

# Segmentarea automată a leziunilor din plămâni folosind tehnici de învățare profundă

Vlad-Mihai Vasilescu

Coordonatori:

As. Univ. Drd. Ing. Ana-Antonia Neacșu  
Prof. Univ. Dr. Ing. Corneliu Burileanu

Facultatea de Electromecanică, Telecomunicații și Tehnologia Informației

9 februarie 2022



# Cuprins

1 Motivație & Obiective

2 Introducere

3 Setup experimental

4 Metode propuse

- Metoda 1
- Metoda 2

5 Rezultate finale & Concluzii

## Motivație & Obiective

# Motivație & Obiective

## Motivație

- Eliminarea necesității de adnotare manuală a zonelor cu leziuni de către specialiști
- Analiza tomografiilor computerizate oferă informații cu privire la progresia diferitelor afecțiuni

# Motivație & Obiective

## Motivație

- Eliminarea necesității de adnotare manuală a zonelor cu leziuni de către specialiști
- Analiza tomografiilor computerizate oferă informații cu privire la progresia diferitelor afecțiuni

## Obiective

- Dezvoltarea unor arhitecturi de rețele neurale pentru segmentarea leziunilor
- Testarea arhitecturilor pe date provenite de la un set relativ mare de pacienți

## Introducere

# Rețele Neurale Artificiale

- Aproximarea funcțiilor de mapare a unor date de intrare către anumite date de ieșire
- Modificarea continuă a ponderilor în vederea obținerii unei modelări cât mai bune

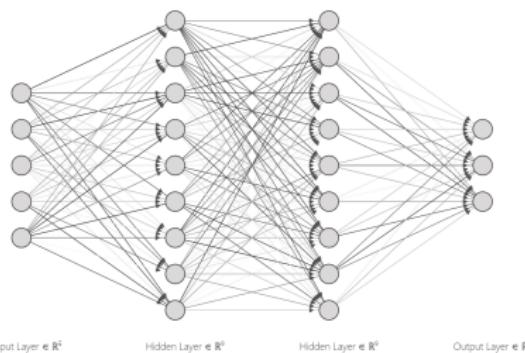
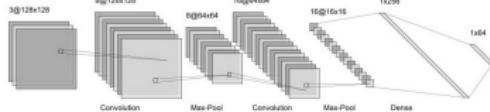


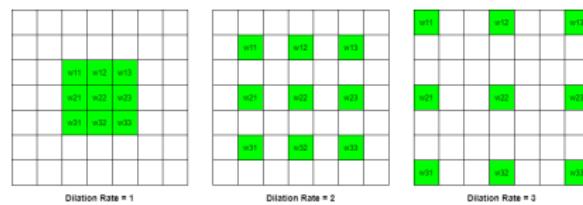
Figura 1: Rețea neurală cu straturi dense

# Rețele Neurale Convoluționale

- Conexiuni locale, invarianță la modificarea poziției obiectelor
- Extragere trăsături – filtrări liniare + funcții de activare neliniare
- Caz particular – convolução dilatătă – creșterea dimensiunii câmpului de recepție fără creșterea numărului de parametrii ai filtrului



(a) Exemplu rețea convoluțională



(b) Efectul factorului de dilatare

# Rețele Generative Adversariale

- Sistem format din 2 rețele neurale distincte – Generator și Discriminator – antrenate într-un mod alternativ
- Modelarea unei distribuții de date de interes – Generator
- Distingerea între exemplele reale și exemple generate – Discriminator

