

0110

0100

1001

0101

1001

0101

0110

0100

1001

1001

1011

0100

0100

1011

0100

0100

1001

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

0100

Számítógépes látás felhasználása az orvostudományban: Diagnosztikát segítő algoritmusok

dr. Juhász Dávid Imre

Emlékeztető: konvolúció

- A képi információ egy másfajta értelmezése, mely az eredeti képen meglévő, de nem észrevehető változások, segítségével a képet képes egészében értelmezni.
- Leggyakrabban követ egy aktivációs függvény, legtöbbször ReLu réteg, majd egy gyűjtő, ún. poolozó réteg.

Konvolúció

- Matematikailag ez a konvolúciós réteg, vagy Kernel-réteg egy „szűrő”, amely végigpásztázza a számsorként értelmezett képet, úgy hogy, az adott helyeken a súly ugyanaz marad
- Képes élek detektálására, még nem látható élekére is.
- Eredetitől eltérő kép keletkezése

Orvosdiagnosztikai AI aktualitása

- A világon több helyen
 - Stanford Egyetem, University of Iowa,
 - Szingapúr, Japán
 - Kína!
- Magyarország:
 - SOTE Városmajori Klinika – BME
 - SOTE Bőrklinika – PPKE ITK
 - SOTE Radiológiai Klinika – MTA SZTAKI?

Az orvos, mint „neurális hálózat”

- Bemenet:
 - Több ezer elolvasott oldal, csak az első két évben
 - Kb. ezer tankönyvi kép
 - Több száz beteg, mint eset, melyből az ember következtet
- Kimenet: diagnózis+terápia, beteg utánkövetési terv

Differenciáldiagnosztika

- Bőrgyógyászat: kután limfómák bőrtünetei
- Radiológia: Tüdőrák diagnosztika, mammográfia
- Háziorvoslás: pöttyös, köhögő, fejfájós gyermek

Mi kell egy jó orvosi diagnosztikai AI-hoz?

- Sok adat, a megfelelő tanulóhalmazhoz
- Egységesen, ugyanolyan, vagy nagyon hasonló módon készített felvételek: Rtg, MRI, mammográfia,
- Felvételek megfelelő szegmentálása, kiértékelése, esetleges megfelelő dokumentáció, a tanításhoz

