TANULÁSI PROBLÉMÁK ORVOSI KÉPFELDOLGOZÁSBAN

LUKÁCS ANDRÁS

ELTE MATEMATIKAI INTÉZET

MI KUTATÓCSOPORT

TKP WORKSHOP - 2022.01.13.

NEMZETI KUTATÁSI, FEJLESZTÉSI ÉS INNOVÁCIÓS HIVATAL

AZ INNOVÁCIÓ LENDÜLETE

AZ NKFI ALAPBÓL MEGVALÓSULÓ PROJEKT

Orvosi képek

- Orvosi képek klasszifikációja, szegmentálása
  - Röntgen
  - Patológia, mikroszkópos képek
  - Retina képek

- Sajátosságok
  - Csatornák száma
  - Színek eloszlása
  - Augmentációs lehetőségek
  - Hierarchikus, rendezett címkék
  - Kiegyensúlyozatlan osztályok

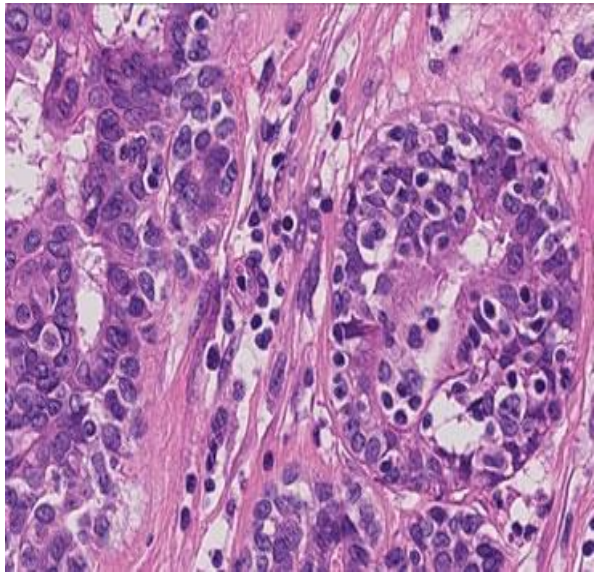

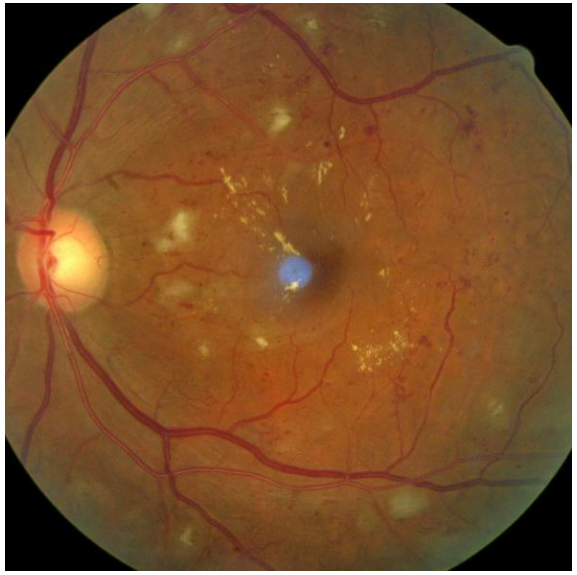

Kutatási célok

- Orvosi képek feldolgozásában TRL4 → TRL5 szint
  - Laboratóriumban (TRL4) → releváns környezetben validált technológia (TRL5)
  - Gépi tanulásban ennek a szintlépésnek az ellenőrzése jelentős részben a validáláshoz használt adathalmazok minőségétől, relevanciájától függ
  - Minőség, relevancia – az adatok a várható felhasználást tükrözik

- Stratégia, irányok
  - Transfer learning jobb megértése, használatának fejlesztése
    - SOTA modellek fejlesztése
  - Adatbázisok sajátosságainak vizsgálata
    - Diverzitás, annotálás minősége, méret, kiegyensúlyozottság
  - Adatbázisok globális reprezentációja
    - Képi szintű normalizálás → adatbázis szintű normalizálás
    - Augmentáció, generatív módszerek

Transfer learning

- Nagy, betanított modellek (Google, OpenAI, Facebook…) → gyorsabb és jobb tanítás más feladaton
- Régebbi ötlet (~1980), mára „ipari sztenderd”
- A transfer learning három fajtája
  - Reprezentáció kinyerés
  - Fine tuning
  - Egyedi megoldások

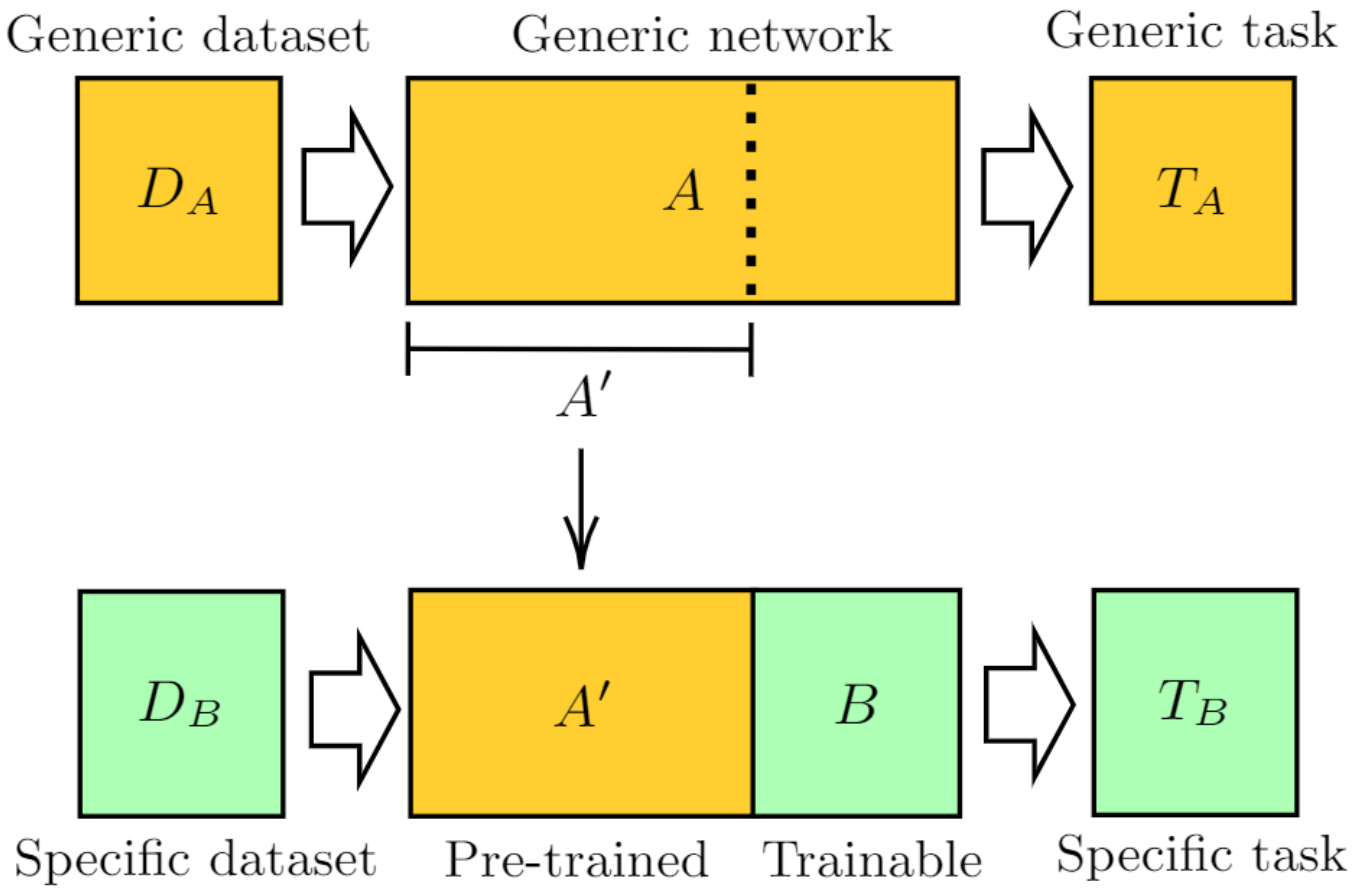

Transfer learning

- Nagy, betanított modellek (Google, OpenAI, Facebook…) → gyorsabb és jobb tanítás más feladaton
- Régebbi ötlet (~1980), mára „ipari sztenderd”
- A transfer learning három fajtája
  - Reprezentáció kinyerés
  - Fine tuning
  - Egyedi megoldások