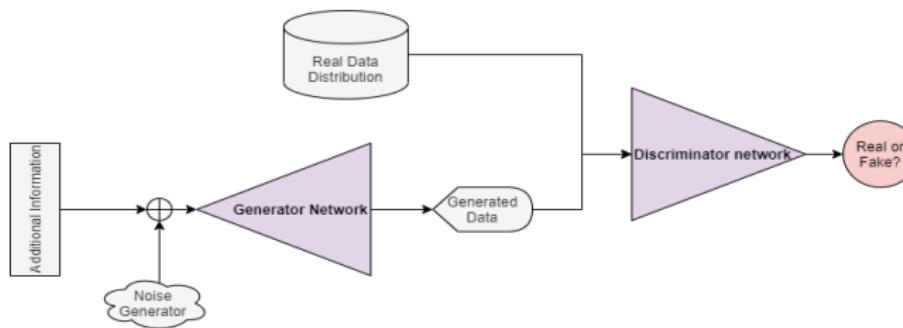


Figura 3: Schemă generală a unui GAN

## Setup experimental

## Baze de date utilizate

- Doar secțiuni transversale ce conțin adnotări ale leziunilor au fost păstrate
- Prima bază de date<sup>1</sup> – 9 pacienți → 373 secțiuni
  - Antrenare – 6 pacienți → 200 secțiuni
  - Validare – 3 pacienți → 173 secțiuni
- Testare – a doua bază de date [1] – 10 pacienți → 1351 secțiuni

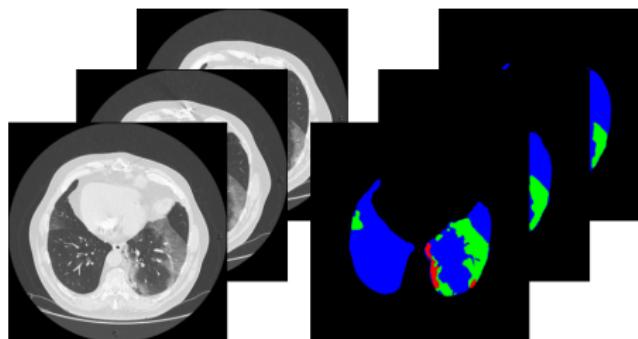


Figura 4: Exemple secțiuni prima bază de date

<sup>1</sup><https://medicalsegmentation.com/covid19/> – Segmentation dataset nr. 2

## Pre-procesarea datelor

- 1 Trunchierea secțiunii  $X^{(i)}$  în intervalul  $[-1000, 1000]$  pe scara Hounsfield:

$$X^{(i)}[l, c] = \begin{cases} 1000, & 1000 < X^{(i)}[l, c] \\ -1000, & X^{(i)}[l, c] < -1000 \\ X^{(i)}[l, c], & -1000 \leq X^{(i)}[l, c] \leq 1000 \end{cases}$$

$$\forall(l, c) \in \{0, 1, \dots, n-1\}^2$$

- 2 Normalizarea secțiunii trunchiate în intervalul  $[0, 1]$ :

$$X^{(i)}[l, c] = \frac{X^{(i)}[l, c] - \min_{0 \leq l, c \leq n-1} X^{(i)}}{\max_{0 \leq l, c \leq n-1} X^{(i)} - \min_{0 \leq l, c \leq n-1} X^{(i)}}$$

- 3 Redimensionarea secțiunii la dimensiunea  $512 \times 512$  folosind *interpolare bilinară*

