



Sesiunea stiintifica AOSR TEAMS 2024-2025

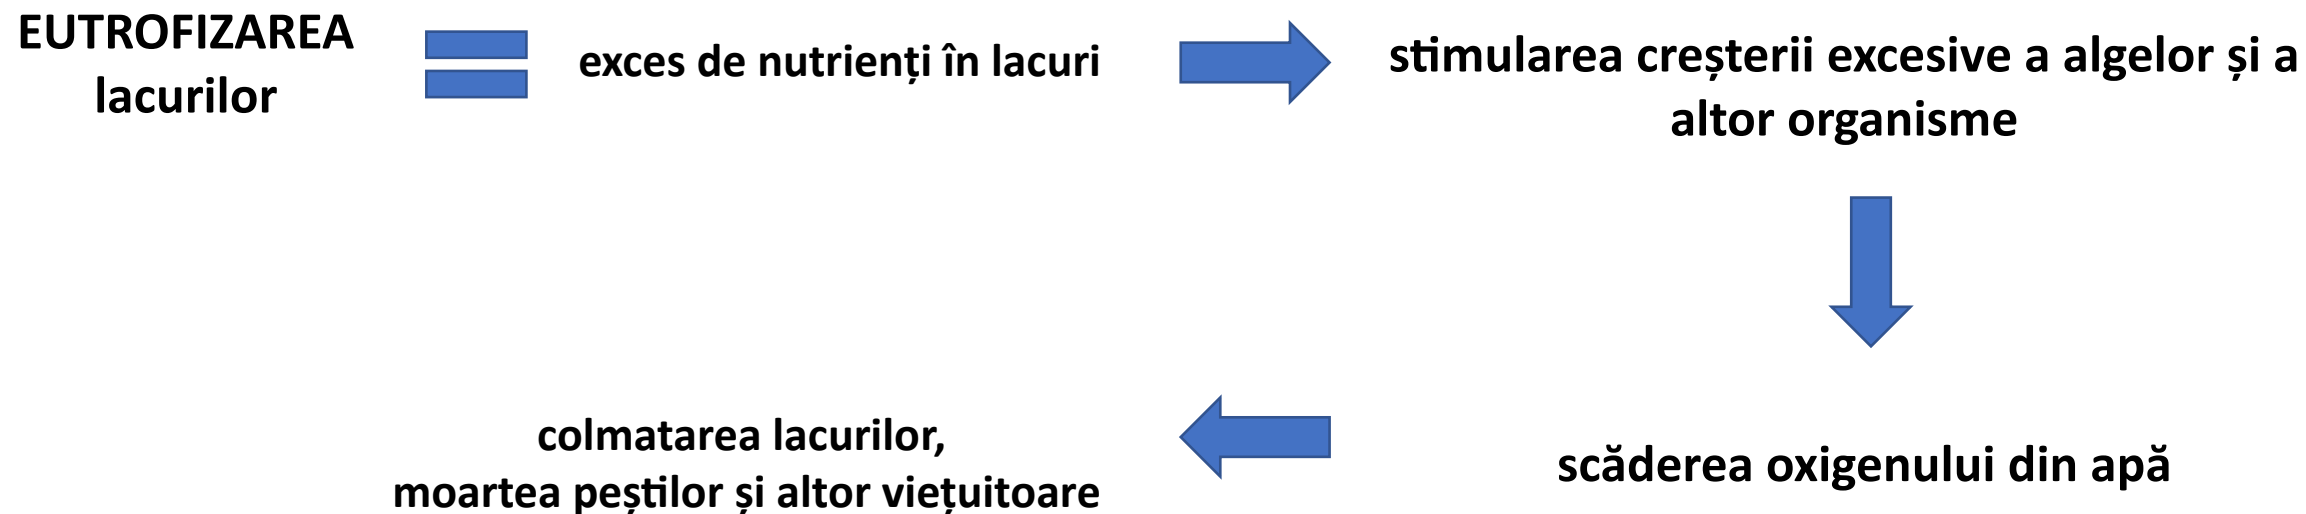


Monitorizarea eutrofizării din Delta Dunării pe baza algoritmilor de tip deep learning

Sabin Rotaru¹ , Andrei Toma¹

¹INCD GeoEcoMar, Bucuresti, Romania





- Dezvoltarea unui model de monitorizare a eutrofizării lacurilor din Delta Dunării, folosind soluții de inteligență artificială de tip deep learning, poate avea un impact semnificativ în protejarea și conservarea mediului înconjurător, asigurând o abordare sustenabilă pentru dezvoltarea regiunii și menținerea unei economii performante.