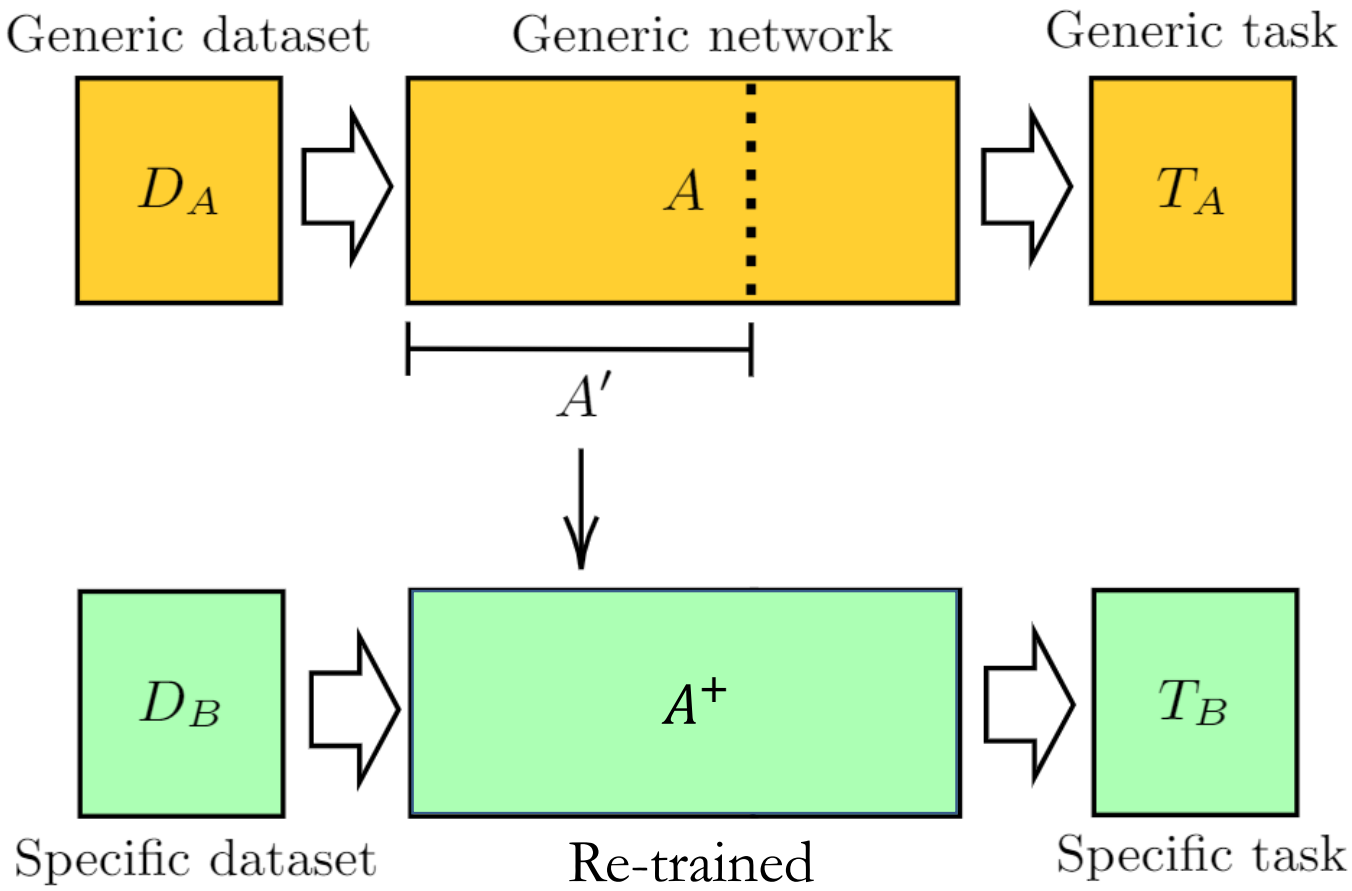

Transfer learning

- Nagy, betanított modellek (Google, OpenAI, Facebook…) → gyorsabb és jobb tanítás más feladaton
- Régebbi ötlet (~1980), mára „ipari sztenderd”
- A transfer learning három fajtája
  - Reprezentáció kinyerés
  - Fine tuning
  - Egyedi megoldások