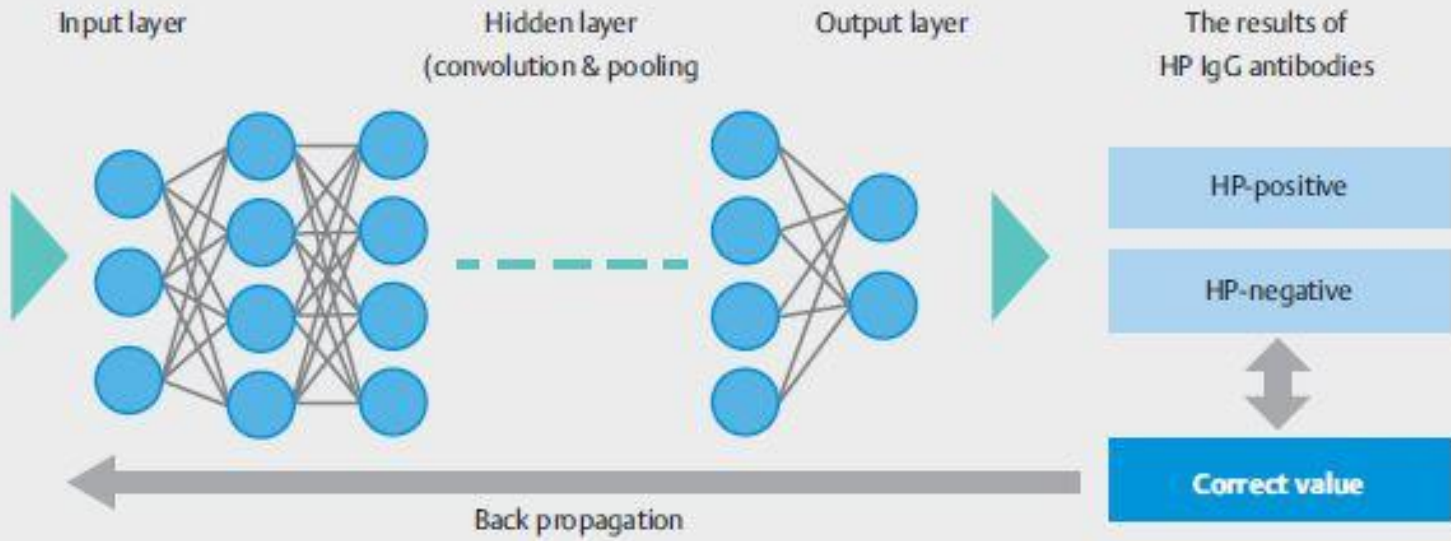
Számítógépes látás felhasználása


- Gastroszkópia:H. Pylori infekció diagnosztizálása
- Csonttörések diagnosztikája
- Myokardiális infarctus diagnosztizálása
- Aritmia diagnosztikája
- Tüdőrák diagnosztika
- Sebklasszifikáció- és 3D elemzés
- Hisztopatológiai diagnosztika

H. Pylori infekció diagnosztikája¹

- Viszonylag új áttörés: 2017.09.
- Képes gasztroszkópos felvételi fényképek elemzéséből megadni: H.P. pozitív, vagy negatív-e a beteg?
- 139 beteg vett részt a vizsgálatban, azaz a tanuló halmaz nem nagy számú (179 kép),
- Validálás: szérum HP IgG szint alapján
- Megoldás, : tanuló halmaz augmentáció, így 589 képpel dolgoztak
- Pontosság: 95,6 %
- Szenszitivitás: 86,7 %
- Specificitás: 86,7 %

Itoh, T., et al., *Deep learning analyzes Helicobacter pylori infection by upper gastrointestinal endoscopy images*. Endosc Int Open, 2018. 6(2): p. E139-44.





► **Table 2** Breakdown of training images and test images.

	HP infection status	No. of endoscopic images	No. of images after data augmentation
Training images	Positive	70	280
	Negative	79	316
Test images	Positive	15	–
	Negative	15	–

Csonttörések diagnosztikája²

- Tanulási halmaz: 256 000 kéz-, csukló-, boka röntgenfelvétel+ hozzájuk tartozó kórlapok
- 5 különböző CNN-t tanítottak a feladatra
- Amit meg tud mondani a CNN:oldalosság, testrész, felvétel típusa, törés megléte
- Pontosság: >90% oldaliséget, testrészt és felvétel típusát tekintve, törést illetően 83%, ez emberi szintet mutat

Olczak, J., et al., *Artificial intelligence for analyzing orthopedic trauma radiographs: Deep learning algorithms—are they on par with humans for diagnosing fractures?* Acta Orthop, 2017. **88**(6): p. 581-6



Accuracy (%)