## Metode propuse

# Arhitectura modelului

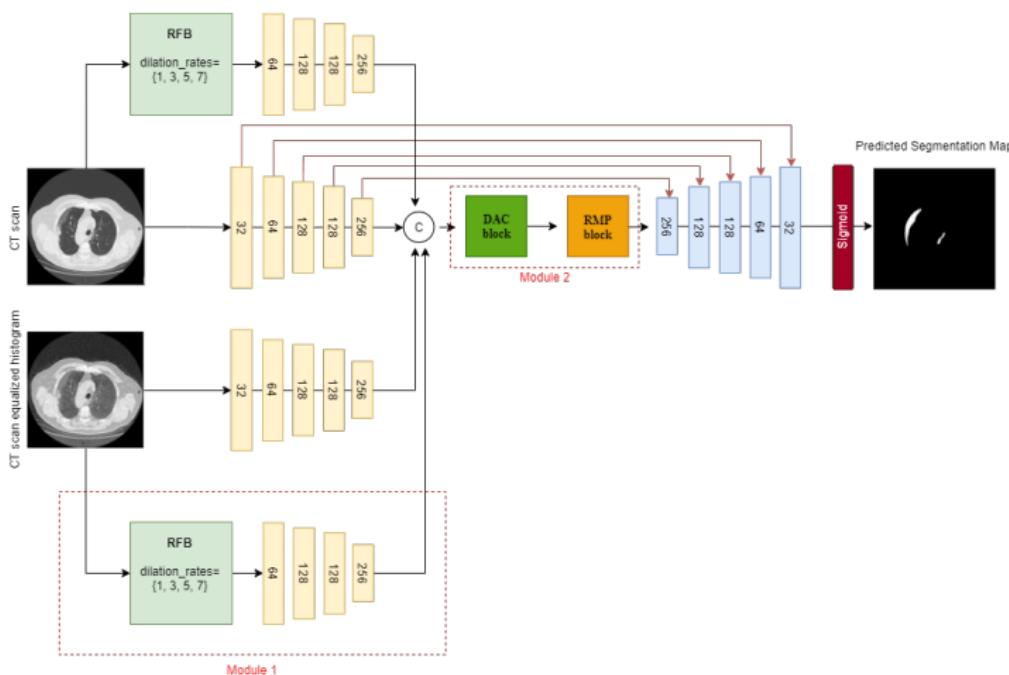


Figura 5: Arhitectura completă

# Arhitectura modelului

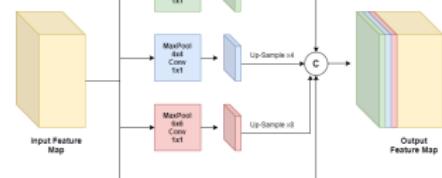
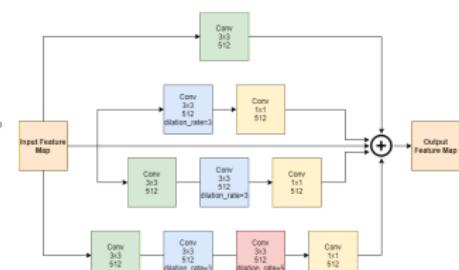
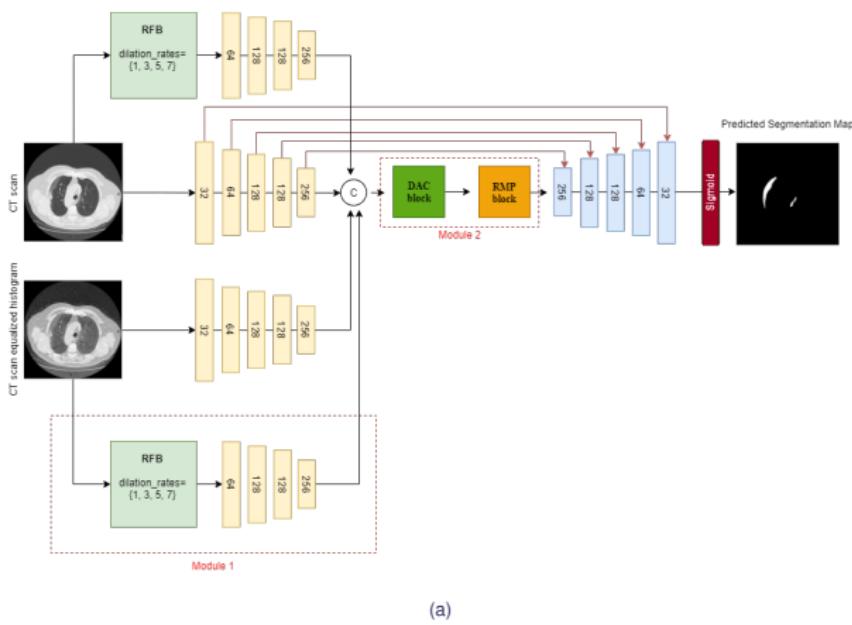