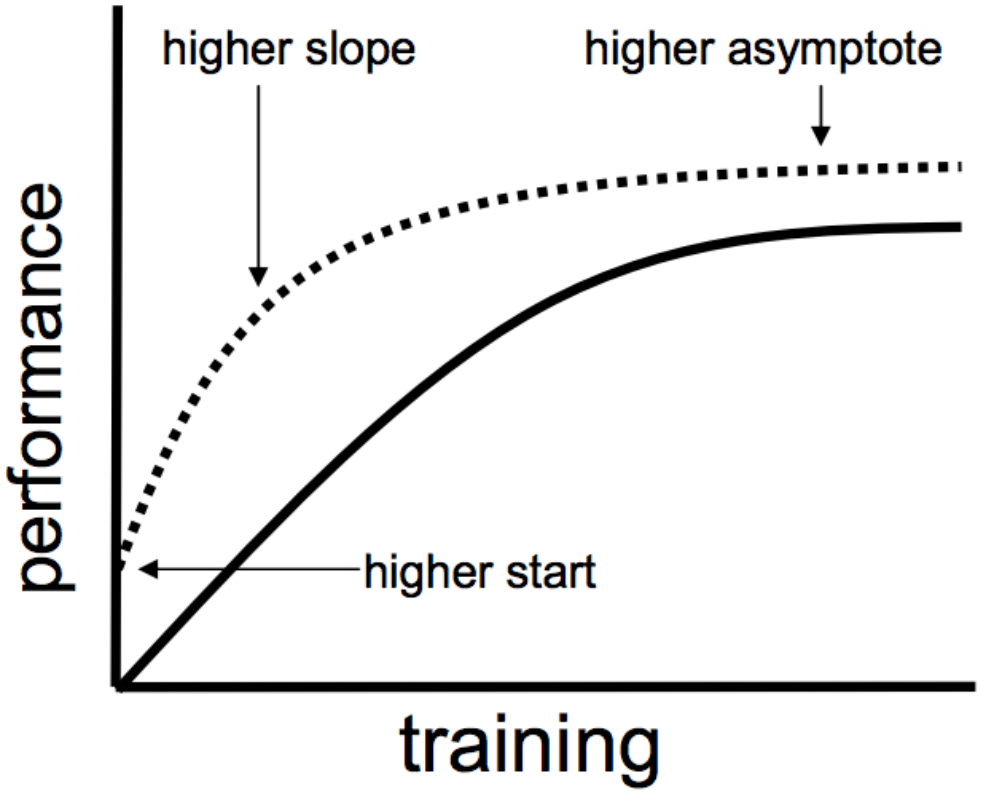

Tanító adathalmaz méretének hatása a TL-re

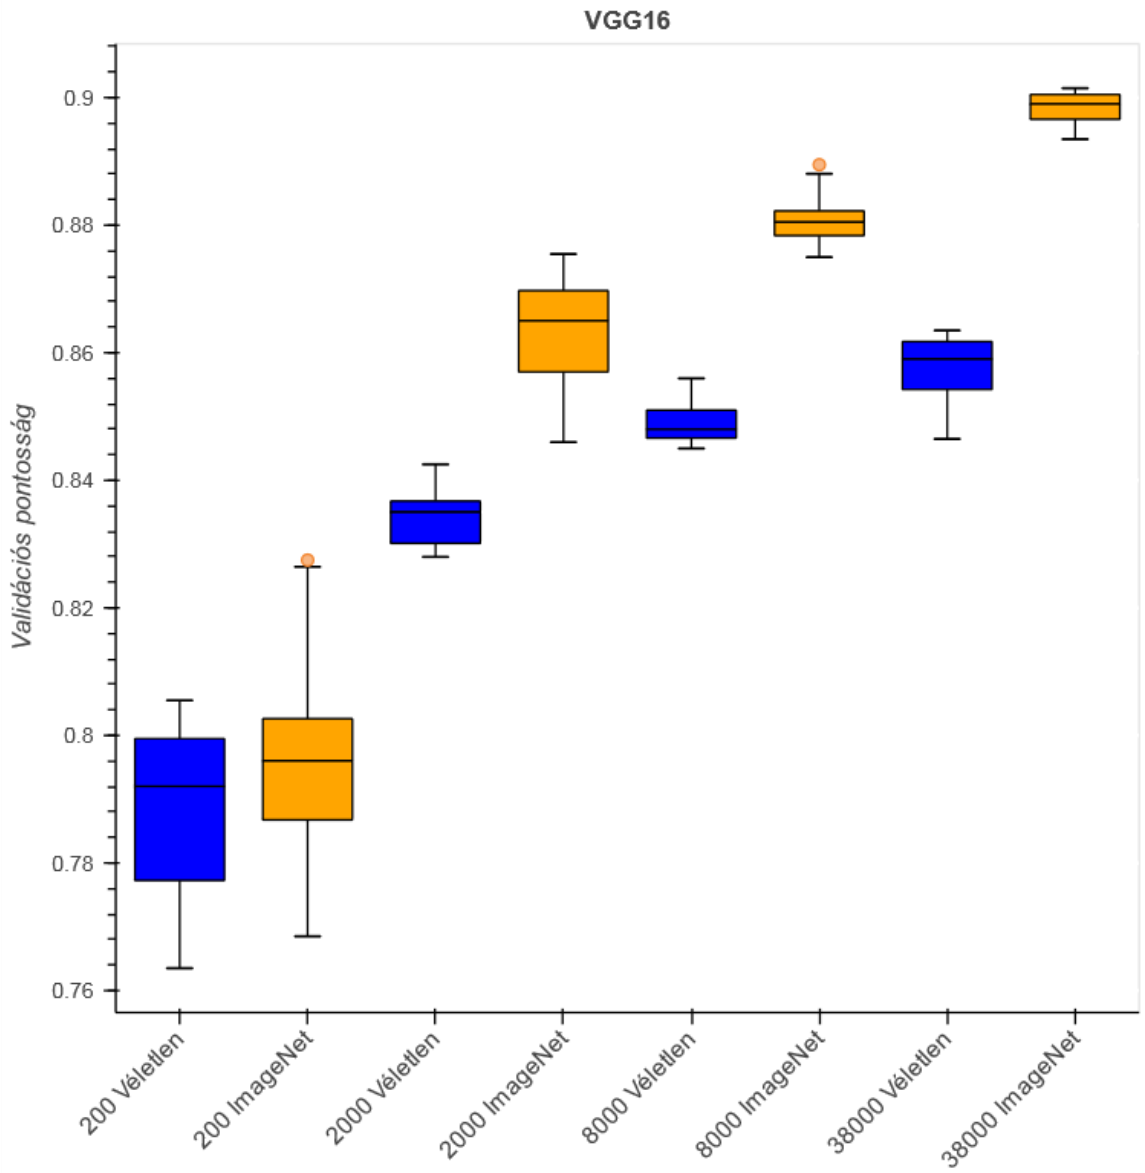

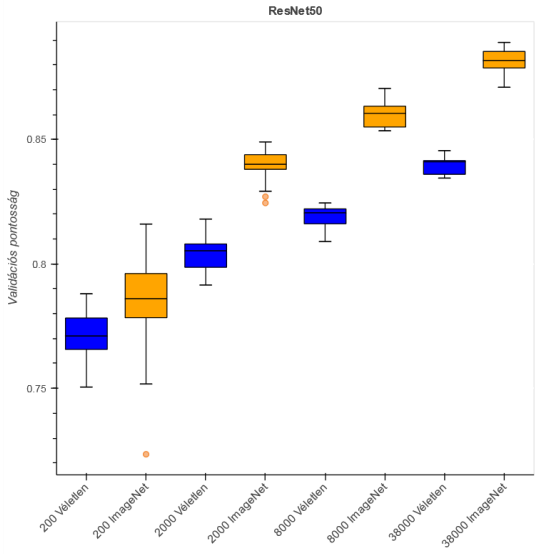

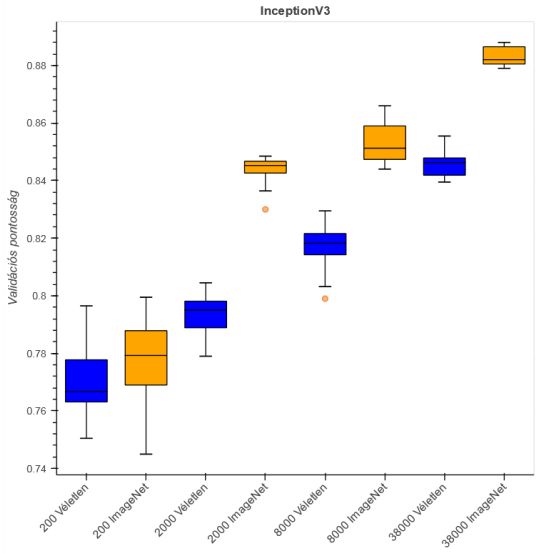

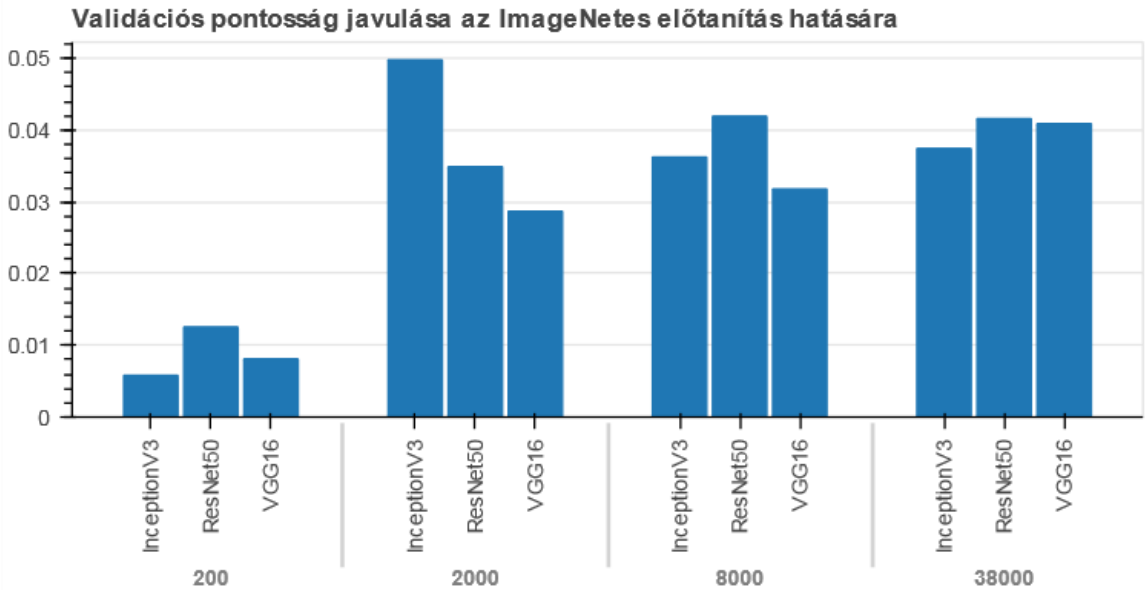

Diabéteszes retinopátia detektálása

- Több retina képadatbázis
  - Kaggle EyePACS (2015, 90k) - ezen tanulunk
  - DDR (2019, 1k)
  - IDRID (2018, 0.5k)

- A betegség súlyossági szintjei
  - 0 - nincs látható rendellenesség
  - 1 – enyhe NPDR (csak bevérzések az ereken)
  - 2 - közepes NPDR (bevérzések mellett más is)
  - 3 - súlyos NPDR (>20 bevérzés, ödéma, zsírlerakódás)
  - 4 – PDR (érburjánzás, retinán túli bevérzések)

