron receptív mezejének hatékony növelésére



[source: deeplearning.net tutorial](https://deeplearning.net/tutorial)



GÉPI LÁTÁS FEJLŐDÉSE



kép forrása: wikipédia

- ▶ CNN a 80-as évektől ismert, karakter felismerésre sikeresen alkalmazták

- ▶ De ezt a feladatot más módszerekkel is nagyon jól meg lehetett oldani


- ▶ Ezután megakadt a neurális háló alapú gépi látás, és más irányba fejlődött a gépi látás területe

- ▶ Ügyes, a kép tulajdonságait jól jellemző mennyiségek, reprezentáció kinyerése, és ezeken egyszerű modellek tanítása (feature engineering)


- ▶ Ezzel ellentétben a konvolúciós neurális háló a nyers adaton dolgozik, a kimenete az osztály

- ▶ end-to-end tanulás, a kép tulajdonságait jól jellemző mennyiségeket is tanulja! A tanult reprezentációs a konvolúciós neuronok rétegei.

[kép forrása](#)



kép forrása: wikipédia




CNN FORRADALOM

- ▶ 80-as évektől ismert, mi hiányzott? (Minden...)
 - ▶ Számítási teljesítmény
 - ▶ Emberi agyban 100 milliárd neuron, számítógép 90-ben ...
 - ▶ Nagy adathalmaz
 - ▶ Komplex összefüggések megtanulásához rengeteg példa kell
- ▶ Számítási teljesítmény fejlődés
 - ▶ Google 2009-ben nagy klasztereken próbálkozik (Dean et al.), de a megoldás végül sokkal demokratikusabb lett: számítógépes játékok világának megjelenítésére kifejlesztett, masszívan párhuzamos (1000+processzor) grafikus chipek általános célú programozásával GPGPU (General-purpose computing on graphics processing units). Legfontosabb keretrendszer az NVIDIA gyártótól a CUDA.
 - ▶ Mára a grafikus kártyák mellett megjelentek a Google által kifejlesztett kifejezetten neurális háló célhardverek a TPU-k (Tensor Processing Unit), amik sokkal kevesebb energiát használnak, mint az általánosabb célú GPU-k, de még nem terjedtek el széles körben.
- ▶ Adathalmazok fejlődése
 - ▶ Imagenet: 14 millió nagy felbontású kép (300x500pixel) az internetről, emberek annotálták (Amazon Mechanical Turk) (Deng et al.), 22ezer kategória. ILSVRC verseny 2010-től: 1.2 millió kép részalmaz, 1000 kategória (Russakovsky et al.)




ILSVRC

- ▶ 2010, 2011: nincs CNN versenyző, 25% top5 pontosság
- ▶ 2012-ben az első CNN alapú versenyző (saját GPU-n futtatható neurális háló implementációval), 15% pontosság
 - ▶ 1989-es karakter felismerő hálózat felturbózva + ReLU (Rectified Linear Unit)
- ▶ Ember pontossága 4-5 %, szakértőkét 2-3%-ra becsülték.
 - ▶ <https://cs.stanford.edu/people/karpathy/ilsvrc/>
- ▶ Azóta folyamatos fejlesztés, rengeteg újdonság a neurális hálózatokkal kapcsolatban: mára 2% pontosság
- ▶ Tavaly be is zárták a versenyt, lényegében megoldottnak tekintik a feladatot (annotációs hibák, nem egyértelmű képek, etc).
- ▶ További nagy versenyek vannak, más gépi látás részfeladatokra. Objektum, gyalogos detekció, szegmentálás. Ezekben még van fejlődés.



CNN UGYANOLYAN, MINT AZ EMBERI LÁTÁS?

- ▶ A legnagyobb kép klasszifikációs benchmarkon a CNN megoldások egyenrangúak, ha nem jobbak, mint egy nagyon-nagyon koncentráló ember.
- ▶ Van különbség?
- ▶ Mi a közös ezekben a képekben?
 - ▶ CNN: mind strucc, és biztos!




ADVERSARIAL PÉLDÁK

- ▶ Az eredetit felismeri a CNN-hogy panda.
- ▶ Emberi szemmel észre nem vehető módosítás után, már magabiztosan gibbonnak nézi.
- ▶ Optikai illúzió mesterséges neuronhálónak
 - ▶ CNN átlátszó, ismerjük a működését, ki lehet számolni, hogyan kell rosszindulatúan picit megváltoztatni a képet, hogy inkább gibbon-t mondjon.
 - ▶ Eredeti szerzők szerint a CNN "túl lineáris" (könnyen tanul, könnyen átverhető)
 - ▶ Emberi látás/agy ilyen mértékű és irányú változtatásra teljesen érzéketlen
- ▶ Nagyon aktívan kutatott téma, sok alkalmazásban gondot jelenthet (kémkedés...)
 - ▶ Önvezető autók átverése a táblák változtatásával (ember számára látható, de nem túl gyanús módon) (Eykholt et al)
- ▶ Orvosi képfeldolgozásban ez csak egy érdekesség, nincs rosszindulatú támadásra, kép manipulációra lehetőség