Figura 5: (a) Arhitectura completă (b) Blocul DAC [2] (c) Blocul RMP [2]

# Rezultate experimentale

- Funcția de cost utilizată:

$$\mathcal{L}_{Dice} = \frac{1}{N_b} \sum_{i=1}^{N_b} 1 - DSC(Y^{(i)}, \hat{Y}^{(i)}) \quad (1)$$

$$DSC(Y^{(i)}, \hat{Y}^{(i)}) = \frac{2|Y^{(i)} \cdot \hat{Y}^{(i)}|}{|(Y^{(i)})^2| + |(\hat{Y}^{(i)})^2| + \epsilon} \quad (2)$$

- Optimizator: *Adam*
- Rezultate intermediiare:

	DSC	Senzitivitate	Specificitate	Precizie
<b>A1</b>	0.515	0.495	0.995	0.564
<b>A1+M1</b>	0.665	0.802	0.996	0.608
<b>A1+M1+M2+conex.</b>	0.707	0.803	0.996	0.671

Tabela 1: Performantele primei arhitecturii pe setul de validare; M1 - Modulul 1 (RFB[3] pe histograma egalizată); M2 - Modulul 2 (DAC + RMP);

# Rezultate experimentale

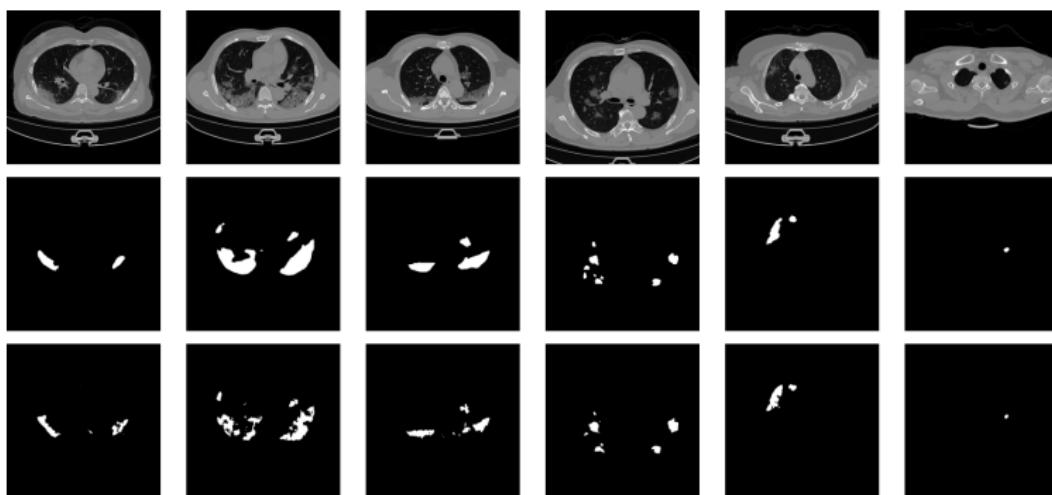


Figura 6: Rezultate experimentale pe setul de test; Primul rând – secțiunile de tomografie de la intrare; Al doilea rând – măștile de segmentare reale; Al treilea rând – măștile de segmentare prezise