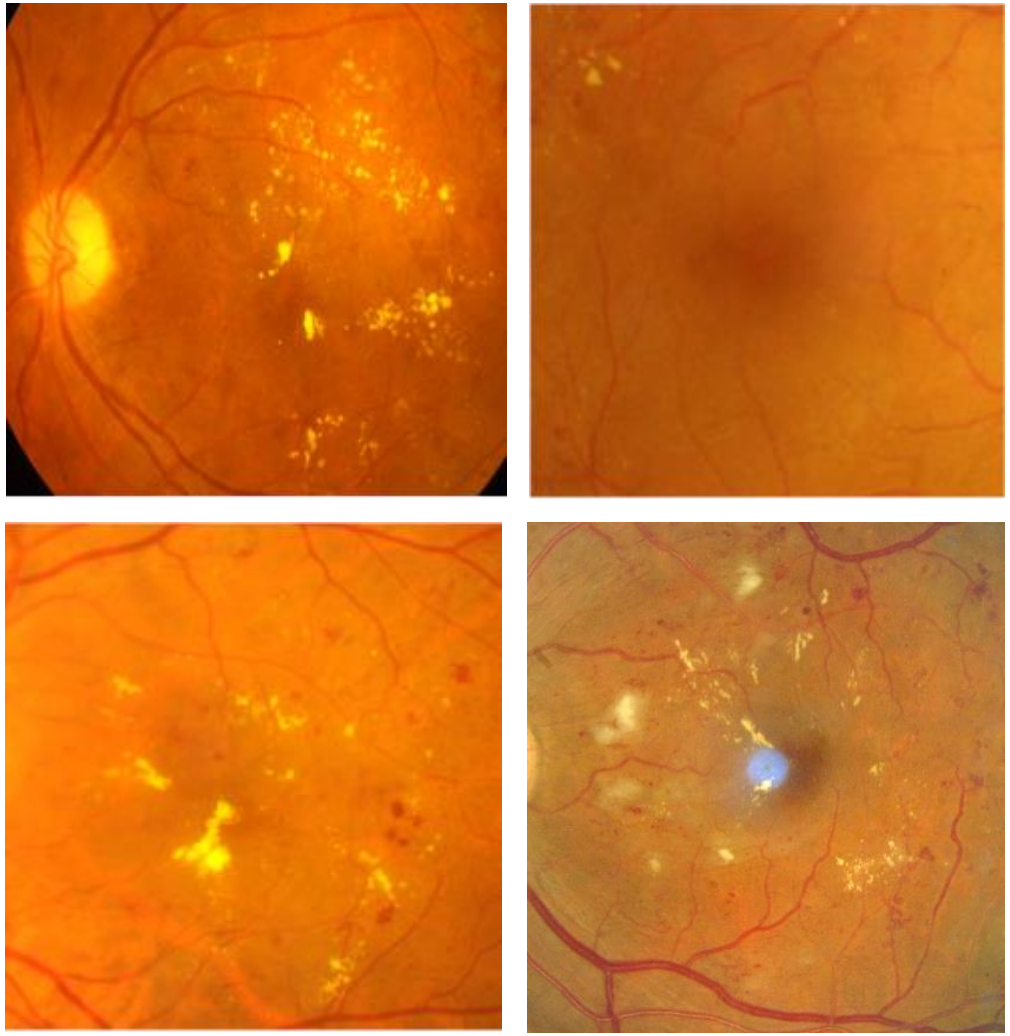

*(N)PDR – (Nem) Proliferatív Diabéteszes Retinopátia

ConvNets Zoo

modell	paraméterek	FLOPs	év
VGG-16	138M	15.3B	2014
ResNet-101	44.5M	7.6B	2015
EfficientNet-B0	5.3M	0.39B	2019
EfficientNet-B6	43M	19B	2019
NFNet-F0	71.5M	12B	2021
EfficientNetV2-S	22M	8.8B	2021

- ImageNet-en előtanított modellek
- Kaggle EyePACS adatbázison továbbtanítva

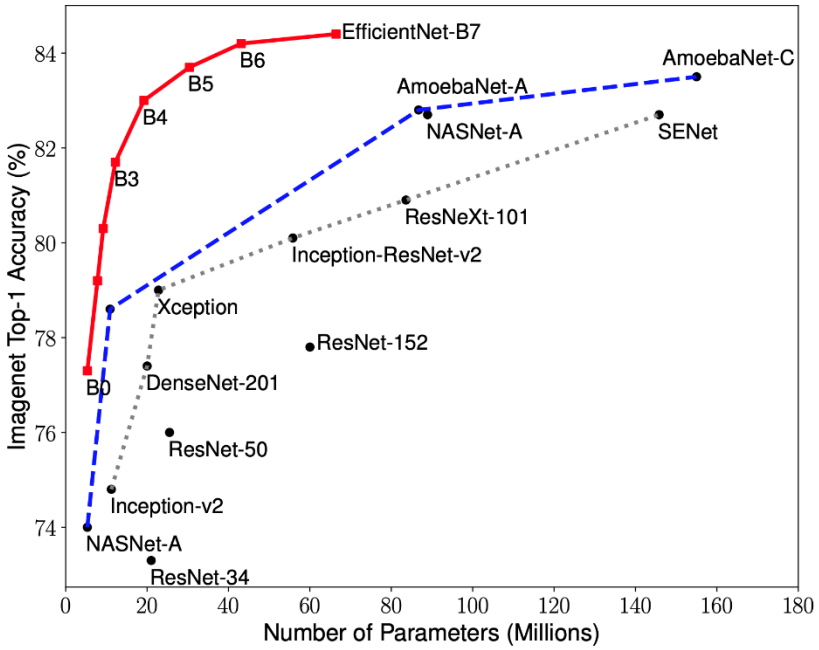

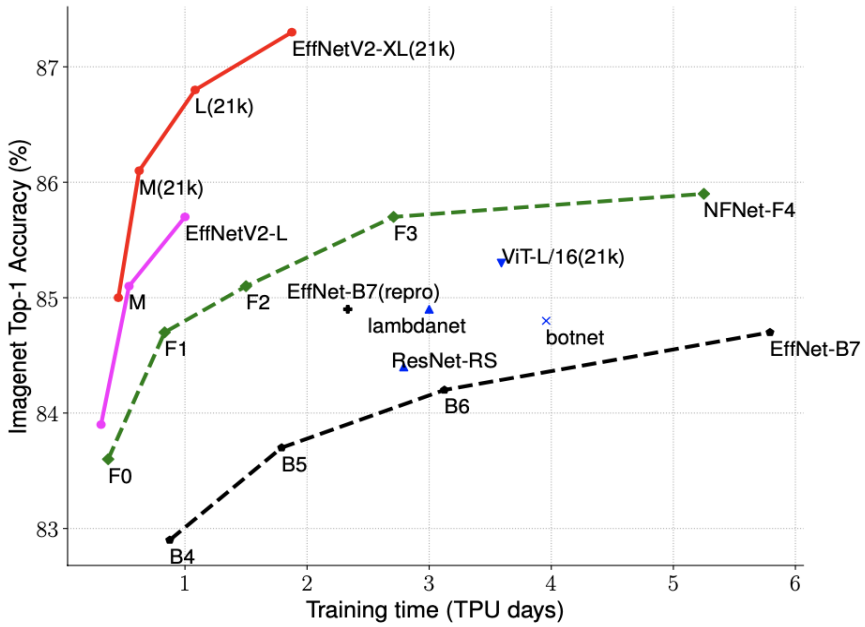

ConvNets Zoo

modell	paraméterek	FLOPs	év
VGG-16	138M	15.3B	2014
ResNet-101	44.5M	7.6B	2015
EfficientNet-B0	5.3M	0.39B	2019
EfficientNet-B6	43M	19B	2019
NFNet-F0	71.5M	12B	2021
EfficientNetV2-S	22M	8.8B	2021