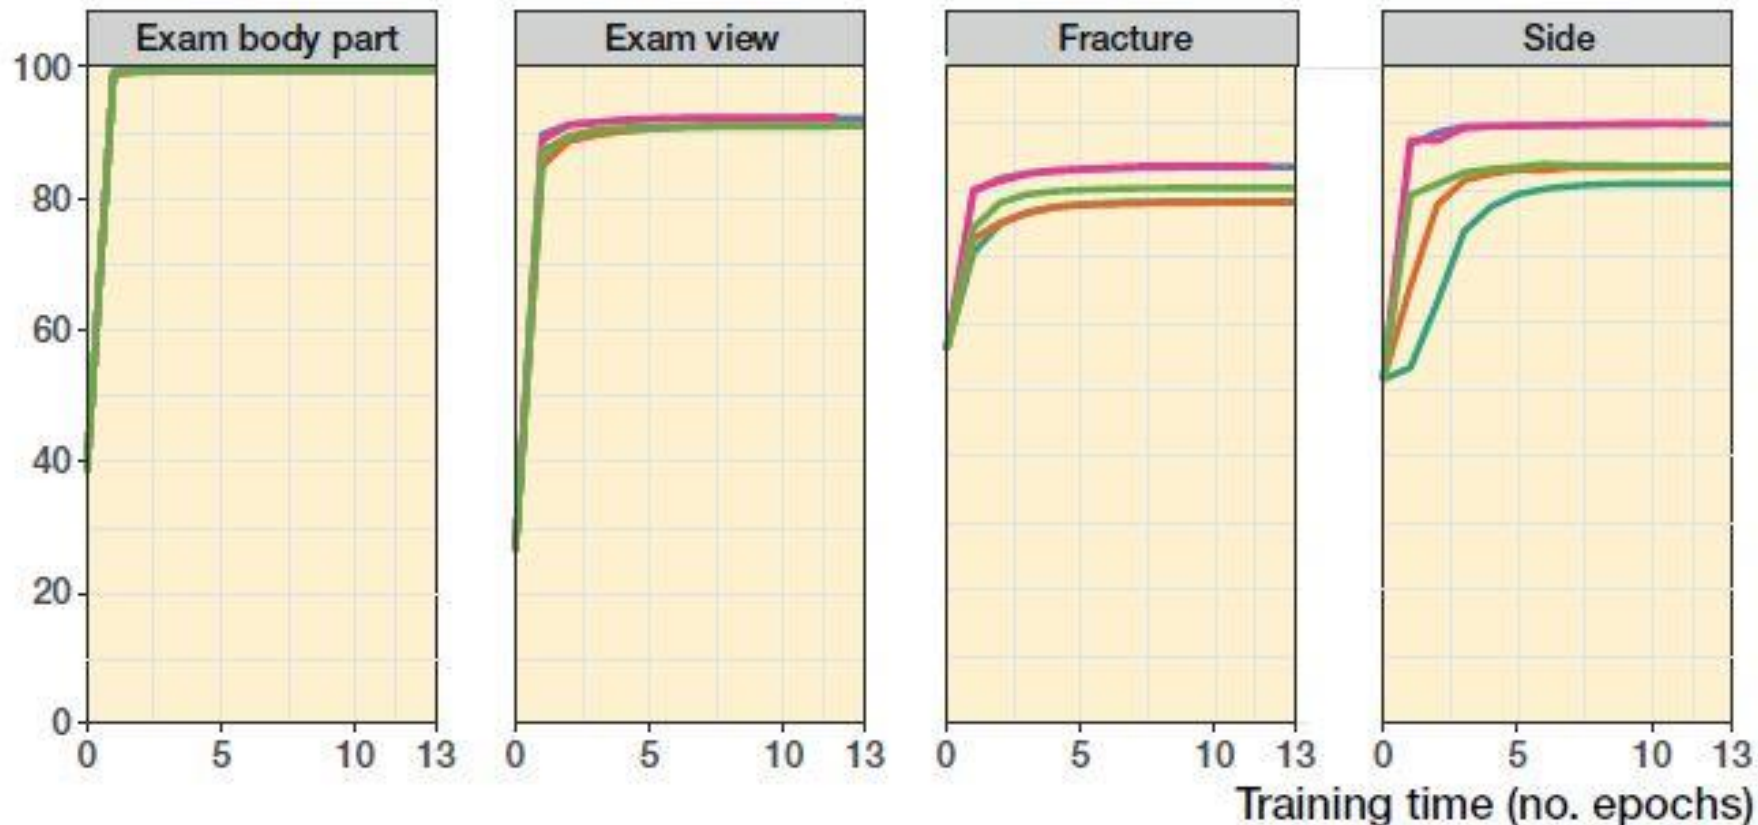


Figure 2. Performance of the 5 networks. An epoch is 1 pass over all images.