# Arhitectura modelului

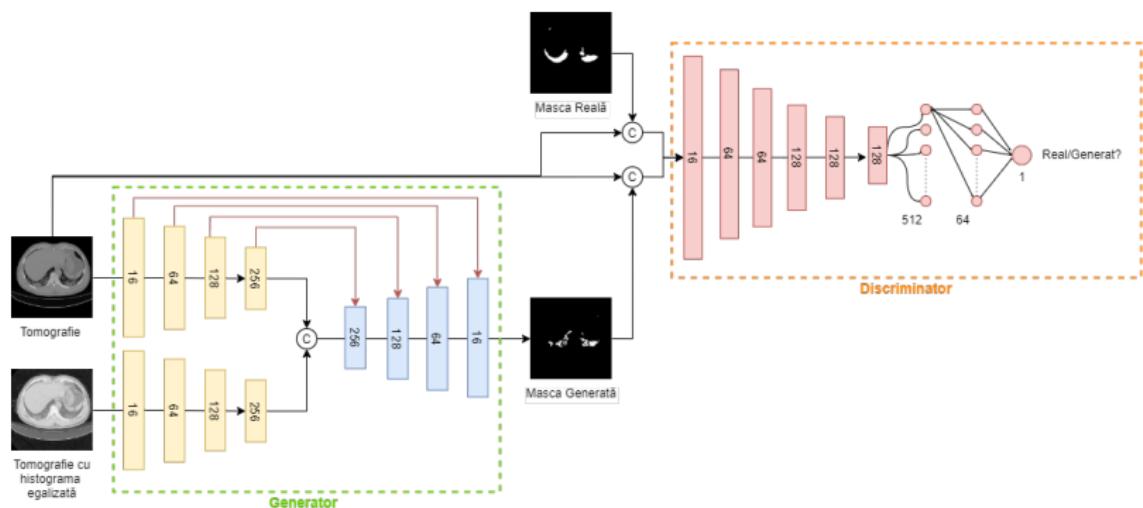


Figura 7: Arhitectura modelului A2

# Rezultate experimentale

- $D(x, y)$ ,  $G(x)$  – funcțiile determinate de structura și parametrii Discriminatorului și Generatorului;  $X^{(i)}$  – secțiune de tomografie;  $Y^{(i)}$  – masca de segmentare reală
- Funcțiile de cost utilizate:

$$\mathcal{L}_D = \frac{1}{B} \sum_{i=1}^B (0.8 - D(X^{(i)}, Y^{(i)}))^2 + (0.2 - D(X^{(i)}, G(X^{(i)})))^2 \quad (3)$$

$$\mathcal{L}_G = \frac{1}{B} \sum_{i=1}^B \underbrace{(1 - DSC(Y^{(i)}, G(X^{(i)})))}_{\text{eroare locală}} + \lambda \underbrace{(0.8 - D(X^{(i)}, G(X^{(i)})))^2}_{\text{eroare Discriminator}} \quad (4)$$

- Optimizator: *Adagrad*
- Pentru același *batch* de date: 1 optimizare pe Discriminator, 3 optimizări pe Generator

# Post-procesarea rezultatelor

- Filtrul bilateral:

$$A_{filtrat}(x, y) = \frac{1}{F_n} \sum_{(i,j) \in V_{xy}} A(x+i, y+j) \exp \left( -\underbrace{\frac{i^2 + j^2}{2\sigma_d^2}}_{\text{distanță}} - \underbrace{\frac{(A(x, y) - A(x+i, y+j))^2}{2\sigma_i^2}}_{\text{diferență intensitate}} \right) \quad (5)$$

$$F_n = \sum_{(i,j) \in V_{xy}} \exp \left( -\frac{i^2 + j^2}{2\sigma_d^2} - \frac{(A(x, y) - A(x+i, y+j))^2}{2\sigma_i^2} \right) \quad (6)$$

- Operații de morfologie matematică – pe mulțimi (imagini) binare:

- Erodare – reducerea dimensiunii obiectelor
- Dilatare – creșterea dimensiunii obiectelor
- Deschidere – Erodare + Dilatare
- Închidere – Dilatare + Erodare