- ImageNet-en előtanított modellek
- Kaggle EyePACS adatbázison továbbtanítva

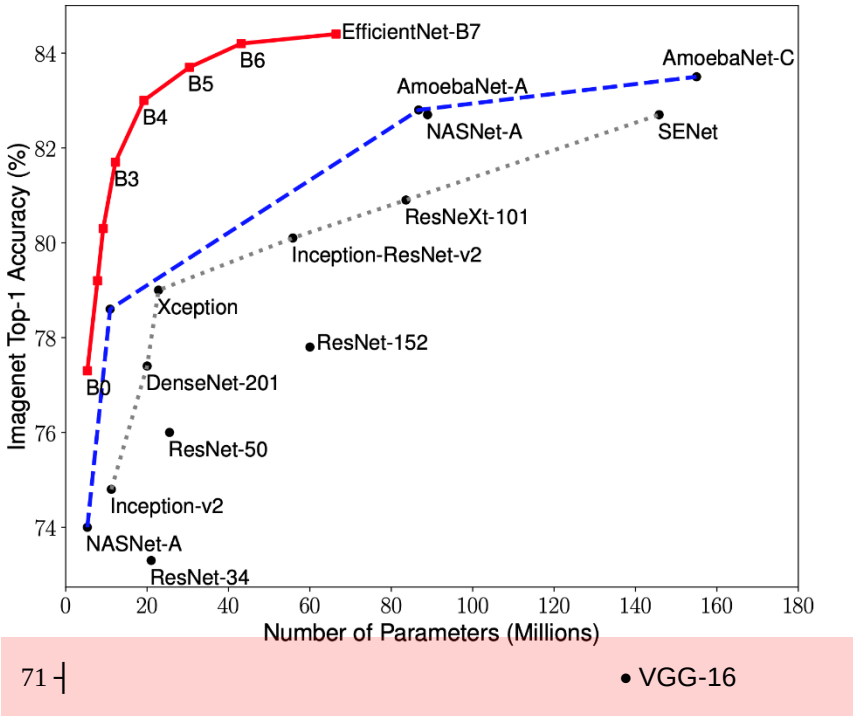

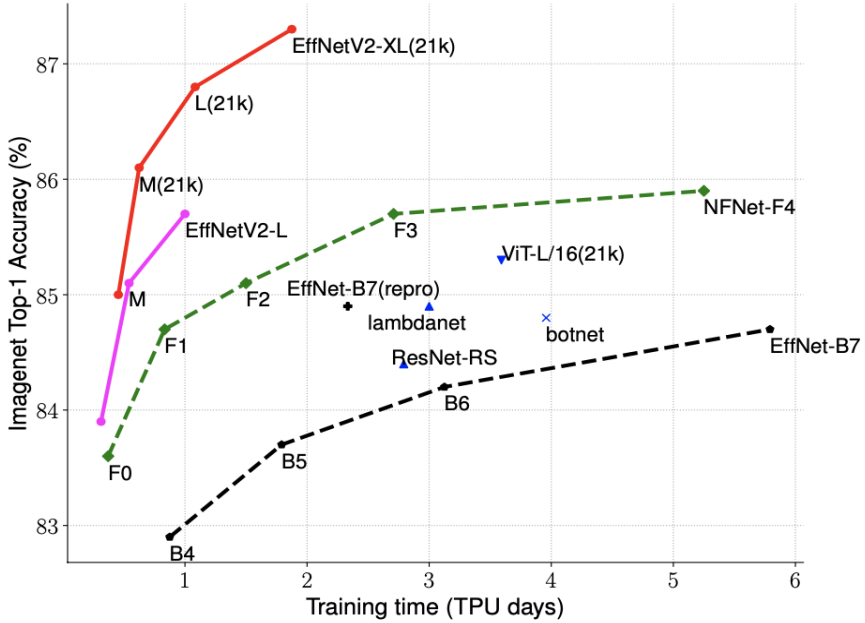

Modellek teljesítménye (EyePACS)

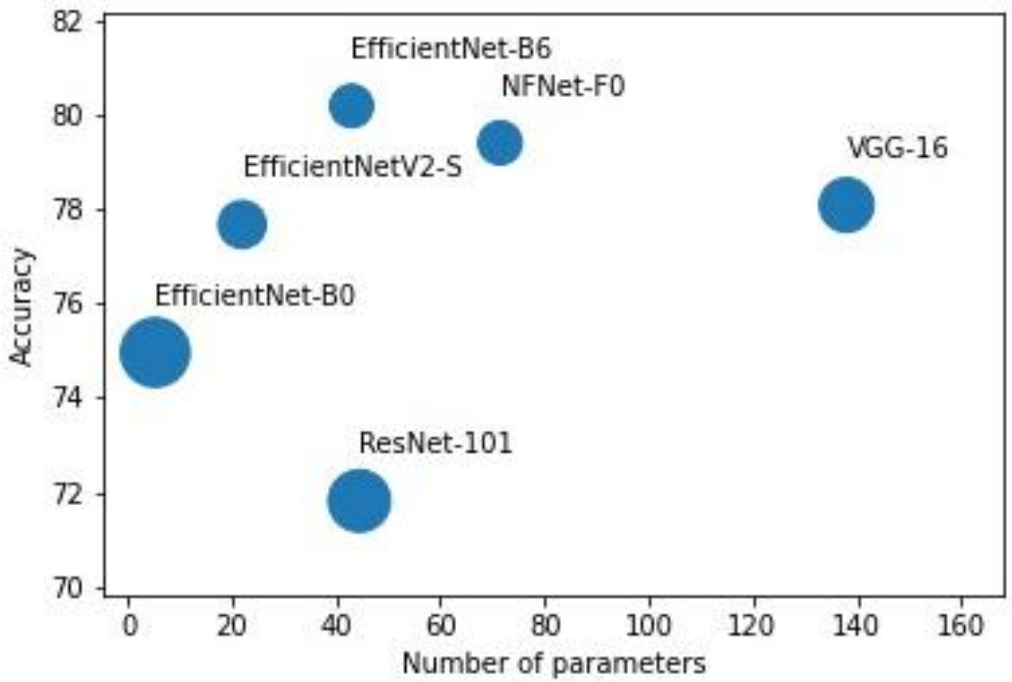

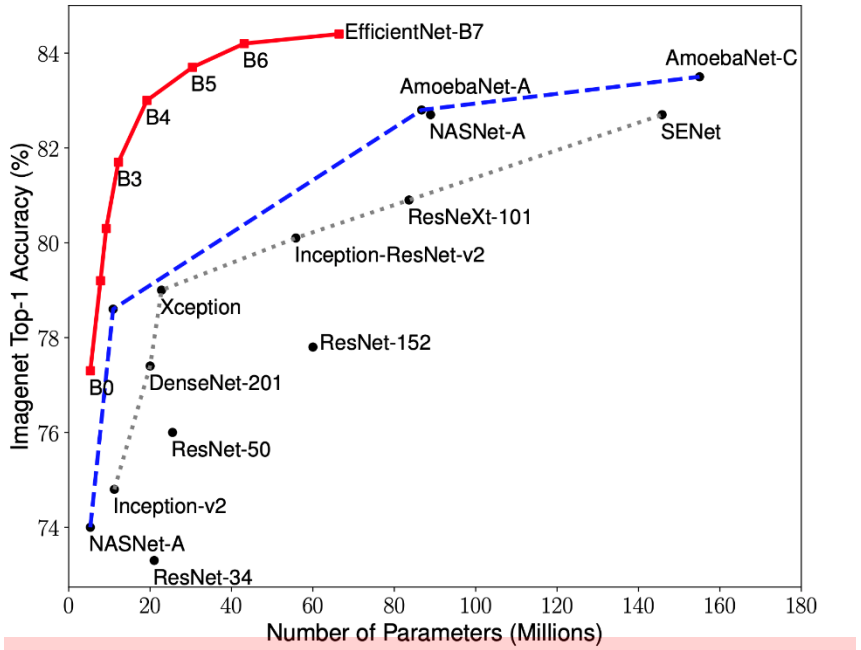

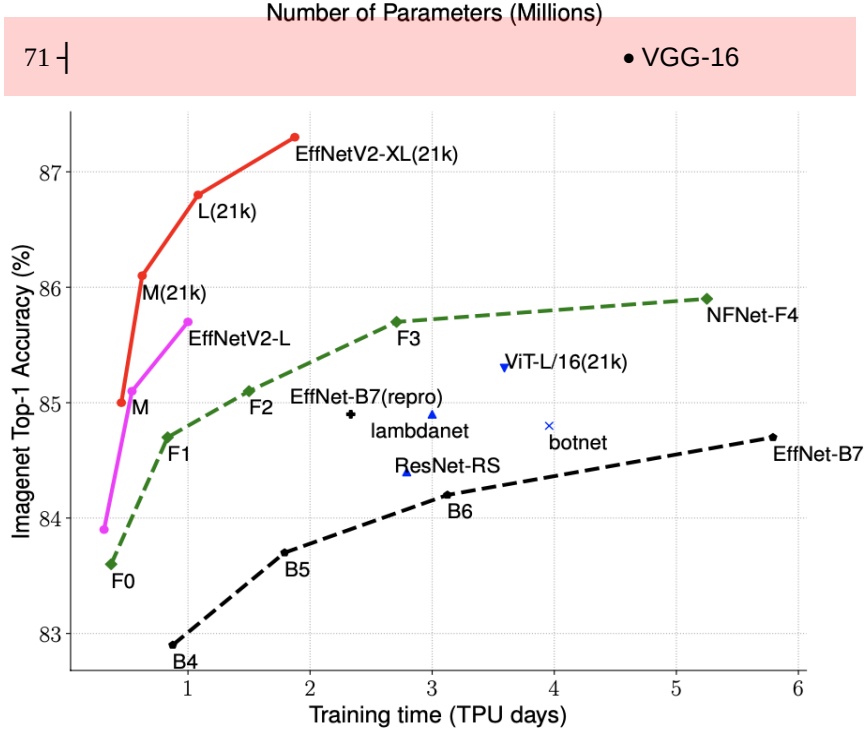

- A modellek ImageNet-re optimalizáltak
  - Lehet-e ezen segíteni?
- Nem mindig van előrelépés egy új modelltípussal
  - VGG v. ResNet, EffNet v. EffNet2v
- A méret továbbra is meghatározó
  - Paraméterszám, tanító adatbázis mérete