- Network
- BVLC reference net
 - VGG 8 layers
 - VGG 16 layers
 - VGG 19 layers
 - Network-in-network

Observer	Label ^a	Accuracy % (Kappa)			
		Network	Reviewer 1	Reviewer 2	Gold standard
Label ^a	–	80 (0.6)	76 (0.5)	74 (0.5)	83 (0.7)
Network	80 (0.6)	–	84 (0.7)	86 (0.7)	83 (0.7)
Reviewer 1	76 (0.5)	84 (0.7)	–	90 (0.8)	82 (0.6)
Reviewer 2	74 (0.5)	86 (0.7)	90 (0.8)	–	82 (0.6)
Gold standard	83 (0.7)	83 (0.7)	82 (0.6)	82 (0.6)	–

^a 4 labels were missing outcome and were excluded from the analysis for this category.

Következtetések

- Egy emberi szintű, használható platformot, szoftvert hoztak létre
- Gyakorlati hiányosságok, melyek a sebész számára szükségesek lennének: osztályokba sorolás, diszlokáció kockázata → ortopéd szakértelme szükséges, kiegészítő, segítő algoritmusnak kiváló

Myokardiális Infarktus Diagnosztika³

- Amerikában 750 000 eset évente, ebből 250 000 esetben nem az első MI
- EKG-ból, 93,53 – 95,22 %-os pontossággal,
- Legjobb:
 - Szenzitivitás: 95,49%
 - Specificitás: 94,19 %
- 200 betegről készült EKG adatbázist használtak fel,
- EKG felvételeken megközelítően 14 600 ütést vizsgáltattak a CNN-nel, ebből 10 000 egészséges, 4 600 beteg
- Nemcsak a QRS-komplexumot, hanem a P, illetve Q hullámokat is elemezték