Forrás: Szegedy et al




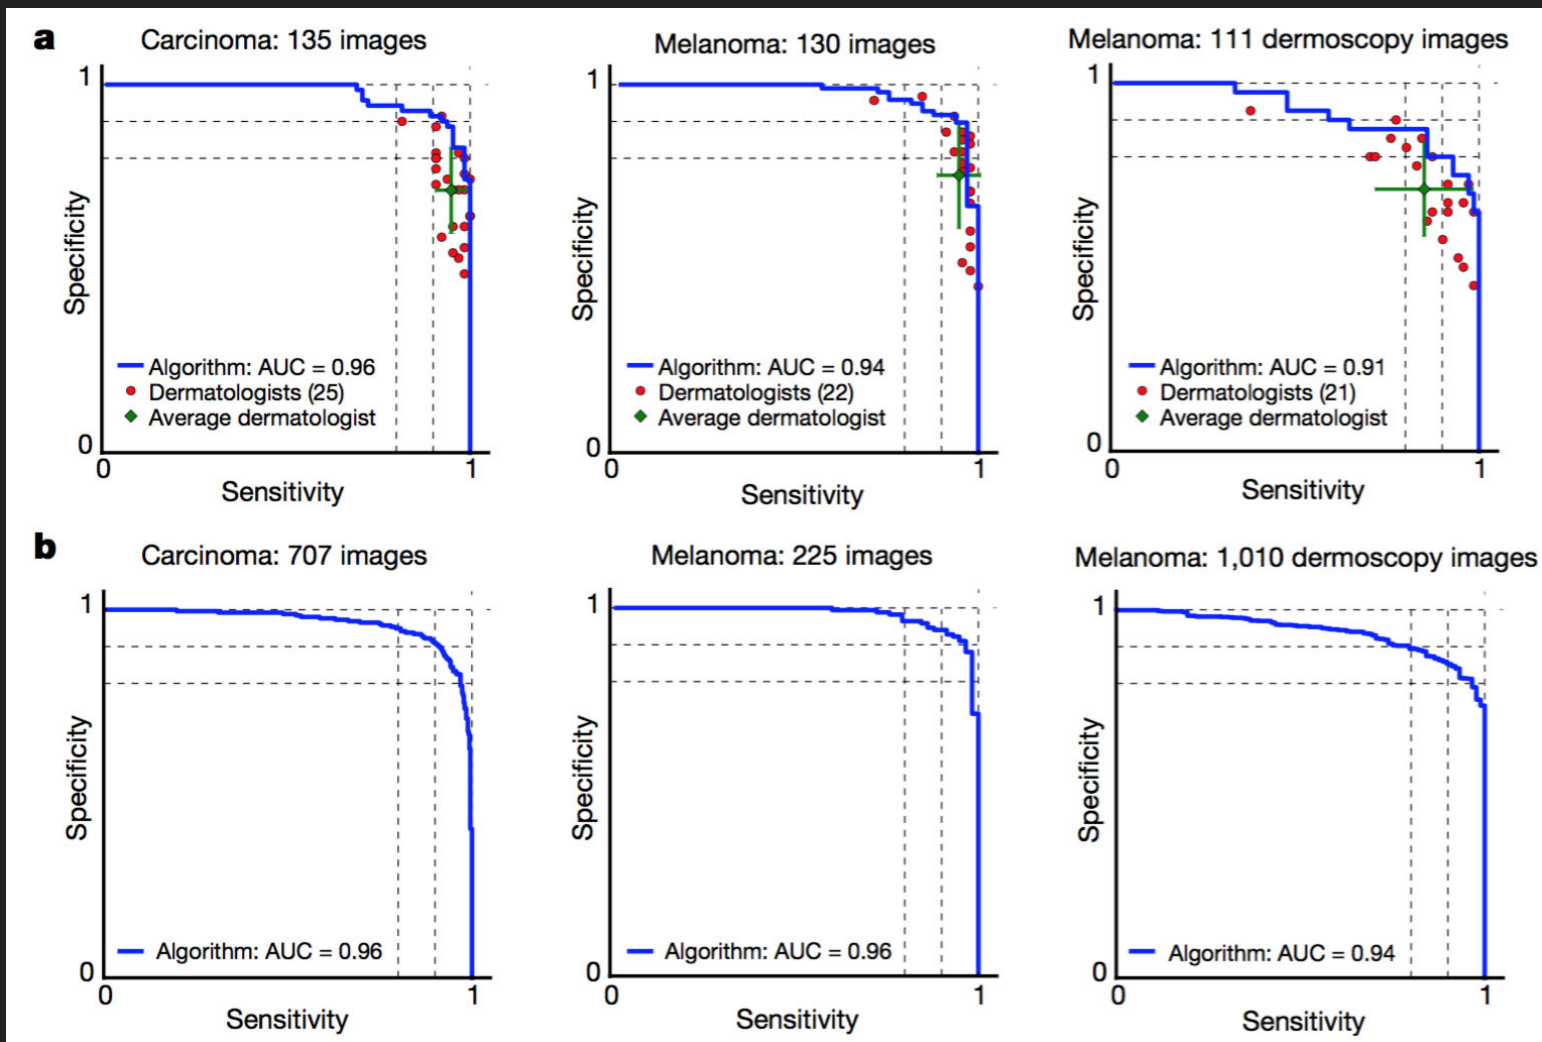
TOVÁBBI KÜLÖNBSÉGEK

- ▶ CNN sokkal egyszerűbb: a legbonyolultabb hálózatok is csak nagyjából száz millió paraméterrel rendelkeznek
- ▶ CNN hardver többeget fogyaszt, (de sokkal gyorsabban elemez (GoogleNet. 7 ezredmásodperc / kép))
- ▶ CNN csak jól definiált szűk feladatot képes ellátni
- ▶ CNN elég buta: tanításához egy speciális feladatra (jelenleg) sokkal több kép kell, mint egy ember számára. Csak címkézett példákból tud tanulni, nem lehet "elmagyarázni neki" hogyan néz ki egy kutya. Nem gondolkozik, csak mintázatot illeszt! Ehhez sok példa kell.