Retina képadatbázisok mint teszt halmazok

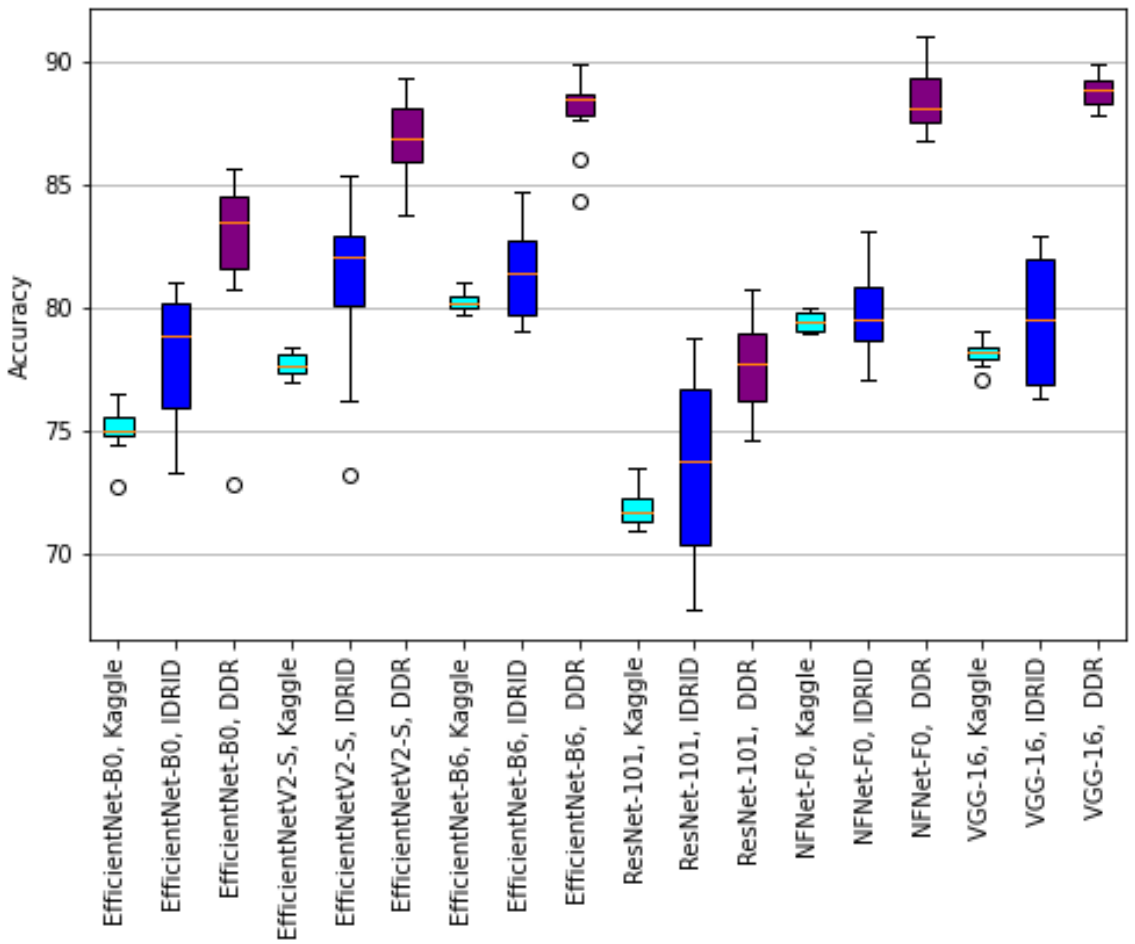

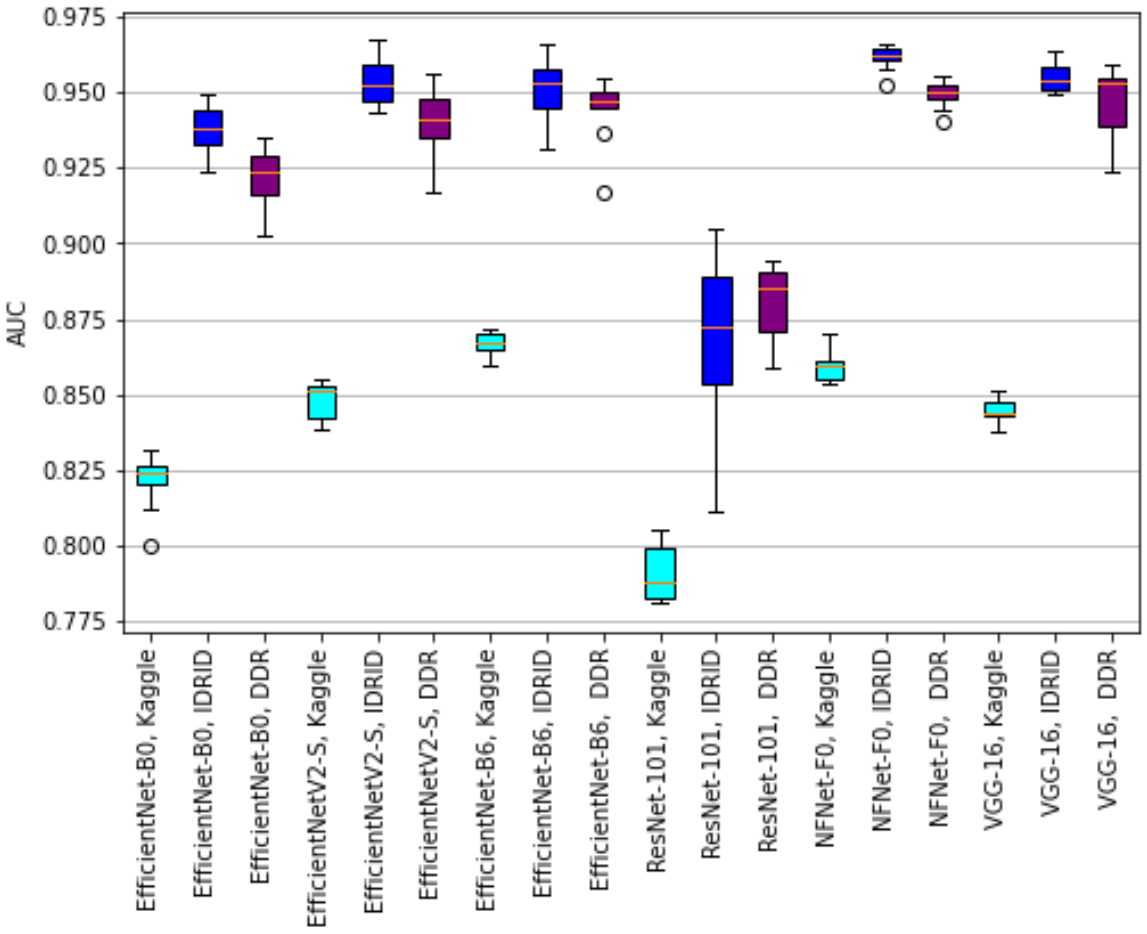

Retina képadatbázisok különbségei

- Tesztelésben használt rekordok száma (3k, 1k, 0.5k)
- Annotálás pontossága
- A képanyag homogenitása
- 1-4 címkék eloszlása