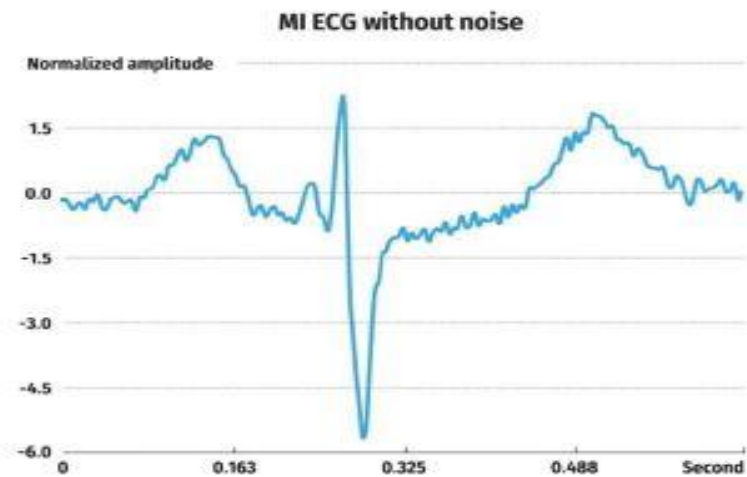

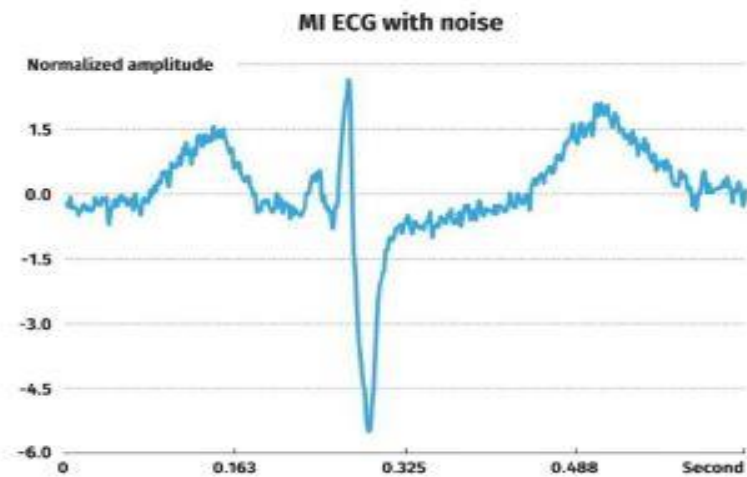
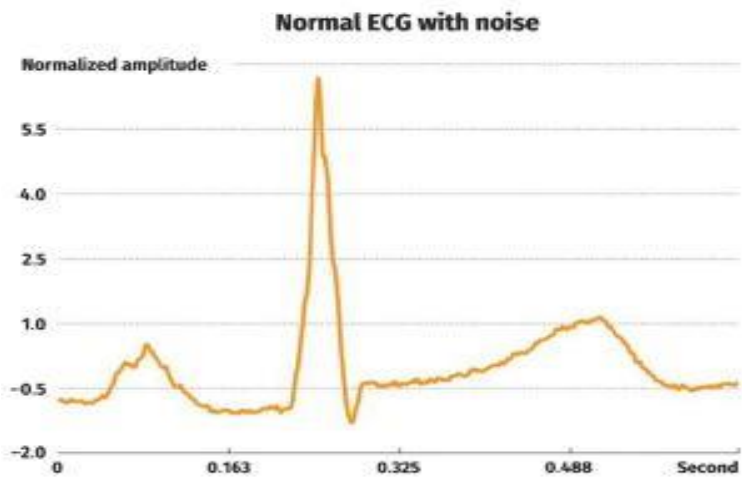


Fig. 2. Sample normal and MI ECG beat with and without noise removal.

All ECG segments




Fig. 4. The apportionment of ECG beats used for training and testing the proposed algorithm.

Table 3

Confusion matrix of ECG beats with noise across 10-folds.

		Predicted		ACC (%)	PPV (%)	SEN (%)	SPEC (%)
		Normal	MI				
Original	Normal	9790	756	93.53	79.48	92.83	93.71
	MI	2527	37,655	93.53	98.03	93.71	92.83

ACC = Accuracy, PPV = Positive Predictive Value, SEN = Sensitivity, SPEC = Specificity

Table 4

Confusion matrix of ECG beats without noise across 10-folds.

		Predicted		ACC (%)	PPV (%)	SEN (%)	SPEC (%)
		Normal	MI				
Original	Normal	9933	613	95.22	84.56	94.19	95.49
	MI	1814	38,368	95.22	98.43	95.49	94.19

ACC = Accuracy, PPV = Positive Predictive Value, SEN Sensitivity, SPEC = Specificity

Table 5

The overall classification results for the classification of normal and MI classes across 10-folds.

Beats Type	TP	TN	FP	FN	ACC (%)	PPV (%)	SEN (%)	SPEC (%)
Noise	37,655	9790	756	2527	93.53	98.03	93.71	92.83
Without Noise	38,368	9933	613	1814	95.22	98.43	95.49	94.19

TP = True Positive, TN = True Negative, FP = False Positive, FN = False Negative

ACC = Accuracy, PPV = Positive Predictive Value, SEN = Sensitivity, SPEC = Specificity

Előnyök

- Nagy az elemszám: nem szükséges kijelölni az EKG ütéseket, megmondani a hálózatnak, hogy mit kell keresnie, hanem magától „rájön”
- Nem szükséges zajszűrő a használathoz

Aritmia diagnosztika⁴

- Ugyanaz a munkacsoport, mint az előző.
- Hasonlóan jó CAD=Computer Aided Diagnosis rendszerek. Miért kell?
- Idő- és energiatakarékosabb: nem kell előszűrni az EKG-kat, kizárni és szelektálni a fölösleges részeket
- Megközelítőleg 30 000 EKG szakasz vizsgálata
- Pitvarfibrilláció, pitvari flutter, kamrafibrilláció, normál szinusz ritmus elkülönítése

Acharya et Al.: Automated detection of arrhythmias using different intervals of tachycardia ECG segments with convolutional neural network, 2017.