- ▶ CNN nagyon szorgalmas, olyan mennyiségű képanyagon lehet tanítani, amit egy ember egész élete során sem tudna feldolgozni
- ▶ CNN nagyon gyorsan tanul: 1 óra alatt (!) betanítható az emberi teljesítmény elérésére az ILSVRC-n
- ▶ A CNN sosem fárad el






CNN A KÉPALKOTÓ DIAGNOSZTIKÁBAN

- ▶ Bőr rák: kép osztályozás
- ▶ Esteva et al.
- ▶ Emlékeztető: szenzitivitás: TP/P, specificitás: TN/N



CNN A KÉPALKOTÓ DIAGNOSZTIKÁBAN

- ▶ Diabéteszes retinopátia: 3D kép klasszifikáció, (De Fauw et al)



ARTICLES

<https://doi.org/10.1038/s41591-018-0107-6>

nature
medicine

Clinically applicable deep learning for diagnosis and referral in retinal disease

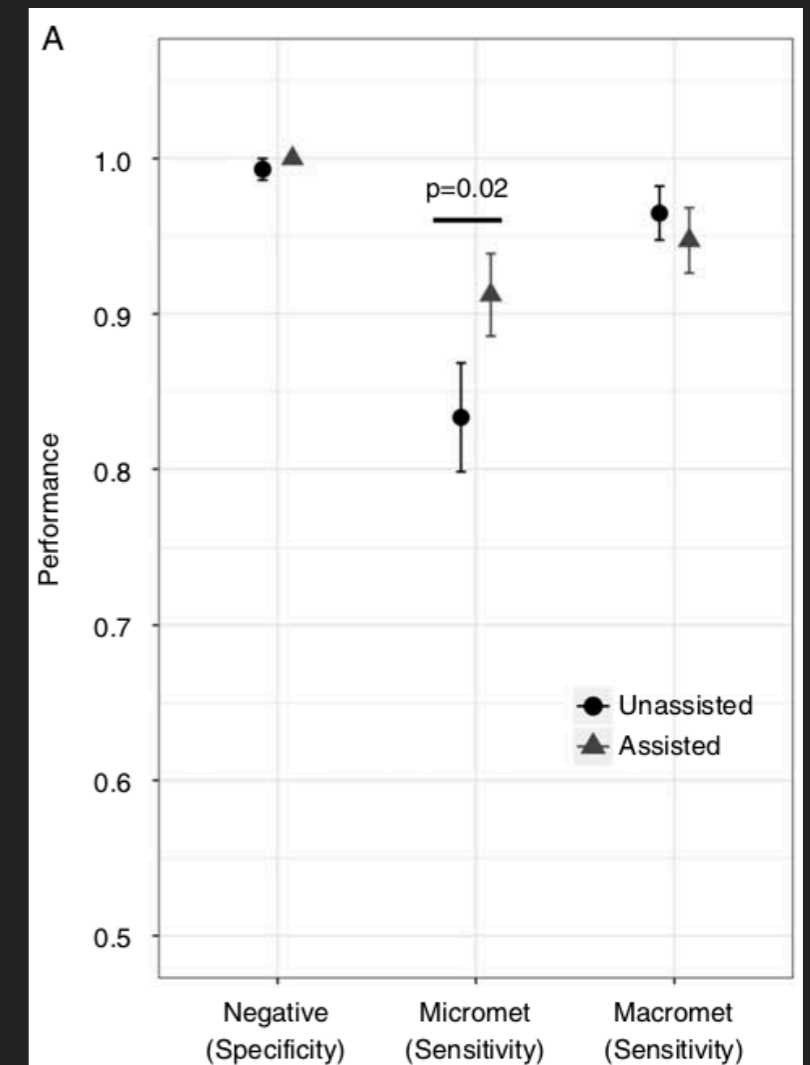
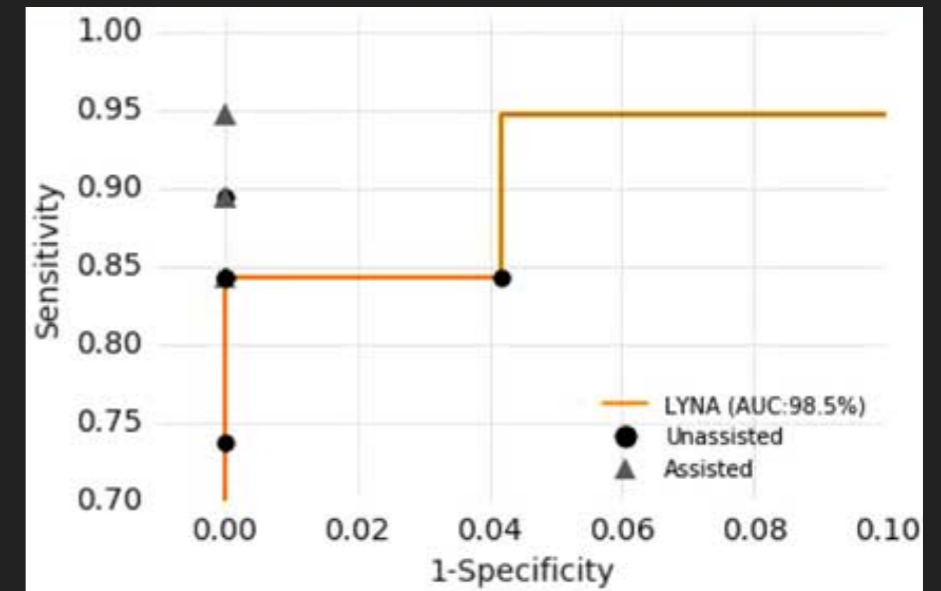