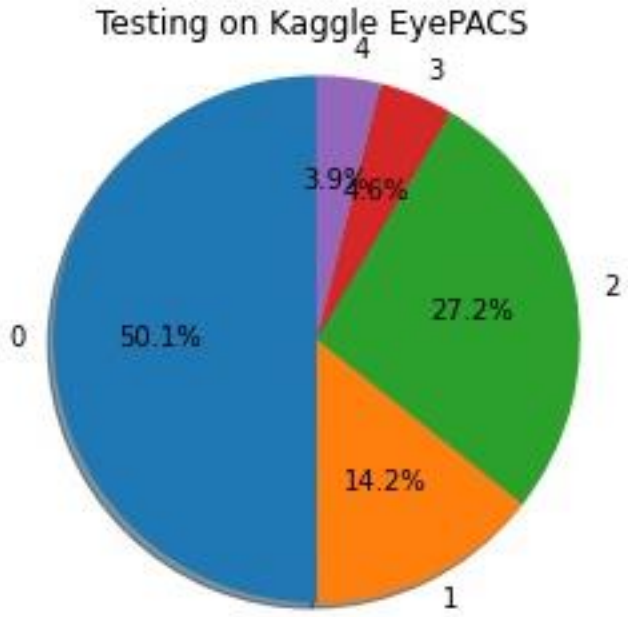

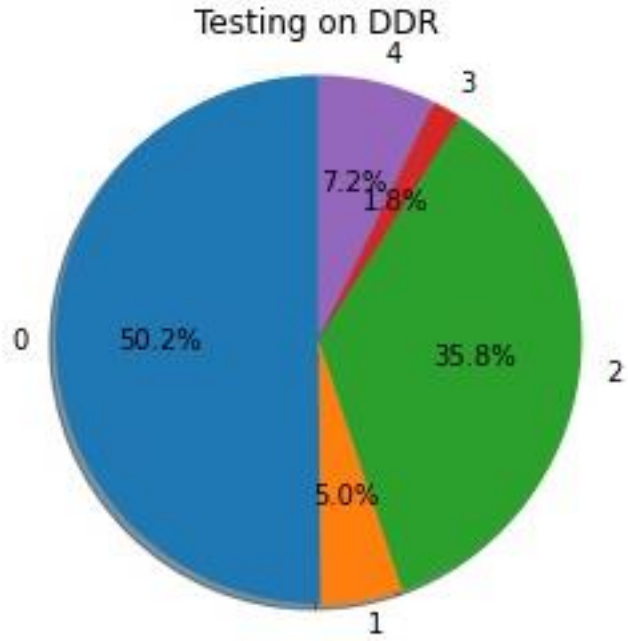

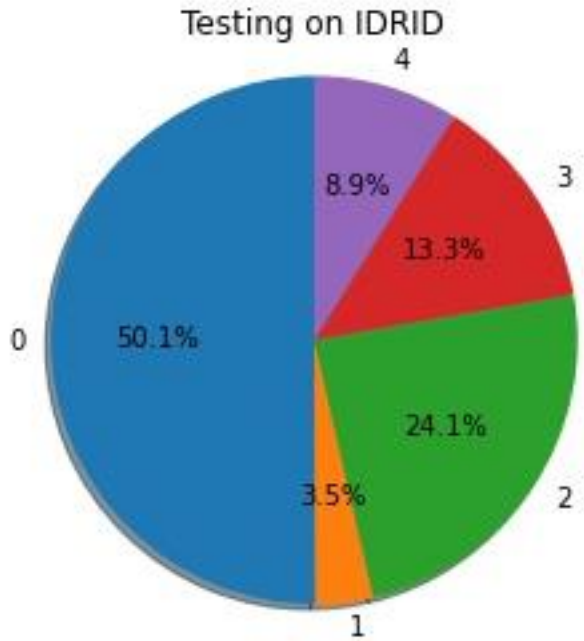

Hisztopatologiai képek szegmentálása

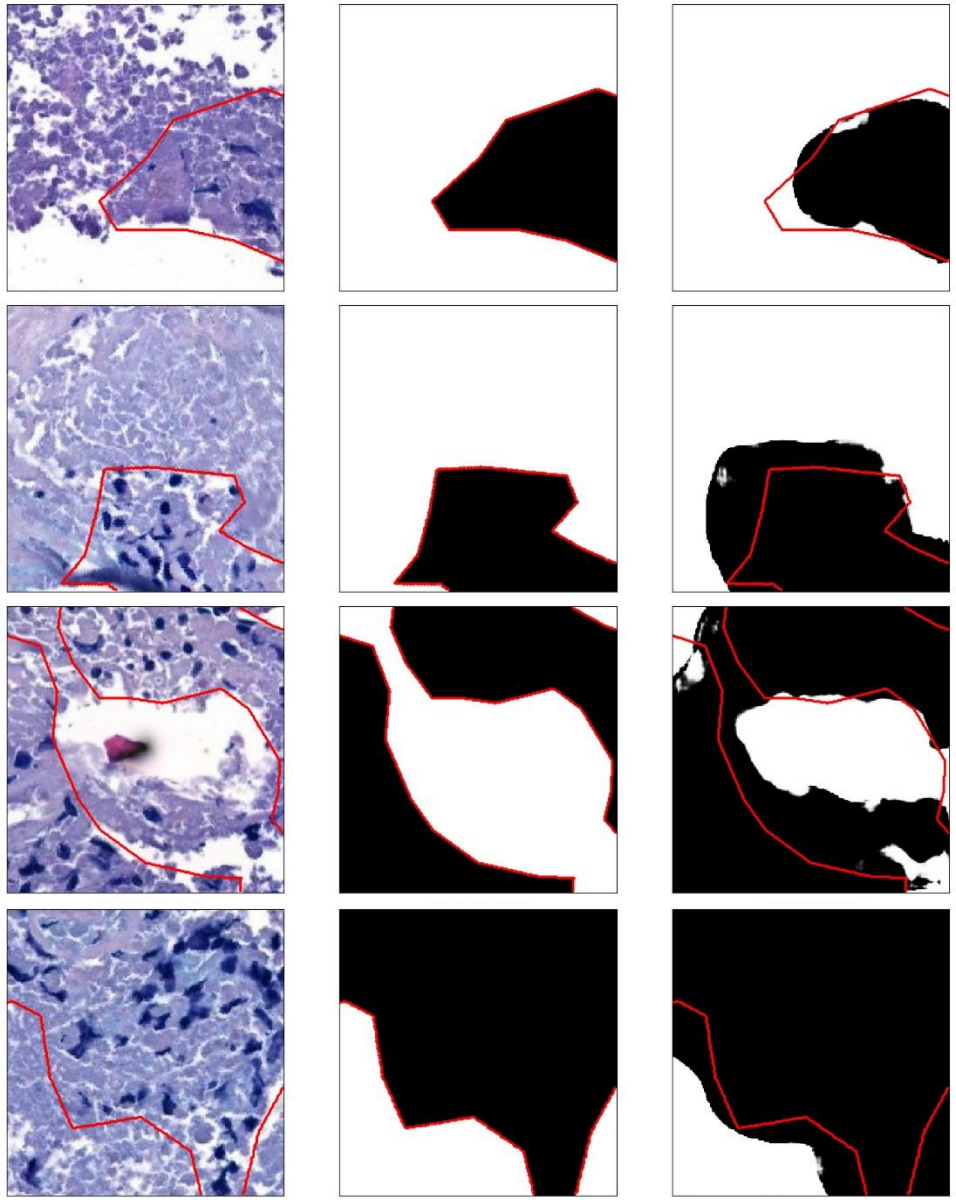

- Valódi adatok
  - Korányi Pulmonológiai Intézet
- Mikroszkópos felvételek biopsziával vett szövetekről
- Patológusok által annotált
  - A határok csak nagyjából vannak követve
  - Az adat kisebb része annotált
- Rendkívül kiegyensúlyozatlan adathalmaz
- Cél: rosszindulatú daganatok, típusaik szegmentálása
- Modellcsalád: U-Net

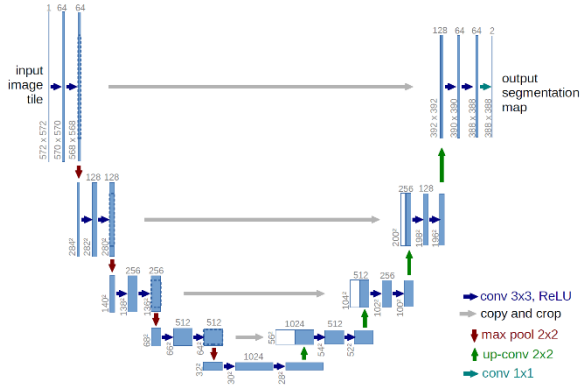

BigEarthNet adathalmaz

- 10 színcsatorna
- 19 címke, közel 600k patch
- Cél: egy vagy több SOTA mély háló műholdfelvételeken használható transfer learningre