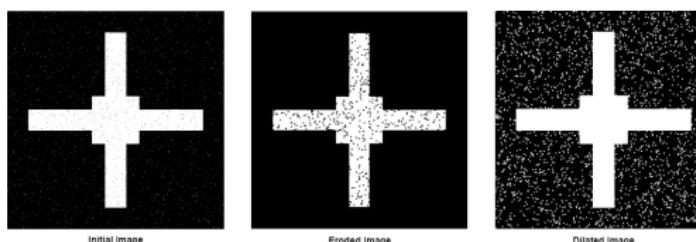


Figura 8: Exemplu de erodare și dilatare

# Post-procesarea rezultatelor

- Filtrul bilateral:

$$A_{filtrat}(x, y) = \frac{1}{F_n} \sum_{(i,j) \in V_{xy}} A(x+i, y+j) \exp \left( -\underbrace{\frac{i^2 + j^2}{2\sigma_d^2}}_{\text{distanță}} - \underbrace{\frac{(A(x, y) - A(x+i, y+j))^2}{2\sigma_I^2}}_{\text{diferență intensitate}} \right) \quad (5)$$

$$F_n = \sum_{(i,j) \in V_{xy}} \exp \left( -\frac{i^2 + j^2}{2\sigma_d^2} - \frac{(A(x, y) - A(x+i, y+j))^2}{2\sigma_I^2} \right) \quad (6)$$

- Operații de morfologie matematică – pe multimi (imagini) binare:

- Erodare – reducerea dimensiunii obiectelor
- Dilatare – creșterea dimensiunii obiectelor
- Deschidere – Erodare + Dilatare
- Închidere – Dilatare + Erodare

	DSC	Senzitivitate	Specificitate	Precizie
<b>A2</b>	0.531	0.685	0.994	0.472
<b>A2+B.F.</b>	0.553	<b>0.722</b>	0.993	0.486
<b>A2+Op_9</b>	0.561	0.605	0.996	<b>0.592</b>
<b>A2+Op_7</b>	0.567	0.639	0.995	0.565
<b>A2+Op_7+Cls_7</b>	<b>0.570</b>	0.649	0.996	0.566

Tabela 2: Performanțele obținute pe setul de validare, folosind diferite metode de post-procesare; B.F. - filtru bilateral; Op\_N/Cls\_N - deschidere/închidere morfologică folosind un element structurant de dimensiune N × N

## Post-procesarea rezultatelor

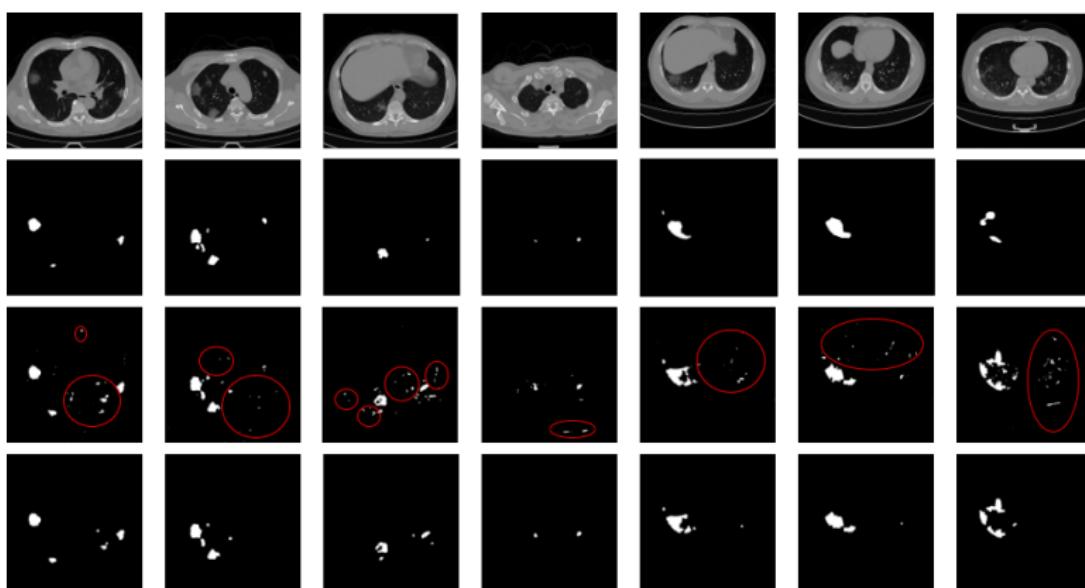


Figura 8: Rezultate experimentale pe setul de test; Primul rând — secțiunile de tomografie de la intrare; Al 2-lea rând — măștile de segmentare reale; Al 3-lea rând — măștile de segmentare prezise pe care au fost evidențiate zone cu probleme; Al 4-lea rând — măștile prezise pe care a fost aplicată operația de deschidere, urmată de operația de închidere