OBIECTIVE

- O1. Dezvoltarea unui model de monitorizare a eutrofizării lacurilor din Delta Dunării folosind soluții de inteligență artificială de tip deep learning pe baza imaginilor satelitare și a datelor recente *in situ*.**
- O2. Evaluarea acurateții modelului dezvoltat prin aplicarea acestuia pe lacurile Deltei Dunării și analizarea schimbărilor la scara decadală ale parametrilor eutrofizării.**
- O3. Evaluarea capacității de scalare a modelului prin aplicarea acestuia la medii deltaice similare**
- O4. Crearea unei baza de date cu modelul dezvoltat și cu rezultatele de monitorizare a eutrofizării obținute în urma rulării acestuia**

METODOLOGIE

1. Achiziția datelor satelitare

Sentinel-2

- **Platformă:** Sentinel Hub, Copernicus Open Access Hub, Google Earth Engine (GEE)
- **Produce:** Nivel-1C (Reflecție TOA) sau Nivel-2A (Reflecție la suprafață)
- **Benzi:** B2 (Albastru), B3 (Verde), B4 (Roșu), B8 (NIR), B11 (SWIR1), B12 (SWIR2)

Landsat

- **Platformă:** USGS Earth Explorer, Google Earth Engine (GEE)
- **Produce:** Colecția 1 sau 2 Nivel-1 și Nivel-2
- **Benzi:** Albastru, Verde, Roșu, NIR, SWIR1, SWIR2 (numerele benzilor specifice variază în funcție de versiunea Landsat)

2. Preprocesare

Pași Comuni de Preprocesare:

- **Corecție Atmosferică:** Convertirea reflecției TOA în reflecție la suprafață (utilizarea Sen2Cor pentru Sentinel-2, LEDAPS sau LaSRC pentru Landsat)
- **Mascarea Norilor:** Utilizarea benzilor QA sau algoritmi precum FMask pentru detectarea și mascarea norilor
- **Corecție Geometrică:** Verificarea manuală a fiecărei imagini în parte pentru a vedea dacă sunt georeferențiate corect
- **Reeșantionare:** Reeșantionarea la o rezoluție spațială comună (de exemplu, 10m pentru Sentinel-2, 30m pentru Landsat)

3. Analiza datelor

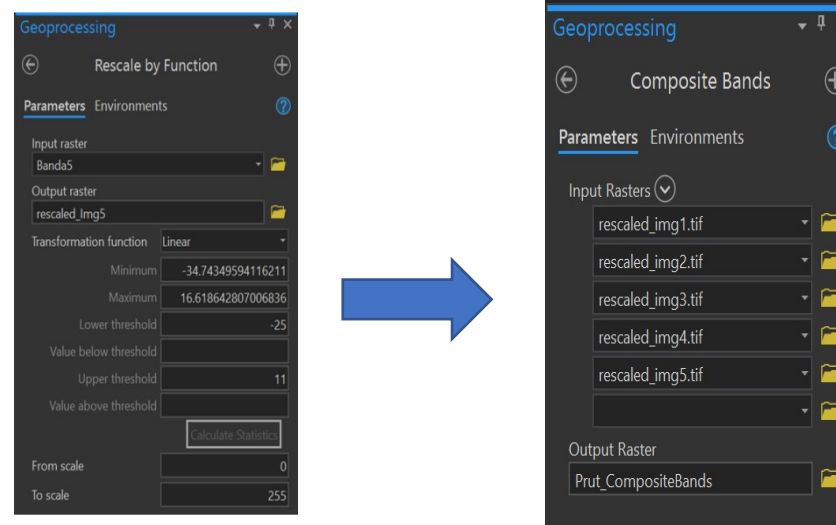
Indicatorii de Eutrofizare:

- **Estimarea Clorofilei-a:** Utilizarea de indici spectrali precum NDVI, EVI și algoritmi special dezvoltați pentru estimarea clorofilei-a
- **Turbiditate:** Derivată din benzile NIR și Roșu, folosind algoritmi precum TSM (Material Suspendat Total)
- **Detecția Înfloririi Algelor:** Utilizarea de indici specifici precum Indexul de Alge Plutitoare (FAI), Indexul de Vegetație Normalizat (NDVI)


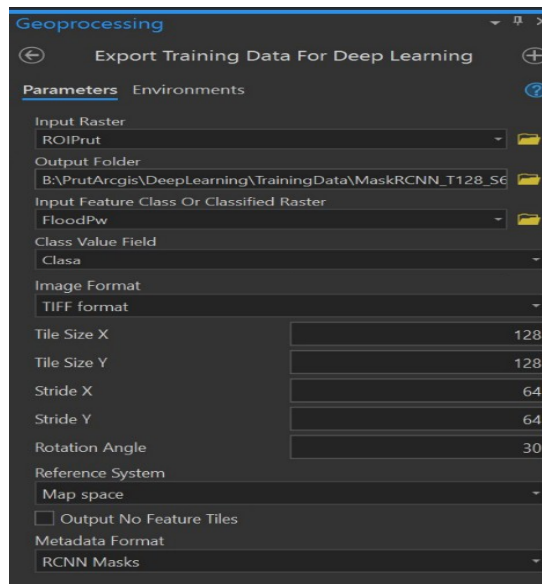
Indici Spectrali:

