


Tüdőrák diagnosztikai mesterséges intelligencia mellkas CT felvétel alapján





Radványi Mihály

AI kutató



Traditional methods



$$y = \text{sign} \left(\sum_{i=1}^N W_i F_i(X) + b \right)$$

Article | [Open Access](#) | Published: 21 March 2019

Effective and Reliable Framework for Lung Nodules Detection from CT Scan Images

Sajid Ali Khan, Shariq Hussain, Shunkun Yang & Khalid Iqbal


Scientific Reports 9, Article number: 4989 (2019) | [Cite this article](#)

6935 Accesses | 5 Citations | 1 Altmetric | [Metrics](#)



Abstract

Lung cancer is considered more serious among other prevailing cancer types. One of the reasons for it is that it is usually not diagnosed until it has spread and by that time it becomes


Feature learning




Convolutional Neural Networks




Stride 1 with Padding




Feature Map



Classification:



























Segmentation:




A mostly complete chart of Neural Networks

©2019 Fjodor van Veen & Stefan Leijnen asimovinstitute.org

- Input Cell
- Backfed Input Cell
- △ Noisy Input Cell
- Hidden Cell
- Probabilistic Hidden Cell
- △ Spiking Hidden Cell
- Capsule Cell
- Output Cell
- Match Input Output Cell
- Recurrent Cell
- Memory Cell
- △ Gated Memory Cell
- Kernel
- Convolution or Pool



Feladattípusok



The diagram illustrates the UNet architecture, showing the flow of data from input image tiles to output segmentation maps. The architecture is divided into three main sections: **What** (left), **Where** (middle), and **UNet** (bottom).


What: This section shows the input image tiles. The input is a 512 x 512 tile, which is processed into a 512 x 512 feature map. This is followed by a series of convolutional layers (conv 3x3, ReLU) and max pooling (max pool 2x2) operations, resulting in a 256 x 256 feature map.

Where: This section shows the output segmentation maps. The output is a 256 x 256 segmentation map, which is processed into a 256 x 256 feature map. This is followed by a series of convolutional layers (conv 3x3, ReLU) and max pooling (max pool 2x2) operations, resulting in a 128 x 128 feature map.


UNet: This section shows the UNet architecture, which is a U-shaped network. The input image tiles are processed by the **What** section, and the output segmentation maps are processed by the **Where** section. The UNet architecture consists of a series of convolutional layers (conv 3x3, ReLU) and max pooling (max pool 2x2) operations, followed by a series of up-convolutional layers (up-conv 2x2) and skip connections. The output of the UNet is a 256 x 256 segmentation map.

Legend:


- conv 3x3, ReLU
- copy and crop
- max pool 2x2
- up-conv 2x2
- conv 1x1



TransUnet




CenterNet




Mask R-CNN

2D vs. 3D

48, 64, 96




Patch méretek



Összetett koncepciók - Ensemble

Összemérhetőség - Adat, Architektúra, Publikált eredmények




NoduleNet

NoduleNet – Luna16 – 4.fold


Architektúrák kiértékelése: SE-ULY model vs. NoduleNet

Publikus tanítóadaton – LUNA 16



Mean	0.527	0.460
Std	0.139	0.244
Max	0.770	0.873


SE-ULY TDR 50 elemén DSC alapján kiértékelve. A kiválasztott 50 CT-vel egyik háló sem találkozott a tanítás során.



	SE-ULY TDR	NoduleNet
TP	71	69
FP	227	654
FN	8	10

Nodulusok kiértékelése


Saját adatok - SE




Előválogatott felvételek száma

Több, mint 20 ezer felvétel előválogatása

Előválogatott felvételek száma havonta





Előválogatott felvételek számának növekedése




Saját adathalmaz


- Több, mint 8000 db
 - Válogatott
 - Szegmentált
 - Validált
 - Pozitív felvétel
- Ebből 7300 db került a tanító halmazba
- Maradékból teszt adat + köztes kiértékelés
- Iteratív kiértékelés és tanítás




Tanítóadat folyamatos javítása - Iteratív tanítás



Iteratív tanítás – predikciók elemzése




	A	B	
	Szegmentáció fájlneve	Kiértékelés	Nodusus
1			
2	PREDPOS_006_SEOKK2.2_Kontraszt_43.nii.gz	Negatív	43
3	PREDPOS_001_SEOKK2.2_Kontraszt_57.nii.gz	Negatív	57
4	PREDPOS_003_SEOKK2.2_Kontraszt_67.nii.gz	Pozitív	67
5	PREDPOS_002_SEOKK2.2_Kontraszt_68.nii.gz	Követendő	68
6	TRUEPOS_005_SEOKK2.2_Kontraszt_85.nii.gz		85
7	PREDPOS_004_SEOKK2.2_Kontraszt_86.nii.gz	Követendő	86
8			
9			