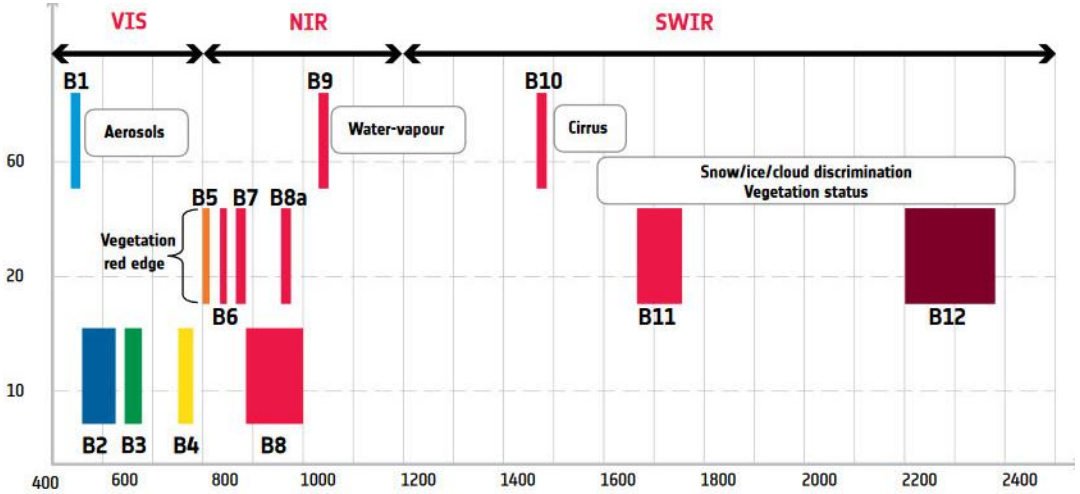

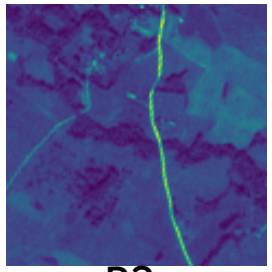
B2

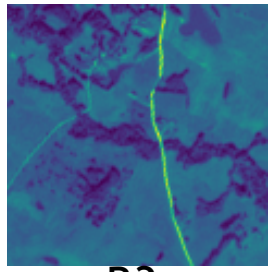
B3

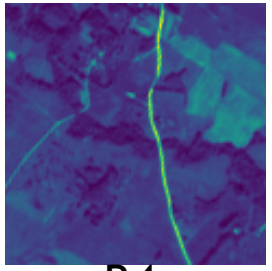
B4

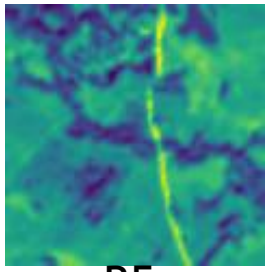
B5

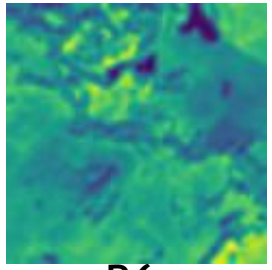
B6

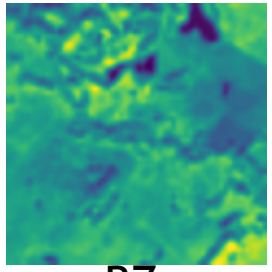
B7

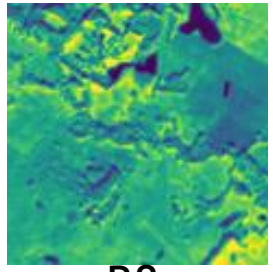
B8

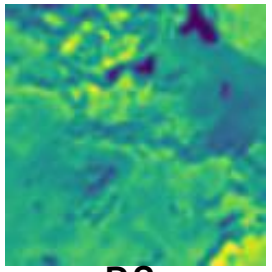
B8a

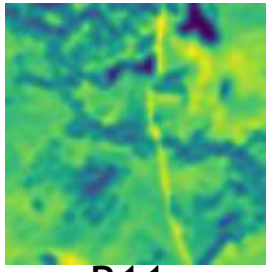
B11

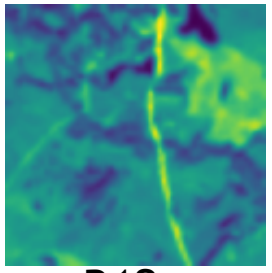
B12

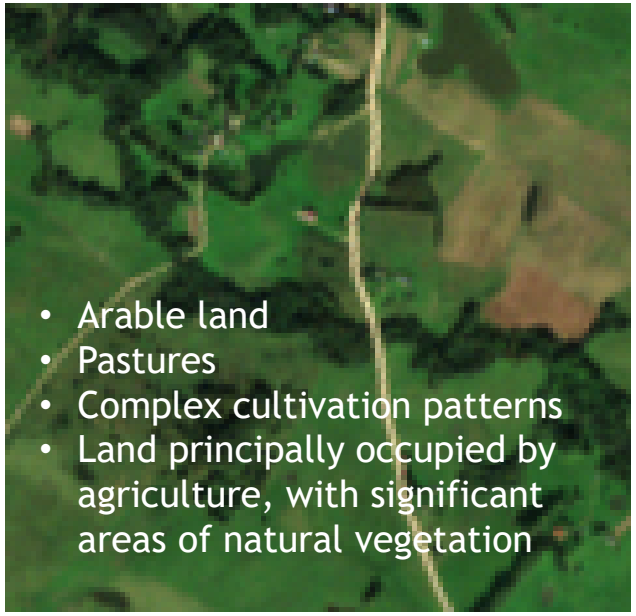

Transfer Learning a BigEarthNet adathalmazon

Model	Parameters	Optimizer	Accuracy			Micro averaged F1		
			From-scratch	ImageNet pretrained	Difference	From-scratch	ImageNet pretrained	Difference
VGG16	14.7M	SGD	0.5067	**0.5122**	+0.0055	0.7470	0.7551	+0.0081
		Adam	0.5059	0.4945	-0.0114	**0.7627**	**0.7691**	+0.0064
ResNet50	23.6M	SGD	0.4885	0.4976	+0.0091	0.7483	0.7223	-0.0260
		Adam	**0.5189**	0.5025	-0.0164	0.7513	0.7578	+0.0065
InceptionV3	21.8M	SGD	0.4895	0.5017	+0.0122	0.7445	0.7527	+0.0082
		Adam	0.4957	0.4813	-0.0144	0.7566	0.7496	-0.0070
EfficientNetB4	17.7M	SGD	0.4824	0.4891	0.0067	0.7529	0.7097	-0.0432
		Adam	0.4902	0.4900	-0.0002	0.7439	0.6969	-0.0470

Modellsebészet

- Hogyan lehet alkalmazni a 3 bemeneti csatornával rendelkező előtanított sztenderd modellt 10 bemeneti csatornára?
  - Csak 3 csatornát használunk az inputból
  - 3d → 10d beágyazással kiegészített modell
  - Modell első rétegének átalakítása több csatornára
  - Modell fúzió (3 modell 9 csatornát kezel)

- Mik legyenek a transfer súlyok az új csatornákban?
  - Véletlen inicializálás
  - Meglévő csatornák súlyainak másolása
    - Red → Infrared

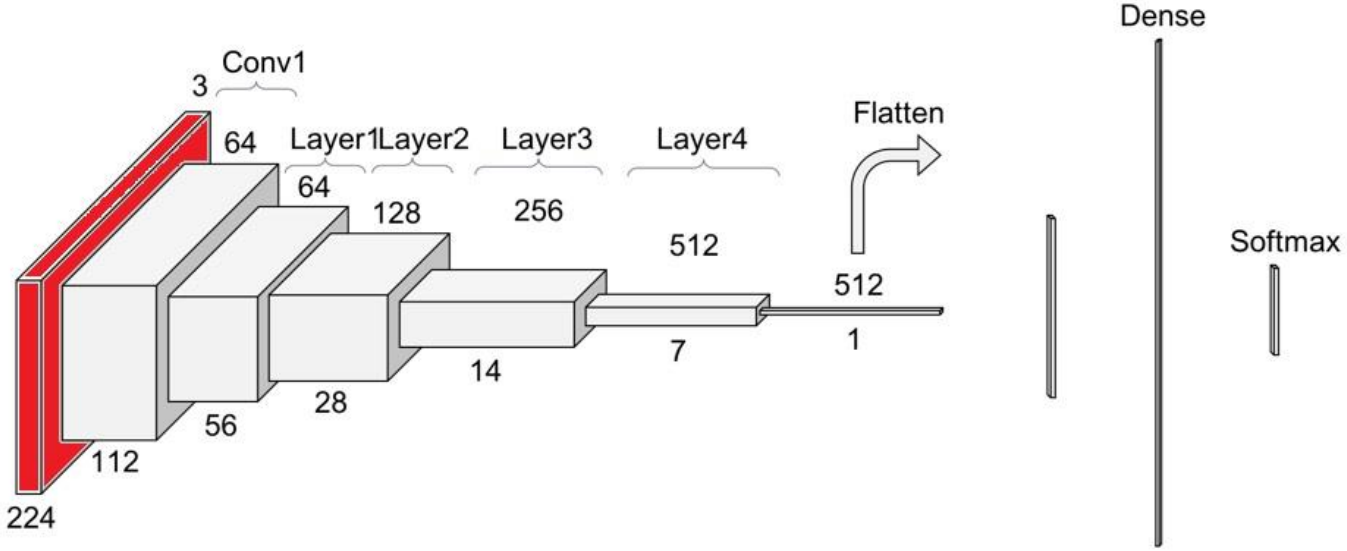

Work in progress

- BigEarthNet-es modellekhez a 10 színcsatorna optimális felhasználásának kidolgozása.
- Szegmentációs feladatok, modellek feltérképezése. Mérési pipeline beüzemelése.
- Mikroszkópos képeken a szövetfestés intenzitásának rekonstrukciója, fizikai valósághoz közelebbi információ kinyerése.
- Modell feladatok arra, hogy hogyan lehet áthidalni ugyanazon típusú, de különböző statisztikájú adatbázisok közötti különbségeket, azaz egy adott adatbázison tanított modellt optimálisan használni másik adatbázisban.

Publikációk

- Gellért Károlyi, András Lukács: Transfer learning for medical image classfication, Developments in Computer Science, June 17-19, 2021
- Gábor Hidy, András Lukács: Nucleus classification with neural networks, Developments in Computer Science, June 17-19, 2021
- Gellért Károlyi, András Lukács: Transfer learning for BigEathNet, in preparation
- Bernadett Vas, András Lukács: Model performances in Retinopathy, in preparation