



**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

- Pandemia COVID-19 a produs schimbări sociale și economice care încă ne afectează viețile. Coronavirusul este un virus proinflamator, ce se reproduce și se răspândește rapid.
- Cel mai afectat organ este plămânul, iar evoluția bolii poate degenera galopat.
- Etapele leziunilor pulmonare cauzate de această boală sunt împărțite în ușoară, moderată și severă. Faza moderată are aspecte similare cu pneumonia, în timp ce faza severă este greu de distins de cancerul pulmonar. Dacă pacientul cu aspecte usoare ale plămânului nu este tratat corect încă de la început, boala poate evolua rapid în stadii ulterioare și poate provoca chiar moartea la pacienții cu comorbidități.



PCR Test




CT scan



X-ray
radiography



- O metodă automată de a detecta gradul de severitate a leziunii pulmonare a bolii pentru pacienții care au fost supuși investigației tomografiei computerizate poate îmbunătăți protocolul clinic.
- Baza de date cu imagini a fost colectată în principal din resurse disponibile online în comunitatea Kaggle și îmbunătățită cu datele colectate de la 55 de pacienți cu COVID-19 și normali de la un spital clinic.
- Învățarea prin transfer de cunoștințe este folosită pentru a rezolva această problemă în principal pentru că rezultatul se obține cu un timp de calcul scăzut.



Date preliminare

- Date colectate de la spital (55 de pacienți)
- Date colectate din baze de date online (118 de pacienți)

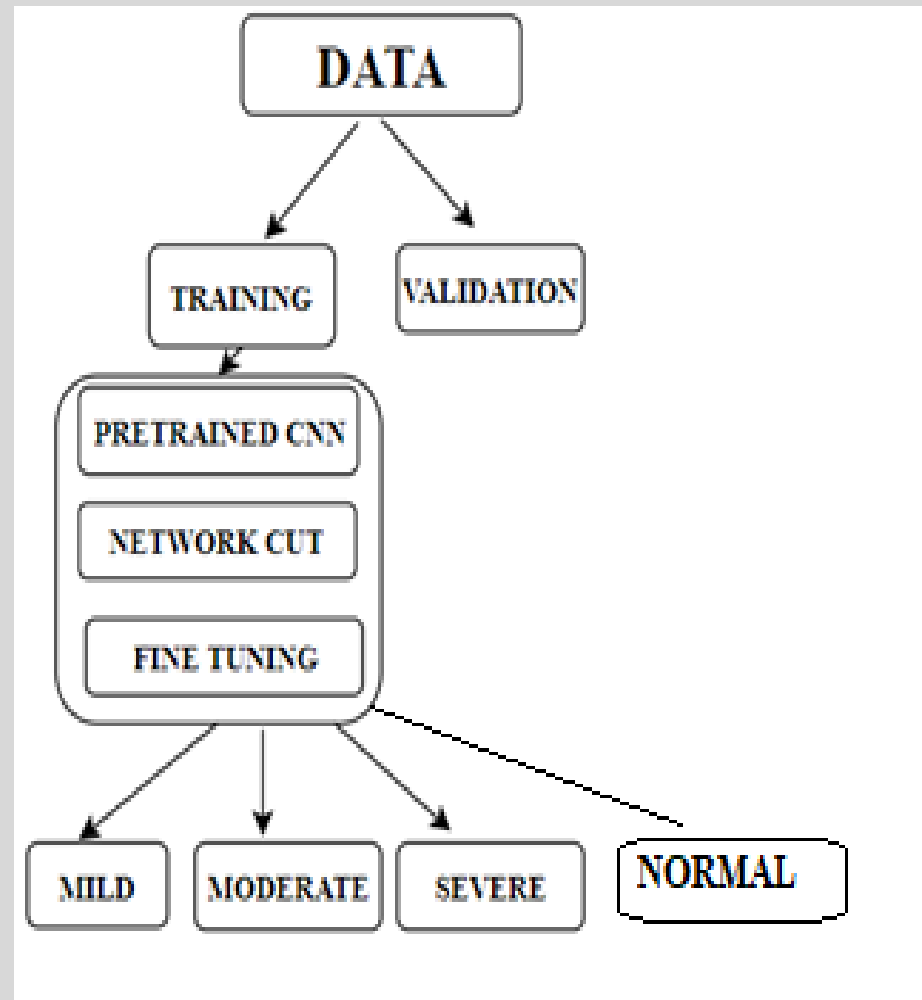
Table 1. Parameters of CT acquisition

Parameters	Unit	Values
Exposure Time	[ms]	600
Tube Current	[mA]	106
Color Type	-	grayscale
Bit Depth	-	12
Intensifier Size	[mm]	250
Image Width	[pixels]	512
Image Height	[pixels]	512
Number of frames per series	[frames]	200
Number of series per patient	-	10

- Tehnicile de inteligență artificială au un impact uriaș în prezent fiind utilizate intens în procesarea imaginilor medicale. Acest lucru i-a încurajat pe oamenii de știință să colecteze imagini medicale obținute din diverse centre medicale pentru a crea modele de învățare cu un grad ridicat de generalizare.
- Succesul tehnicilor de învățare profundă în diferite sarcini de calcul de nivel înalt, cum ar fi clasificarea imaginilor sau detectarea obiectelor, în special abordările supervizate (cum ar fi rețelele neuronale convoluționale, CNN), au motivat cercetătorii să exploreze comportamentul acestor metode atunci când etichetarea se face la nivelul pixelului (segmentare semantică).
- Principalul avantaj al acestor tehnici de învățare profundă, în comparație cu metodele tradiționale de segmentare, este capacitatea de a găsi cea mai bună reprezentare, cei mai adecvați descriptori, într-un mod direct și automat, eliminând astfel necesitatea determinării lor manuale. Dar dezavantajele lor sunt cantitatea mare de date necesară, care este direct proporțională cu performanța obținută și lipsa interpretabilității modelului.