Jeffrey De Fauw¹, Joseph R. Ledsam¹, Bernardino Romera-Paredes¹, Stanislav Nikolov¹, Nenad Tomasev¹, Sam Blackwell¹, Harry Askham¹, Xavier Glorot¹, Brendan O'Donoghue¹, Daniel Visentin¹, George van den Driessche¹, Balaji Lakshminarayanan¹, Clemens Meyer¹, Faith Mackinder¹, Simon Bouton¹, Kareem Ayoub¹, Reena Chopra^{1,2}, Dominic King¹, Alan Karthikesalingam¹, Cian O. Hughes^{1,3}, Rosalind Raine³, Julian Hughes², Dawn A. Sim², Catherine Egan², Adnan Tufail², Hugh Montgomery^{1,3}, Demis Hassabis¹, Geraint Rees^{1,3}, Trevor Back¹, Peng T. Khaw², Mustafa Suleyman¹, Julien Cornebise^{1,3,4}, Pearse A. Keane^{1,4*} and Olaf Ronneberger^{1,4*}

The volume and complexity of diagnostic imaging is increasing at a pace faster than the availability of human expertise to interpret it. Artificial intelligence has shown great promise in classifying two-dimensional photographs of some common diseases and typically relies on databases of millions of annotated images. Until now, the challenge of reaching the performance of expert clinicians in a real-world clinical pathway with three-dimensional diagnostic scans has remained unsolved. Here, we apply a novel deep learning architecture to a clinically heterogeneous set of three-dimensional optical coherence tomography scans from patients referred to a major eye hospital. We demonstrate performance in making a referral recommendation that reaches or exceeds that of experts on a range of sight-threatening retinal diseases after training on only 14,884 scans. Moreover, we demonstrate that the tissue segmentations produced by our architecture act as a device-independent representation; referral accuracy is maintained when using tissue segmentations from a different type of device. Our work removes previous barriers to wider clinical use without prohibitive training data requirements across multiple pathologies in a real-world setting.

Medical imaging is expanding globally at an unprecedented rate^{1,2}, leading to an ever-expanding quantity of data that requires human expertise and judgement to interpret and OCT has shown promise in resolving some of these criteria in isolation, but has not yet shown clinical applicability by resolving all three.



CNN A KÉPALKOTÓ DIAGNOSZTIKÁBAN

- ▶ Mellrák nyirokcsomó szövettan áttét keresés: Kép klasszifikáció, detekció (Litjens et al., Steiner et al.)



CNN A KÉPALKOTÓ DIAGNOSZTIKÁBAN

► Alzheimer PET-CT alapján (Ding et al.)



Radiology

ORIGINAL RESEARCH • NEUR

A Deep Learning Model to Predict a Diagnosis of Alzheimer Disease by Using ^{18}F -FDG PET of the Brain

Yiming Ding • Jae Ho Sohn, MD, MS • Michael G. Kawczynski, MS • Hari Trivedi, MD • Roy Harnish, MS • Nathaniel W. Jenkins, MS • Dmytro Litniew, PhD • Timothy P. Copeland, MPP • Mariani S. Aboian, MD, PhD • Carina Mari Aparici, MD • Spencer C. Behr, MD • Robert R. Flavell, MD, PhD • Shib-Ying Huang, PhD • Kelly A. Zalocusky, PhD • Lorenzo Nardo, PhD • Youngho Seo, PhD • Randall A. Hawkins, MD, PhD • Miguel Hernández Pampaloni, MD, PhD • Dexter Hadley, MD, PhD • Benjamin L. Franc, MD, MS