Eredmények


2 másodperces EKG szakasz

- Pontosság: 92,5 %
- Szenszitivitás: 98,09 %
- Specificitás: 93,13 %

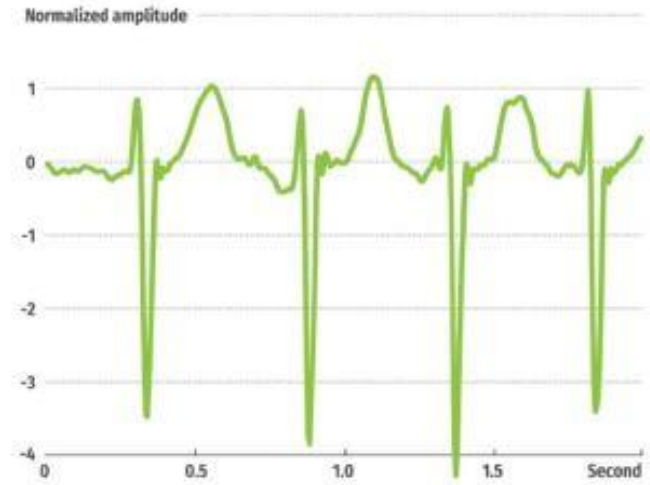
5 másodperces EKG szakasz

- Pontosság: 94,9 %
- Szenszitivitás: 99,13 %
- Specificitás: 81,44 %


Normal ECG



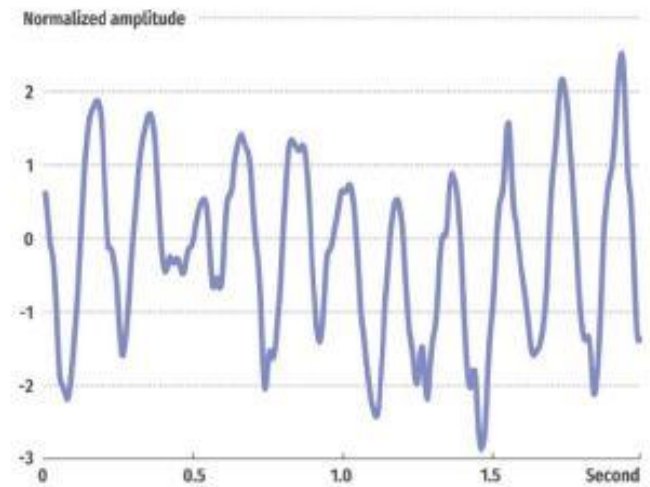
Atrial Fibrillation ECG



Atrial Flutter ECG



Ventricular Fibrillation ECG



Tüdőrák diagnosztika⁵

- Az 5. legnagyobb mortalitású daganat
- Az Európai Unió megelőzési stratégiája: néhány éven belül a kockázati populáció évenkénti szűrése alacsony dózisú CT-vel
- Egy verseny: ki írja a legjobb tüdődagantot felismerő neurális hálózatot?
- Felhasznált mellkas CT-k: 235 000 felvétel


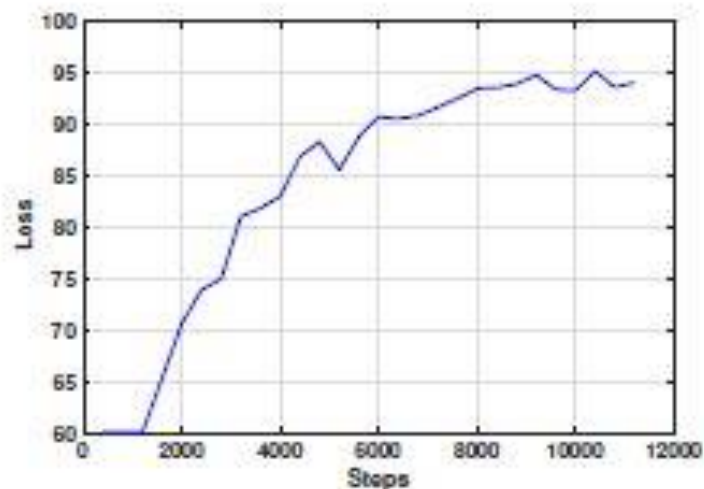


Figure 5: (left): the recognition rate of cross-validation set, and (right): total loss function as gradient steps which are taken with respect to mini-batches.




