




**PROCESAREA IMAGINILOR MEDICALE DE  
TIP CT PENTRU IDENTIFICAREA SI  
EVALUAREA AFECTĂRII PULMONARĂ  
DATORATE COVID19 UTILIZÂND ANALIZA  
FRACTALA SI TEHNICI DE INTELIGENȚĂ  
ARTIFICIALĂ**

Lucian Mihai ITU  
Irina-Andra Tache




- În contextul evoluției pandemiei COVID19 din martie 2020, care a afectat peste 229 țări și teritorii din lume până în prezent, eforturile sunt îndreptate atât spre actualizarea ghidurilor de practică medicală, cât și spre dezvoltarea unor instrumente statistice, care monitorizează dinamica epidemiei în timp real.
- Absența unui tratament curativ a avut un impact global fără precedent, datorat necesarului ridicat de îngrijiri medicale în secțiile de terapie intensivă, de suport respirator și ventilație mecanică, de resurse umane și materiale, ce a impus reorganizarea sistemului public de sănătate.
- Pentru partea de diagnoză și predicție a evoluției bolii au fost dezvoltate și implementate soluții în clinicile de specialitate care utilizează tehnici de învățare automată, dar eforturile de îmbunătățire încă continuă.

◦ Tehnicile de învățare profundă au un impact ridicat în prezent, fiind intens utilizate, cu rezultate foarte bune în procesarea imaginilor medicale. Aplicațiile acestui domeniu în procesarea scanărilor de tip CT pulmonare sunt:

- clasificarea imaginilor pacienților cu aspect pulmonar normal și cei afectați de COVID19, precum în (Ahuja et al, 2021) cu o acuratețe de 99.4% folosind strategia de transfer de cunoștințe având ca rețea preantrenată Resnet18 și în (Rahimzadeh et al, 2021) cu acuratețe de 98.49% folosind rețeaua Resnet50V2,
- diferențierea între diversele tipurile de pneumonie și COVID19, precum în (Yan et al, 2020) care a reușit o acuratețe de 87.5% pentru care se folosește o rețea neuronală convoluțională multi-scalară,
- segmentarea semantică și localizarea bolii COVID19 (Karthik et al, 2022).

- Principiul de învățare prin transfer de cunoștințe este acela de a ajusta ultimele straturi din rețeaua neuronală convoluțională preantrenată pe setul de imagini ImageNet. Straturile preantrenate își conservă ponderile în vederea utilizării lor în etapa de extragere a caracteristicilor generale ale obiectelor.
- Strategia de înlocuire a straturilor superioare ale rețelei presupune reantrenarea ultimului strat convoluțional sau a celui complet conectat și, în final, a celui de clasificare care trebuie adaptat problemei studiate. Procesul de reantrenare a rețelei neuronale se face cu noul set de imagini, cu scopul detectării caracteristicilor particulare ale obiectelor de interes.




Baza de date cu imagini a fost colectată în principal din resurse disponibile online în comunitatea Kaggle<sup>1</sup> și îmbunătățită cu datele colectate de la 10 de pacienți depistați cu COVID-19 și alți 45 având aspect normal, de la un spital clinic din România în anul 2020.

### **Date preliminare**

Date colectate de la spital  
(55 de pacienți)

Date colectate din baze de  
date online (118 de  
pacienți )


Total 173 pacienti, 7300  
imagini



a) Samples of COVID-19 CT scans for mild stage



b) Samples of COVID-19 CT scans for moderate stage



c) Samples of COVID-19 CT scans for normal stage



d) Samples of COVID-19 CT scans for severe stage

Un algoritm de învățare supervizată aplicat imaginilor de tip CT cu proiecția axială a toracelui a fost dezvoltat în (Tache et al, 2023) pentru a realiza clasificarea imaginilor în 4 clase, plămâni cu aspect pulmonar normal și cele 3 faze asociate evoluției bolii COVID19.

Setul de date de testare cuprinde date diferite de setul de antrenare și de validare, reprezentând 20% din totalul imaginilor. Evaluarea procesului de antrenare s-a făcut conform strategiei de transfer de cunoștințe pentru rețeaua Resnet50, datorită performanțelor ei superioare, cu o acuratețe de 86.89%, specificitate de 96%, sensibilitate de 80% și precizie de 81%.

No.	Hyperparameter	Value
1	Algorithm Type	Adam
2	No. of Epochs	30
3	Learn-Rate Schedule	piecewise
4	Learn-Rate Drop Factor	0.2
5	Learn-Rate Drop Period	5
6	Mini-Batch Size	32
7	Initial Learn Rate	$10^{-4}$
8	Validation Frequency	40
9	Validation Patience	15
10	Shuffle	Every epoch

# Rezultate

Training Network	Accuracy (%)	Recall	Specificity	Precision	False Positive Rate	F1 Score	Matthews' Correlation Coefficient	Cohen's Kappa Coefficient
Resnet 50	86.89 (86.01,87.19)	0.8 (0.79,0.82)	0.96 (0.96,0.96)	0.81 (0.78,0.81)	0.04 (0.04,0.04)	0.79 (0.78,0.8)	0.76 (0.74,0.77)	0.65 (0.63,0.66)
Inceptionv3	85.99 (82.11,86.97)	0.78 (0.72,0.8)	0.96 (0.95,0.96)	0.8 (0.75,0.82)	0.04 (0.04,0.05)	0.77 (0.71,0.8)	0.74 (0.68,0.77)	0.63 (0.52,0.65)
Googlenet	83.4 (82.4,84.54)	0.76 (0.74,0.77)	0.95 (0.95,0.95)	0.78 (0.77,0.79)	0.05 (0.05,0.05)	0.74 (0.72,0.76)	0.71 (0.69,0.73)	0.56 (0.53,0.59)
Mobilenetv2	84.15 (83.65,86.75)	0.76 (0.74,0.81)	0.95 (0.95,0.96)	0.77 (0.76,0.8)	0.05 (0.04,0.05)	0.75 (0.74,0.8)	0.71 (0.7,0.76)	0.58 (0.56,0.65)
Squeezenet	85.71 (84.17,87.78)	0.79 (0.76,0.81)	0.96 (0.95,0.96)	0.79 (0.77,0.82)	0.04 (0.04,0.05)	0.78 (0.75,0.81)	0.75 (0.72,0.78)	0.62 (0.58,0.67)
Shufflenet	80.65 (80.04,80.65)	0.73 (0.71,0.73)	0.94 (0.94,0.94)	0.73 (0.72,0.73)	0.06 (0.06,0.06)	0.69 (0.68,0.69)	0.66 (0.65,0.66)	0.48 (0.47,0.48)



# Diseminare

Irina Andra Tache, REVIEW OF BLOOD VESSELS VELOCITY ESTIMATIONS, Seria Analele Academiei Oamenilor de știință din România despre Știință și Tehnologie și Informație Online ISSN 2066 - 8562 Volumul 14, Numărul 1-2/2021

Irina Andra TACHE , Lucian Mihai ITU , Severus Constantin OLTEANU, Lung damage identification due to COVID19 from CT scans, Conferinta nationala de toamna AOSR, noiembrie 2022

Irina Andra Tache, Dimitris Glotsos , Silviu Stanciu Classification of Pulmonary Damage Stages Cause by COVID-19 Disease from CT scans via Transfer Learning, Bioengineering MDPI, 2023, 10, 6, Q2 IF 5.046

Irina Andra TACHE , Lucian Mihai ITU , Identificarea afectării pulmonare datorate COVID19 din imagini medicale de tip CT, Conferinta nationala de primavara AOSR, mai 2023