From the Department of Radiology and Biomedical Imaging (Y.D., J.H.S., H.T., R.H., N.W.J., T.P.C., M.S.A., C.M.A., S.C.B., R.R.F., S.Y.H., Y.S., R.A.H., M.H.P., B.L.F.) and Institute for Computational Health Sciences (J.H.S., M.G.K., H.T., D.L., K.A.Z., D.H.), University of California, San Francisco, 550 Parnassus Ave, San Francisco, CA 94143; Department of Electrical Engineering and Computer Sciences, University of California, Berkeley, Berkeley, Calif (Y.D.); and Department of Radiology, University of California, Davis, Sacramento, Calif (L.N.). From the 2017 RSNA Annual Meeting. Received April 23, 2018; revision requested July 3; final revision received August 24; accepted September 13. Address correspondence to J.H.S. (e-mail: sohn87@gmail.com).

H.T. supported by Foundation for the National Institutes of Health fellowship (5T32EB001631-10). Data collection and sharing for this project was funded by the Alzheimer's Disease Neuroimaging Initiative (ADNI), National Institutes of Health (U01 AG024904) and U.S. Department of Defense (W81XWH-12-2-0012). J.H.S. supported by University of California, San Francisco (CTSI Resident Research Grant 2017, Radiology & Biomedical Imaging Seed Grant #17-11). ADNI data are disseminated by the Laboratory for Neuro Imaging at the University of Southern California. Data used in the preparation of this article were obtained from the ADNI database (adni.loni.usc.edu). As such, the investigators within the ADNI contributed to the design and implementation of ADNI and/or provided data but did not participate in analysis or writing of this report.

Conflicts of interest are listed at the end of this article.

See also the editorial by Larvie in this issue.

Radiology 2018; 00:1-9 • <https://doi.org/10.1148/radiol.2018180958> • Content code: NR

Purpose: To develop and validate a deep learning algorithm that predicts the final diagnosis of Alzheimer disease (AD), mild cognitive impairment, or neither at fluorine 18 (^{18}F) fluorodeoxyglucose (FDG) PET of the brain and compare its performance to that of radiologic readers.

Materials and Methods: Prospective ^{18}F -FDG PET brain images from the Alzheimer's Disease Neuroimaging Initiative (ADNI) (2109 imaging studies from 2005 to 2017, 1002 patients) and retrospective independent test set (40 imaging studies from 2006 to 2016, 40 patients) were collected. Final clinical diagnosis at follow-up was recorded. Convolutional neural network of InceptionV3 architecture was trained on 90% of ADNI data set and tested on the remaining 10%, as well as the independent test set, with performance compared to radiologic readers. Model was analyzed with sensitivity, specificity, receiver operating characteristic (ROC), saliency map, and t -distributed stochastic neighbor embedding.

Results: The algorithm achieved area under the ROC curve of 0.98 (95% confidence interval: 0.94, 1.00) when evaluated on predicting the final clinical diagnosis of AD in the independent test set (82% specificity at 100% sensitivity), an average of 75.8 months prior to the final diagnosis, which in ROC space outperformed reader performance (57% [four of seven] sensitivity, 91% [30 of 33] specificity; $P < .05$). Saliency map demonstrated attention to known areas of interest but with focus on the entire brain.

Conclusion: By using fluorine 18 fluorodeoxyglucose PET of the brain, a deep learning algorithm developed for early prediction of Alzheimer disease achieved 82% specificity at 100% sensitivity, an average of 75.8 months prior to the final diagnosis.

© RSNA, 2018



Online supplemental material is available for this article.

MESTERSÉGES NEURÁLIS HÁLÓK A KÉPALKOTÓ DIAGNOSZTIKÁBAN

https://www.synapse.org/Digital_Mammography_DREAM_challenge




CNN A MAMMOGRÁFIÁBAN

- ▶ Mammográfiai verseny: kép klasszifikáció
- ▶ Szerintem: objektum detekció!
- ▶ 2. hely, 1000+ résztvevőből, végül a legpontosabb módszer jelenleg (AUC = 0.928)






CNN A MAMMOGRÁFIÁBAN

- ▶ Mammográfiai verseny: kép klasszifikáció
- ▶ Szerintem: objektum detekció!
- ▶ 2. hely, 1000+ résztvevőből, végül a legpontosabb módszer jelenleg (AUC = 0.928)



