

TRANSFER LEARNING AZ ORVOSI KÉPKLASSZIFIKÁCIÓBAN

LUKÁCS ANDRÁS
ELTE MATEMATIKAI INTÉZET
MI KUTATÓCSOPORT

TKP WORKSHOP 2021.06.11.



NEMZETI KUTATÁSI, FEJLESZTÉSI
ÉS INNOVÁCIÓS HIVATAL

AZ INNOVÁCIÓ LENDÜLETE

AZ NKFI ALAPBÓL
MEGVALÓSULÓ
PROJEKT

COVID-19 járvány és MI megoldások

- COVID-19 járvány → számtalan tüdőröntgen (CXR) és CT képeken működő gépi/mély tanulás alapú megoldás
- Ezek jelentős része hibás
- Fő problémák
 - Képek minősége
 - Tanító adathalmazok kis mérete
- Kicsi tanító adathalmazok → transfer learning alkalmazása
- A kutatásban vizsgált témák
 - A transfer learning orvosi képekre való alkalmazása
 - A tanító adathalmaz méretének hatása
 - Az orvosi munkában megjelenő diagnosztikai képek MI alapú elemzésének megalapozása

nature machine intelligence

Analysis | [Open Access](#) | Published: 15 March 2021

Common pitfalls and recommendations for using machine learning to detect and prognosticate for COVID-19 using chest radiographs and CT scans

Michael Roberts , Derek Driggs, Matthew Thorpe, Julian Gilbey, Michael Yeung, Stephan Ursprung, Angelica I. Aviles-Rivero, Christian Etmann, Cathal McCague, Lucian Beer, Jonathan R. Weir-McCall, Zhongzhao Teng, Effrossyni Gkrania-Klotsas, AIX-COVNET, James H. F. Rudd, Evis Sala & Carola-Bibiane Schönlieb

Nature Machine Intelligence **3**, 199–217 (2021) | [Cite this article](#)




AZ INNOVÁCIÓ LENDÜLETE

AZ NKFI ALAPBÓL
MEGVALÓSULÓ
PROJEKT


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



Modellek és tanításuk orvosi képeken

- Orvosi képek
 - Röntgen, CT, ultrahang
 - Endoszkópiás képek
 - Patológia, mikroszkópos képek
- Klasszifikáció (regresszió), szegmentálás
- Speciális domain $\Rightarrow$ hangolni kell a módszereket
- Szempontok
 - Modellválasztás
 - Annotált adathalmaz mérete
 - Transfer learning
 - Augmentáció
 - Előfeldolgozás



Transfer learning röntgenképek esetében

- Van-e hatása az előtanításnak, ha a célfeladat képei nagyon különböznek az előtanítási képektől?
 - Színcsatornák száma
 - Megjóslandó kategóriák száma és jellege
 - Tanító adat diverzitása
- A tanító halmaz mérete hogyan befolyásolja az előtanítás hatását?


CheXpert adathalmaz

- 224316 kép, 14 címke NLP eszközökkel kinyerve
- Címkénként 4 lehetséges érték
 - 1 (van), 0 (nincs), -1 (bizonytalan), blank (nincs információ)

(No Finding)
Enlarged
Cardiomediastinum
Cardiomegaly
Lung Opacity

Lung Lesion
Edema
Consolidation
Pneumonia
Atelectasis


Pneumothorax
Pleural Effusion
Pleural Other
Fracture
Support Devices



Lung Opacity = blank



Lung Opacity = 0







Lung Opacity = 1

Kísérleti komponensek, hiperparaméterek

- Dataset: CheXpert / CXR14
- Image resolution: 256X256 / 512X512
- Task: Lung Opacity / other cat. / all cat. / hierarchical
- **Train size (per category):** 100 / 1000 / 4000 / 16000
- **Model:** VGG16 / ResNet50 / EfficientNetB5 / DenseNet201
- Model top: linear / 128+linear / 512+256+128+64+linear
- Optimizer: CoolMomentum / Adam / SGD
- Base learning rate: 0.1 / 0.01 / 0.001 / **0.0001**
- Learning rate schedule: flat / gradual / sudden
- Batch size: 64 / 16
- Epochs: until convergence (10~100)
- **Pretraining:** ImageNet / CXR / from scratch
- Augmentation: none / crop / flip / rotate

Eredmények



Megállapítások



- A transfer learning segíti az orvosi képelemzést is
- Nagyobb tanító adathalmazzal jobban kihasználható
- Az adatbázisok diverzitásának nagy a jelentősége

További kutatási irányok

- Modellek körének bővítése
 - DensNet, EfficienNet, NF-ResNet, Big Transfer
- Adatbázisok és adatkörök bővítése
 - Adatbázisok közötti transfer learning
 - Patológiás, ill. retinaképek és műholdképek
- Szegmentációs feladatok

Digitális patológia

- Mikroszkóp képek vizsgálata
- CoNSeP adatbázis
 - 41 *whole slide imaging* 16 CRA betegtől
 - 24319, szakértők által annotált sejtmag
 - Átalakítva 32x32 patch-ekké
 - Csak látszólag nagy tanító adathalmaz
- Cél a sejtmagok klasszifikálása



tumour epithelial



endothelial



muscle




fibroblast



healthy epithelial





inflammatory



other


Adatbázisok közötti tanulás modellezése

- Egy slide patch-jei homogénebb adathalmaz
- Kétfajta *train-test* vágás a patch-eken
 - Szokásos véletlen vágás, minden slide-ból jut a *train* és *test* halmazba is
 - Néhány kiválasztott slide-hoz tartozó patch-ek adják a *test* halmaz




Diabéteszes retinopátia detektálása

- Retinaképek vizsgálata
- EyePACS adatbázis
 - 88702 nagy felbontású (433-3456 pixeles) retina kép
 - Diverz, sokféle kamerából
 - 5 címke (0 egészséges, 1-3 non-poliferatív, 4-poliferatív)
 - Sok képnek gyenge a minősége
 - Sok hibás annotálás
- Cél: SOTA mélyhálós modellek





egészséges (0)




poliferatív (4)

BigEarthNet adathalmaz


- 10 színcsatorna
- 19 címke
- Cél: egy vagy több SOTA mély háló műholdfelvételeken használható transfer learningre




B2




B3




B4




B5




B6




B7




B8




B8a



B11



B12





Kérdések?