Típushibák azonosítása


- Meszes területek



- Gyulladásból visszamaradt




Helyes predikciók




Iteratív tanítás hatása

48-96 union modell on all SEOKK dataset




Predikciók elemzése előtt




Predikciók elemzése után

Tanítási adatok - paraméterek




Tüdő szegmentálása

NODULUST TARTALMAZÓ PATCHEK




NODULUST **NEM** TARTALMAZÓ PATCHEK



Tetszés szerint állítható tanító paraméterek*	Általában használt értékek
Egy felvételtől hány patchet vágunk	30
Hány CT patcheit keverjük össze a tanítás előtt	10
A patchek milyen arányban legyenek pozitívok/negatívok	7:3
Patchek mérete	[64,64,64]
Egy patchnek minimum mekkora részét foglalja el nódulus ahhoz, hogy azt pozitívnak osztályozzuk	10%**
Egy patchre maximum hány nodulust prediktálhatunk	10
Milyen predikciót engedünk tovább	>0.85 score <10 pixel outline >0.45 prediktált maszk érték

*Ezen kívül is rengeteg konfigurációban állítható paraméter van, ezek csak a legtriviálisabbak
** az is elég ha egy vagy több teljes nódulus rajta van, amennyiben nem éri el a 10%-ot


Eredmények – 3D Attention Unet -ek




$$\text{Sensitivity} = \frac{TP}{GT \text{ nodule count}}$$

$$\text{Positive Predictive Value} = \frac{TP}{TP + FP}$$

3D Mask R-CNN




Mask R-CNN predikció




Nagy nodulusok

Volume $\geq 10'000\text{vx}$





° Radiológusi szegmentáció

° 48-96 Predikció



DeepCAC - kitérő



Heart localization: 3D Unet

- 112 x 112 x 112 px

Resize
Crop
Resize


Heart segmentation: 3D Unet

- 128 x 128 x 80 px


Resize
Cut cubes

CAC segmentation: 3D Unet

- 48 x 48 x 32 px



DeepCAC – transfer learning







Heart localization: 3D Unet

- 112 x 112 x 112 px
- Training data: 1636 CT, 1200 epoch



Transfer Learning





- Large nodules $\geq 10'000$ vx
 - Train data: 285 SE CT
 - Epoch: 54 epoch



DeepCAC – transfer learning

Test data: 58 SE CT

Proof-of-Concept



Speciális módszerek és stratégiák



Alkalmazott technológia / architektúra	Összefoglaló	Eredmények
CenterNet	Pixelenkénti szegmentáció helyett a nodulus sarokpontjait és középpontját detektáló hálózat típusok	Szenzitivitás: 82 % -> 85 %, SE halmazon: 91% PPV: 20 % -> 7 %
Fals pozitív szűrő háló	Másodrendű hálózat, ami az elsődleges háló predikcióra hoz bináris döntést: valóban nodulus van-e az adott patch-en	Fals pozitív predikciók: 80 % -t kiszűri Valós pozitív predikciók: 3 % -t kiszűri PPV: 15 %
Quantitative Texture Analysis (QTA)	Fals pozitív szűrő módszer, ami a CT felvétel fizikai paramétereit és struktúráját tömöríti speciális feature vektorra a nodulusok környékén. Az így kapott leírók osztályzásával lehetőség nyílik fals pozitív találatok szűrésére	Szenzitivitás: 82 % -> 41 % PPV: 21 % -> 62 %
QTA alapú CenterNet U-Net hibrid	Egy QTA alapú Centernet és egy UNet párosítása	Szenzitivitás: (61 % , 81 %)-> 85 % PPV (4 %, 21 %)-> 6%
Anomália detekció QTA alapon	Rendellenes, hibás felvételek szűrése, a tanító és teszhalmazok automatikus tisztítása	Szenzitivitás: 82 % - 82.6 % PPV: 21 % -> 30 %
Orientációs U-Net	A noduluskörnyéki, lokális érzetminták numerizálása és tanítóadathoz fűzése. A módszer segít megkülönböztetni a nodulusokat az ércsomóktól, ezzel javítja a modell szenzitivitását	Szenzitivitás: 82 % -> 84 % PPV: 21 % -> 17%
Adatfeldolgozás finomhangolása	A tanítóadat szerkezetének, összetételének változtatása és annak hatásai	Szenzitivitás – ppv görbe létrejötte
Iteratív tanítás eredményinek felhasználása	Az összes predikció kiértékelése és validálása, ami lehetőséget ad a tanítóhalmaz pontosítására.	Unet64 szenzitivitás: 88.7% -> 91.5% PPV 12% -> 17.6% 48-96 szenzitivitás: 94.5%- > 95.7% PPV 7% -> 10%