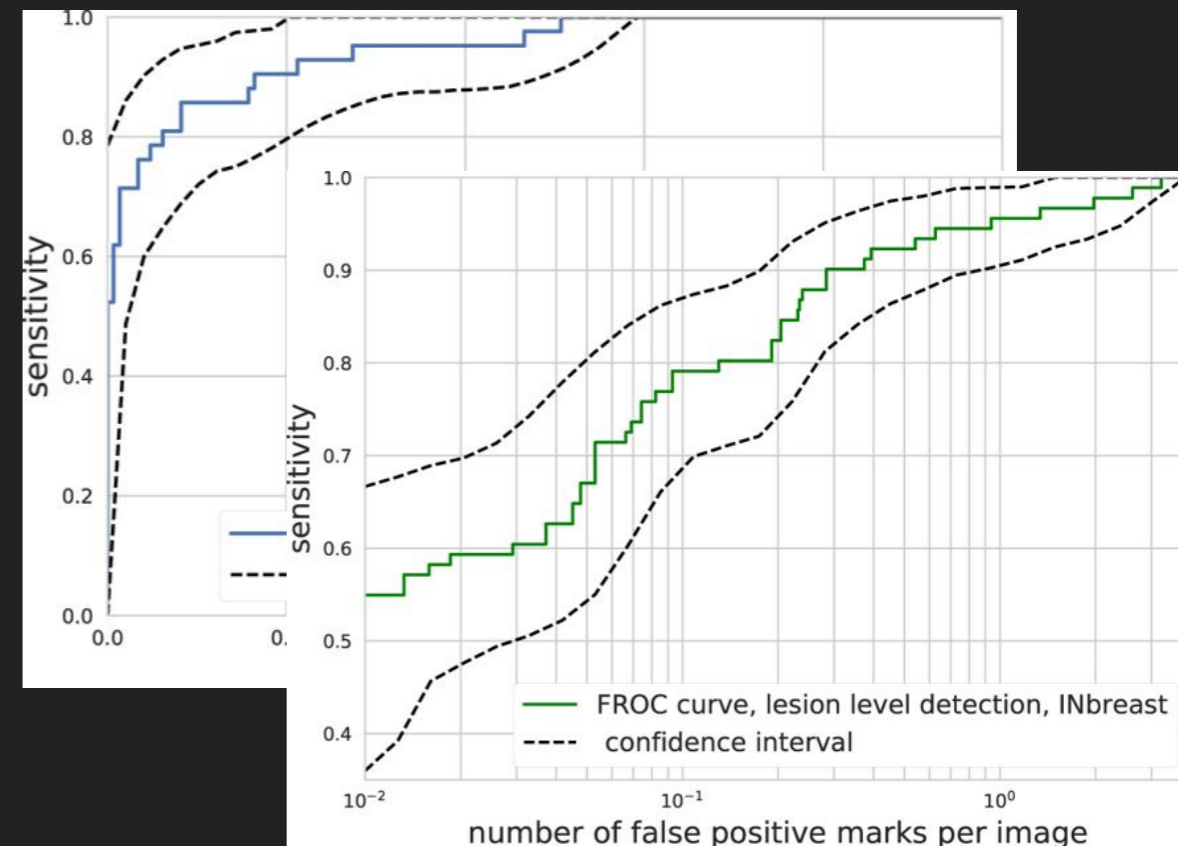


CNN A MAMMOGRÁFIÁBAN

- ▶ Mammográfiai verseny: kép klasszifikáció
- ▶ Szerintem: objektum detekció!
- ▶ 2. hely, 1000+ résztvevőből, végül a legpontosabb módszer jelenleg (AUC = 0.928)



CNN A MAMMOGRÁFIÁBAN

- ▶ Ribli, D., Horváth, A., Unger, Z., Pollner, P., & Csabai, I. (2018). Detecting and classifying lesions in mammograms with Deep Learning. Scientific reports, 8(1), 4165.




MESTERSÉGES NEURÁLIS HÁLÓK A KÉPALKOTÓ DIAGNOSZTIKÁBAN

CNN A MAMMOGRÁFIÁBAN

► [open source](#)

► Demo OsiriX/Horos plugin



ribidezso / frcnn_cad

Computer aided detection using Faster-RCNN

29 commits 1 branch 0 releases 1 contributor

Branch: master New pull request Create new file Upload files Find file Clone or download

ribidezso Update README.md Latest commit 7ff9c6b 2 days ago

| File | Update | Time |
|-------------------------------|-------------------|-------------|
| data | Update README.md | 6 days ago |
| results | Update README.md | 6 days ago |
| README.md | Update README.md | 2 days ago |
| demo.ipynb | demo notebook | 18 days ago |
| vgg16_frcnn_cad_test_prototxt | uploaded prototxt | 18 days ago |

Computer aided detection with Faster-RCNN

A VGG16 based Faster-RCNN detector trained to detect breast cancer lesions on mammogram images.

For more details and results please see the article on arXiv: <https://arxiv.org/abs/1707.08401>

Model weights

Model weights can be downloaded from here, the models is licensed with Creative Commons Attribution + Noncommercial + ShareAlike license [License CC BY-NC-SA 4.0](#)

- http://dkrib.web.elte.hu/cad_faster_rcnn/vgg16_frcnn_cad.caffemodel

OsiriX/Horos plugin

I wrote a plugin for the popular medical image viewer: OsiriX/Horos. This is a simplified version of the model. It is based on [CoreML](#). In order to run it you will need:

- A mac
- High Sierra (10.13) operating system (because of CoreML)
- Horos (free) or OsiriX medical image viewer.