Figure 2: Four slices of different patient chests cavity from the Kaggle Data Science Bowl 2017 data set.


Table 1: The result of our proposed dCNN in three metric measurements.

	<i>Sensitivity</i>	<i>Specificity</i>	<i>F1</i>
AIDA [9]	0.538	0.648	0.33
ours	0.87	0.991	0.95

Sebklasszifikáció.- és 3D elemzés

- Krónikus seb gyógyhajlamának gyorsítása
- Szakorvosok által validált, krónikus sebek gyógyulását elősegítő, mesterséges intelligencia alapú szoftver:
 - Kórházi ellátás szükségessége?
 - Nővér munkájának segítése
 - Sebek gyógyulásától eddig nem látott adatok?

A vizsgálat menete



Mobiltelefonnal
fénykép és kérdőív
készül

Mesterséges intelligencia
vizsgálja a képeket és
adatokat

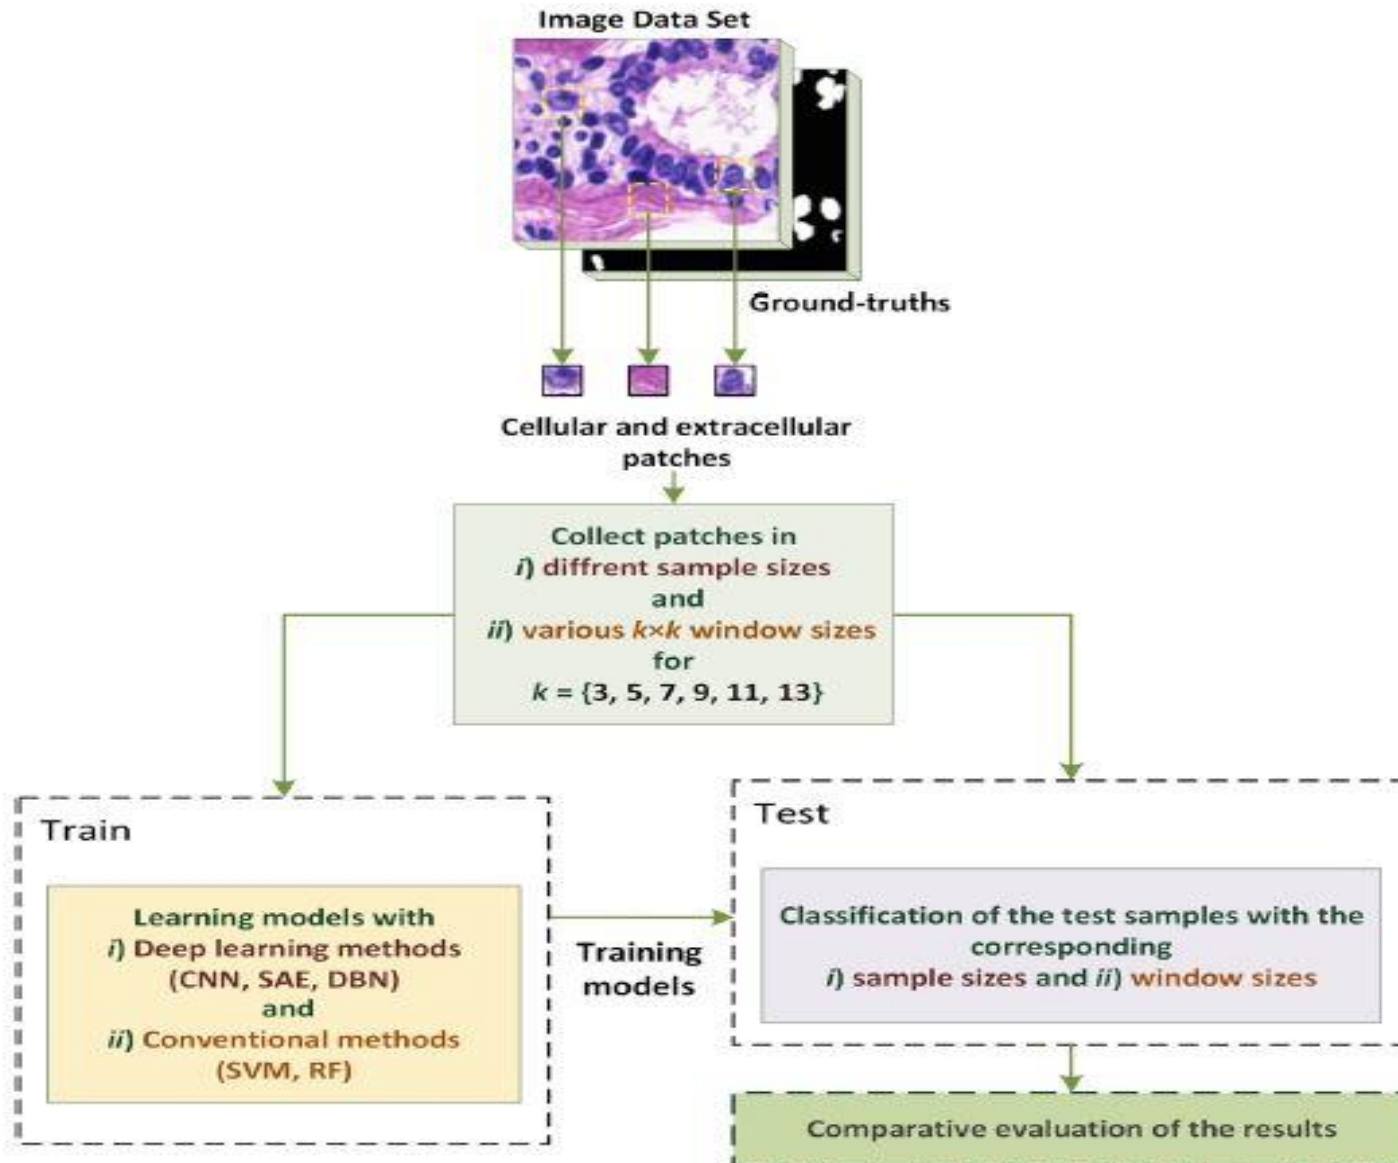
Döntéstámogatás


Biztonságosabb
betegellátás

Patológia: Sejt-szegmentáció mesterséges intelligenciával⁶


- Különböző típusú neurális hálózatokat teszteltek, hogy melyik a legjobb sejtek felismerésében, elkülönítésében
- Egészséges, ill. malignus sejtek
- Az optimális: CNN
- Felhasznált felvételek száma: 36000 szövettani metszet