## Rezultate finale & Concluzii

# Rezultate finale

	DSC		Senzitivitate		Specificitate		Precizie	
	Val	Test	Val	Test	Val	Test	Val	Test
<b>U-Net[5]</b>	0.492	0.446	0.456	0.416	0.996	0.998	0.657	<b>0.696</b>
<b>Inf-Net[4]</b>	<b>0.664</b>	0.428	0.674	0.431	0.997	0.997	<b>0.789</b>	0.634
<b>A1+M1+M2+conex.</b>	<b>0.707</b>	0.516	<b>0.803</b>	0.525	0.996	0.998	<b>0.671</b>	<b>0.685</b>
<b>Generator</b>	0.338	0.497	0.354	0.463	0.996	0.996	0.456	0.662
<b>Generator + Discriminator (A2)</b>	0.531	0.538	0.685	<b>0.661</b>	0.994	0.993	0.472	0.511
<b>A2 + B.F.</b>	0.553	<b>0.556</b>	<b>0.722</b>	<b>0.693</b>	0.993	0.993	0.486	0.523
<b>A2 + Op_7 + Cls_7</b>	0.570	<b>0.562</b>	0.649	0.593	0.995	0.995	0.565	0.618

Tabela 3: Compararea performanțelor arhitecturilor pe seturile de validare și testare

## Contribuții personale

- Design-ul și implementarea arhitecturilor prezentate
- Modificarea continuă a arhitecturilor în vederea obținerii unor performanțe cât mai bune
- Definirea procesului de antrenare – alegerea funcțiilor de cost, modul de împărțire al datelor de intrare, modul de antrenare alternativă pentru cele 2 rețele aferente celei de-a 2-a metode
- Alegerea metodelor de post-procesare în vederea îmbunătățirii rezultatelor

## Dezvoltări ulterioare

- Extinderea modelelor pentru segmentarea directă a întreg volumului de tomografii
- Clasificarea zonelor de leziuni segmentate în diferite tipuri de leziuni
- Antrenarea unor structuri de tip GAN mai complexe
- Antrenarea arhitecturilor într-un mod semi-supervizat

# Referințe

-  Ma Jun and Ge Cheng and Wang Yixin and An Xingle and Gao Jiantao and co.  
**COVID-19 CT Lung and Infection Segmentation**  
<https://doi.org/10.5281/zenodo.3757476>, doi: 10.5281/zenodo.3757476, 2020
-  Gu, Zaiwang and Cheng, Jun and Fu, Huazhu and Zhou, Kang and Hao, Huaying and Zhao, Yitian and Zhang, Tianyang and Gao, Shenghua and Liu, Jiang  
**Ce-net: Context encoder network for 2d medical image segmentation**  
*IEEE transactions on medical imaging*, vol 38, no 10, pp 2281–2292, 2019
-  Liu, Songtao and Huang, Di and others  
**Receptive field block net for accurate and fast object detection**  
Proceedings of the European Conference on Computer Vision (ECCV), pp 385–400, 2018
-  Fan Deng-Ping and Zhou Tao and Ji Ge-Peng and Zhou Yi and Chen Geng and Fu Huazhu and Shen Jianbing and Shao Ling  
**Inf-net: Automatic covid-19 lung infection segmentation from ct images**  
in *IEEE Transactions on Medical Imaging*, vol. 39, no.8, pp. 2626–2637, 2020
-  Ronneberger Olaf and Fischer Philipp and Brox Thomas  
**U-net: Convolutional networks for biomedical image segmentation**  
in *International Conference on Medical image computing and computer-assisted intervention*, pp. 234 – 241, 2015

Vă mulțumesc!

---