Installation: Download the plugin, unzip it, click on the installer, and approve it. Restart OsiriX/Horos. The plugin will appear in the menu of OsiriX/Horos: Plugins/Image Filters/CnnCAD. You can also add it to the toolbar of the 2D viewer.

Usage: Open the images in the 2D viewer and click on the menu item: Plugins/Image Filters/CnnCAD. A pop-up will appear

```
#!/usr/bin/env python
# -*- coding: utf-8 -*-
# You need to install py-faster-rcnn, see the github repository for instructions:
# https://github.com/rbgirshick/py-faster-rcnn
# You need a GPU with at least 8GB memory, with CUDA and cuDNN

import modules and change Faster-RCNN configs

import sys
# Note: do not use py-faster-rcnn installation
sys.path.append('root/py-faster-rcnn/tools')
import caffe_model_zoo
import sys
from fast_rcnn_test_net import fast_rcnn_test_net
from fast_rcnn_test_net import fast_rcnn_test_net
import caffe

# Faster RCNN config we need to change
cfg.TEST_MAX_SIZE = True # use GPU for proposals
cfg.TEST_MAX_SIZE = True # change max size
cfg.TEST_MAX_SIZE = True # change max size
import sys

Populating the interactive namespace from numpy and matplotlib

Define functions to load model, run detection, and visualize detection

def load_net(path, w, device=0):
    """Load model"""
    caffe.set_mode_gpu()
    caffe.set_device(device)
    net = caffe.Net(path, w, caffe.TEST)
    return net


def detect(net, im, CONF_THRESH = 0.1, nms_thresh = 0.3):
    """Detect objects"""
    CLASSES = ['background', 'tumor', 'macrocalc']
    cfg.TEST_MAX_SIZE = True
    scores, boxes = net.detect(im, cls_prob_threshold=CONF_THRESH,
                              nms_thresh=nms_thresh)
    cls_inds = np.where(scores > 0)
    cls_scores = scores[cls_inds, cls_inds]
    boxes = np.hstack([cls_inds, boxes])
    keep = np.where(scores[cls_inds, cls_inds] > CONF_THRESH)
    boxes = boxes[keep, :]
    return boxes

def viz_detect(net, im, CONF_THRESH = 0.3):
    """Draw boxes around detected 'tumor'"""
    fig, ax = plt.subplots(1, 1)
    ax.imshow(im, cmap='gray')
    inds = np.where(scores > CONF_THRESH)
    for i in inds:
        score = scores[i, i]
        box = boxes[i, :]
        plt.plot(box[0], box[1], box[2], box[3],
                color='r', linewidth=2)
    plt.axis('off')
    plt.show()
```

```
#!/usr/bin/env python
# Load the model weights here
net = load_net(path='vgg16_frcnn_cad_test_prototxt',
              w='vgg16_frcnn_cad.caffemodel')
```

Load and analyze image

```
in: 4: # Load image, visualize this part to load your image
im = cv.imread('demo.jpg')
# Run detection
detection = detect(net, im)
# Visualize detections
viz_detect(net, detection, im)
```



ÖSSZEFOGLALÓ A NEURÁLIS HALÓ ALAPÚ KÉPFELISMERÉS HELYZETÉRŐL A KÉPALKOTÓ DIAGNOSZTIKÁBAN

- ▶ Több különböző területen megközelítette vagy elérte szakorvosok kép osztályozó (diagnosztizáló) pontosságát, ezeknek a területeknek a száma csak növekedni fog
- ▶ Még több adattal tovább fog nőni a pontossága
- ▶ Szűk, jól definiált feladatokat tud megoldani
- ▶ Nagy volumenű szűrővizsgálatokban lesz a leghasznosabb
- ▶ Monoton, fárasztó, koncentrációt igénylő, nem embernek való feladatokban segítheti az embert és lassan tehermentesítheti. Az emberek az embernek való feladatokkal tudnak foglalkozni. (Számológép van, matematikusok is vannak.)



ÖSSZEFOGLALÓ A NEURÁLIS HALÓ ALAPÚ KÉPFELISMERÉS HELYZETÉRŐL A KÉPALKOTÓ DIAGNOSZTIKÁBAN

- ▶ Több különböző területen megközelítette vagy elérte szakorvosok kép osztályozó (diagnosztizáló) pontosságát, ezeknek a területeknek a száma csak növekedni fog
- ▶ Még több adattal tovább fog nőni a pontossága
- ▶ Szűk, jól definiált feladatokat tud megoldani
- ▶ Nagy volumenű szűrővizsgálatokban lesz a leghasznosabb
- ▶ Monoton, fárasztó, koncentrációt igénylő, nem embernek való feladatokban segítheti az embert és lassan tehermentesítheti. Az emberek az embernek való feladatokkal tudnak foglalkozni. (Számológép van, matematikusok is vannak.)
- ▶ Az orvos feladata nem (csak) kép klasszifikáció. A CNN nem mesterséges intelligencia, hanem mesterséges (vizuális) percepció.
- ▶ A betegellátás komplex folyamatában nem helyettesítheti az orvost.



KÉRDÉSEK!

KÖSZÖNÖM A FIGYELMET!