- A hálózatra bízták, hogy különböző mintázatokat keressen az adott típusú szövetekben, és találjon rá összefüggést, amely alapján azonosítani tudja a sejteket

Hatipoglu et Al.: Cell segmentation in histopathological images with deep learning algorithms by utilizing spatial relationships, 2017.






(a)



(b)



(c)






(d)

Következtetések


- Előnyös: Segítségnek jó, a patológus mellé
- Hátrányos:
 - a metszet mérete változik, nem minden felbontást képes a hardver feldolgozni, kiértékelni
 - túl nagy, és – egyelőre – számításba nem vehető intra- és interobszerver variabilitás


Retina diagnosztika AI-jal

- OCT felvételekből
- 14500 felvétel
- 8 „kontroll” személy: 4 szemész, 4 retinaspecialista
- Triázs: sürgősségi besorolás + szegmentáció
- Emberi szintet elérő, vagy egyes esetekben meghaladó pontosság



Diabéteszes retinopátia diagnosztikája AI-jal





0110
0100
1001

0101
1001
0110
0100
0110
0100
1001

0101
1001
0101
0110
0100
1001
0101

0101 1100
1001 0100
0101 0100 0110
0110 1011 0100

>connection ended

Retina Videó

- <https://www.youtube.com/watch?v=reYQusRXecE>