- În domeniul medical, datele nu sunt ușor de colectat, din cauza politicilor de confidențialitate ale pacientului. Prin urmare, pentru a crește cantitatea de date, pot fi implementate unele strategii, una este augmentarea datelor care aplică transformări asupra datelor brute precum translația, rotația, reflectarea etc. și cealaltă este construirea unui set de date artificial, care seamănă cu date inițiale.

- Principiul de învățare prin transfer de cunoștințe este de a folosi CNN-urile predefinite antrenate pe mii de imagini stocate în baza de date ImageNet pentru a extrage caracteristicile generale ale obiectelor prin conservarea ponderilor straturilor rețelei.
- Strategia de tăiere a rețelei va înlocui straturile finale cu cel puțin un nou strat convoluțional și cu unul de clasificare adaptat problemei de clasificare. Se începe apoi procesul de reantrenare a noului CNN cu noul set de date de imagini pentru detectarea caracteristicilor particulare ale obiectelor.




- 9 CNN pre-instruite (Inceptionv3, Resnet101, Resnet50, Resnet18, Alexnet , Nasnetmobile , Shufflenet , Googlenet , Mobilenetv2) sunt utilizate pentru clasificarea leziunilor pulmonare în 4 (normale, ușoare, moderate și severe).

Table 3. Training options

No.	Hyperparameter	Value
1	Algorithm type	Stochastic gradient descending with momentum optimizer
2	Learn Rate Drop Factor	0.2
3	Learn Rate Drop Period	2
4	Mini Batch Size	32
5	Initial Learn Rate	1e-3
6	Validation Frequency	10
7	Shuffle	Every epoch
8	Iterations per epoch	156

Table 4. The dataset distribution


No. of patients	Mild	Moderate	Normal	Severe
Training	37	37	32	27
Validation	16	16	13	11



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

Table 4 The accuracies of different pre-pretrained network


Training network	No. of epochs	Accuracy (%)
Inceptionv3	4	79.12
	10	81.34
	20	80.21
Resnet50	4	80.9
	10	81.93
	20	80.8
Resnet18	10	77.62
Resnet101	10	77.58
<u>Alexnet</u>	10	75.85
<u>Nasnetmobile</u>	10	79.89
<u>Shufflenet</u>	10	79.94
<u>Googlenet</u>	10	80.75
Mobilenetv2	10	79.44

Table 5. The evaluation metrics for each class when considering 10 epochs

Neural Net	Metrics	Mild (%)	Moderate (%)	Normal (%)	Severe (%)
Inceptionv3	Precision	65.93	35.9	99.09	45.1
	Recall	67.12	21.34	98.67	72.52
Resnet101	Precision	67.26	74.36	97.19	7.56
	Recall	83.98	25.04	99.71	50
Resnet50	Precision	74.34	56.41	100	28.57
	Recall	66.4	28.5	98.62	85.71
Resnet18	Precision	75.22	79.49	96.14	4.2
	Recall	88.54	25.54	100	44.12
<u>Alexnet</u>	Precision	63.27	48.72	99.93	2.52
	Recall	58.61	21.79	97.94	13.04
<u>Nasnetmobile</u>	Precision	67.26	83.08	98.46	12.04
	Recall	78.35	30.74	97.97	86
<u>Shufflenet</u>	Precision	68.58	53.33	100	21.57
	Recall	77.11	24.53	98.07	61.6
<u>Googlenet</u>	Precision	76.99	73.33	99.86	10.92
	Recall	75.65	28.66	99.65	84.78
Mobilenetv2	Precision	65.49	89.74	98.6	6.16
	Recall	94.27	29.17	99.5	64.71



(a)



(b)

Figure. The classification results for (a) severe class (b) moderate class

Diseminare

- Irina Andra Tache, Revizuirea estimărilor vitezei vaselor de sânge, 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 , Clasificarea stadiilor de afectare pulmonară cauzată de boala Covid19 din tomografii, bioinginerie, în curs de revizuire

Bibliografie

- Weiss SR, Leibowitz JL. Patogeneza coronavirusului . *Adv Virus Res* 2011;81:85-164
- S. Kooraki , M. Hosseiny , L. Myers și A. Gholamrezanezhad , „ Foccare de coronavirus (COVID-19): Ce ar trebui să știe Departamentul de Radiologie” , *Jurnalul Colegiului American de Radiologie*, voi. 17, nr. 4, p. 447–451, apr. 2020
- S. Ahuja , BK Panigrahi , N. Dey , V. Rajinikanth și TK Gandhi, „Deep transfer learning-based automated detection of COVID-19 from pulmonar CT scan slices” , *Appl Intel* 51, 571–585 , 2021