HIVATKOZÁSOK

- ▶ Lee, H., Grosse, R., Ranganath, R., Ng, A.Y., 2009. Convolutional deep belief networks for scalable unsupervised learning of hierarchical representations, in: Proceedings of the 26th Annual International Conference on Machine Learning - ICML '09. Presented at the the 26th Annual International Conference, ACM Press, Montreal, Quebec, Canada, pp. 1-8. <https://doi.org/10.1145/1553374.1553453>
- ▶ Goodfellow I, Bengio Y, Courville A, Bengio Y. Deep learning. Cambridge: MIT press; 2016 Nov 18.
- ▶ Fukushima, K., 1980. Neocognitron: A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position. *Biological Cybernetics* 36, 193-202. <https://doi.org/10.1007/BF00344251>
- ▶ Dean, J., Corrado, G., Monga, R., Chen, K., Devin, M., Mao, M., Ranzato, M., Senior, A., Tucker, P., Yang, K., Le, Q.V., Ng, A.Y., n.d. Large Scale Distributed Deep Networks 9.
- ▶ Deng, J., Dong, W., Socher, R., Li, L.-J., Li, K., Fei-Fei, L., n.d. ImageNet: A Large-Scale Hierarchical Image Database 8.
- ▶ Russakovsky, O., Deng, J., Su, H., Krause, J., Satheesh, S., Ma, S., Huang, Z., Karpathy, A., Khosla, A., Bernstein, M., Berg, A.C., Fei-Fei, L., 2015. ImageNet Large Scale Visual Recognition Challenge. *International Journal of Computer Vision* 115, 211-252. <https://doi.org/10.1007/s11263-015-0816-y>
- ▶ Szegedy, C., Zaremba, W., Sutskever, I., Bruna, J., Erhan, D., Goodfellow, I., Fergus, R., 2013. Intriguing properties of neural networks. arXiv:1312.6199 [cs].
- ▶ Goodfellow, I.J., Shlens, J., Szegedy, C., 2014. Explaining and Harnessing Adversarial Examples. arXiv:1412.6572 [cs, stat].
- ▶ Eykholt, K., Evtimov, I., Fernandes, E., Li, B., Rahmati, A., Xiao, C., Prakash, A., Kohno, T., Song, D., 2017. Robust Physical-World Attacks on Deep Learning Models. arXiv:1707.08945 [cs].

HIVATKOZÁSOK

- ▶ Esteva, A., Kuprel, B., Novoa, R.A., Ko, J., Swetter, S.M., Blau, H.M., Thrun, S., 2017. Dermatologist-level classification of skin cancer with deep neural networks. *Nature* 542, 115-118. <https://doi.org/10.1038/nature21056>
- ▶ De Fauw, J., Ledsam, J.R., Romera-Paredes, B., Nikolov, S., Tomasev, N., Blackwell, S., Askham, H., Glorot, X., O'Donoghue, B., Visentin, D., van den Driessche, G., Lakshminarayanan, B., Meyer, C., Mackinder, F., Bouton, S., Ayoub, K., Chopra, R., King, D., Karthikesalingam, A., Hughes, C.O., Raine, R., Hughes, J., Sim, D.A., Egan, C., Tufail, A., Montgomery, H., Hassabis, D., Rees, G., Back, T., Khaw, P.T., Suleyman, M., Cornebise, J., Keane, P.A., Ronneberger, O., 2018. Clinically applicable deep learning for diagnosis and referral in retinal disease. *Nature Medicine* 24, 1342-1350. <https://doi.org/10.1038/s41591-018-0107-6>
- ▶ Litjens, G., Sánchez, C.I., Timofeeva, N., Hermsen, M., Nagtegaal, I., Kovacs, I., Hulsbergen - van de Kaa, C., Bult, P., van Ginneken, B., van der Laak, J., 2016. Deep learning as a tool for increased accuracy and efficiency of histopathological diagnosis. *Scientific Reports* 6. <https://doi.org/10.1038/srep26286>
- ▶ Steiner, D.F., MacDonald, R., Liu, Y., Truskowski, P., Hipp, J.D., Gammage, C., Thng, F., Peng, L., Stumpe, M.C., 2018. Impact of Deep Learning Assistance on the Histopathologic Review of Lymph Nodes for Metastatic Breast Cancer. *Am J Surg Pathol* 00, 11.
- ▶ Ribli, D., Horváth, A., Unger, Z., Pollner, P., Csabai, I., 2018. Detecting and classifying lesions in mammograms with Deep Learning. *Scientific Reports* 8. <https://doi.org/10.1038/s41598-018-22437-z>

HOZZUK ÖSSZE AZ ORVOSI ÉS KÉPFELISMERÉSI TUDÁST!

[HTTP://CSABAIBIO.ELTE.HU](http://csabaibio.elte.hu)

CSABAI@COMPLEX.ELTE.HU

DKRIB@CAESAR.ELTE.HU

POLLNER@ANGEL.ELTE.HU

**ORVOSI KÉPALKOTÓ DIAGNOSZTIKAI
PROJEKTET-BEN SZÍVESEN
EGYÜTTMŰKÖDÜNK!**