Eredmények

Teszt


100 pozitív
100 negatív

	Páciens szintű metrikák								Nodulus szintű metrikák		
model	Szenzitivitás	Specifititás	PPV	NPV	TN	FN	TP	FP	Szenzitivitás	PPV	Mean Dice
SE-ULY-model1	0.99	0.81	0.839	0.988	81	1	99	19	0.675	0.633	0.774
SE-ULY-model2	1.00	0.79	0.826	1.000	79	0	100	21	0.660	0.406	0.750
ensemble (model1 + model2)	0.96	0.92	0.923	0.958	92	4	96	8	0.585	0.780	0.836




Szenzitivitás = $TP / (TP + FN)$
 Specifititás = $TN / (FP + TN)$
 PPV = $TP / (TP + FP)$
 NPV = $TN / (TN + FN)$


Predikció érzékenységének hangolása – nodulus szinten



Predikció érzékenységének hangolása – páciens szinten





Radiológusi döntés / diagnózis támogatása





Predikciók priorizálása

Azonosító	Térfogat (mm ³) (max)	Valószínűség (max)	Nodulusok száma	Dátum	Predikciós riport
ULY_001810	13619	1	3	2022.09.19 9:07	ULY_001810 prediction report.pdf
ULY_001775	61262	0,899	4	2022.09.19 8:29	ULY_001775 prediction report.pdf
ULY_001882	164846	0,897	8	2022.09.19 10:22	ULY_001882 prediction report.pdf
ULY_001869	107479	0,863	4	2022.09.19 9:50	ULY_001869 prediction report.pdf
ULY_001790	424	0,854	2	2022.09.19 8:48	ULY_001790 prediction report.pdf
NEG_000170	52	0,846	1	2022.09.19 4:53	NEG_000170 prediction report.pdf
NEG_000124	2294	0,835	2	2022.09.19 0:39	NEG_000124 prediction report.pdf
ULY_001880	4549	0,823	7	2022.09.19 10:15	ULY_001880 prediction report.pdf
NEG_000109	297	0,805	4	2022.09.18 23:18	NEG_000109 prediction report.pdf
NEG_000108	198	0,801	1	2022.09.18 23:12	NEG_000108 prediction report.pdf
NEG_000165	1583	0,782	1	2022.09.19 4:27	NEG_000165 prediction report.pdf
NEG_000182	3203	0,745	1	2022.09.19 6:00	NEG_000182 prediction report.pdf
NEG_000121	92	0,686	1	2022.09.19 0:23	NEG_000121 prediction report.pdf
NEG_000151	2301	0,608	1	2022.09.19 3:10	NEG_000151 prediction report.pdf
NEG_000176	0	0,47	0	2022.09.19 5:26	NEG_000176 prediction report.pdf
NEG_000186	0	0,374	0	2022.09.19 6:21	NEG_000186 prediction report.pdf
NEG_000101	0	0,373	0	2022.09.18 22:36	NEG_000101 prediction report.pdf
NEG_000115	0	0,243	0	2022.09.18 23:49	NEG_000115 prediction report.pdf
NEG_000131	0	0,124	0	2022.09.19 1:20	NEG_000131 prediction report.pdf
NEG_000136	0	0,124	0	2022.09.19 1:46	NEG_000136 prediction report.pdf

Predikciós riport - Lelet




3D-s szegmentáció




Tüdőrák diagnosztika mesterséges intelligenciával


Cél: automatikus nodulus detekció



Eredmény: diagnosztikai szolgáltató



Eszköz: iteratív kutatás és tanítás



A jelen és a folytatás

- Klinikai validáció folyamatban
 - Országos Korányi Pulmonológiai Intézetben
 - HUNCHEST felvételein és eredményein
 - Közel 2000 felvételen
- ISO 13485 (Medical Device) tanúsítvány és CE minősítés folyamatban
- Cél: országos szűrőprogramban alkalmazhatóság
- További kutatási lehetőség
 - Mellkasi CT felvételeken egyéb szűrővizsgálatok (pl. kardiovaszkuláris betegségek)