- **NDVI:** $(NIR - Roșu) / (NIR + Roșu)$
 - **EVI:** $2.5 * ((NIR - Roșu) / (NIR + 6 * Roșu - 7.5 * Albastru + 1))$
 - **FAI:** $(NIR - (Roșu + (SWIR1 - Roșu) * (NIR - Roșu) / (SWIR1 - Roșu))) / (NIR - (Roșu + (SWIR1 - Roșu) * (NIR - Roșu) / (SWIR1 - Roșu)))$
- **Integrarea rezultatelor obținute din acești indicatori într-un model de Deep Learning (U-Net).**

4. Standardizarea imaginilor obținute – metoda de filtrare a valorilor benzilor și compunerea unui pachet singular



5. Eșantionarea imaginilor și augmentarea datelor



Machine Learning și Deep Learning

Inteligența artificială utilizează algoritmi matematici care permit computerelor să memoreze tipare și să recreeze anumite procese. Învățarea automată este un mod analitic de rezolvare a problemelor prin **identificare, clasificare sau predicție**. Algoritmii învață din datele introduse și apoi folosesc aceste cunoștințe pentru analizarea unor date complet necunoscute.

Modelele **Machine Learning și Deep Learning** pot fi descrise drept algoritmi automatizați care încearcă să imite felul în care oamenii se raportează la obiecte.


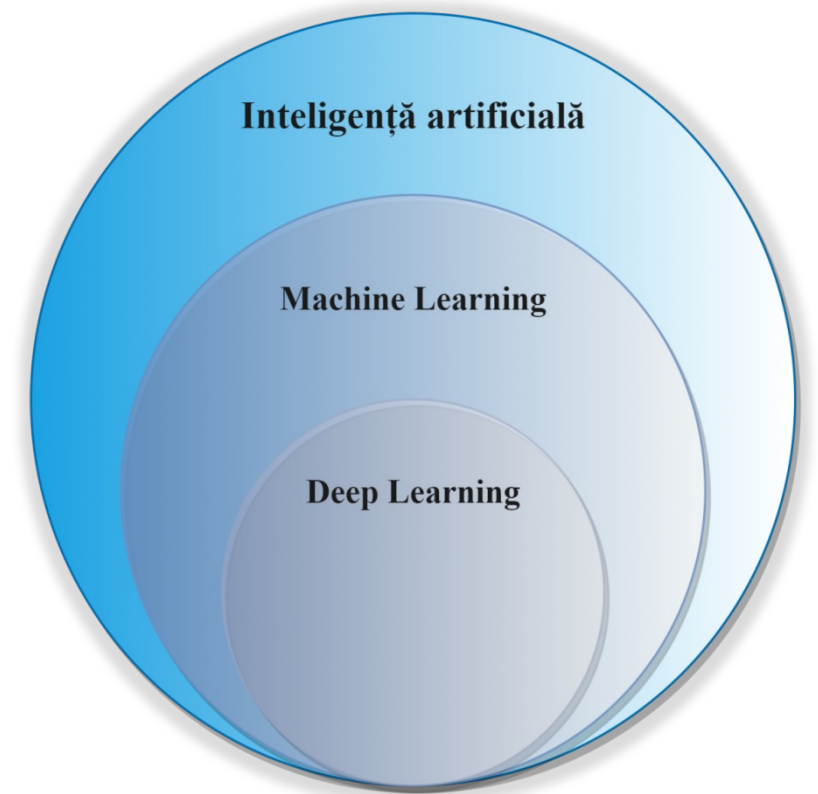
Cei mai cunoscuți algoritmi de Machine Learning sunt:

- Random Forest (*utilizează arbori de decizie*)
- Support Vector Machine (*transpune datele în hiperplanuri pentru a distinge diferențele*).

Cei mai cunoscuți algoritmi de Deep Learning sunt:

- **U-Net**
- DeepLabV3
- Mask R-Cnn

Utilizează rețele neuronale complexe



6. Antrenarea modelului de Deep Learning in ArcGIS Pro, prin Jupyter Notebook

```
File Edit View Insert Cell Kernel Widgets Help Trusted Python [conda env:arcgis-flood-deeplearning] *  
+ ↻ ↺ ↻ ⬆ ⬇ ⬆ ⬇ Run ⏸ ⏪ ⏩ Code
```

```
In [1]: import os  
import arcgis  
from torchvision.models import *
```

```
In [3]: arcgis.__version__  
Out[3]: '1.8.2'
```


```
In [5]: import torch  
torch.__version__  
Out[5]: '1.4.0'
```

```
In [5]: nume_esantion = "MaskRCNN_T128_564_R30_Prut_redus"
```

```
In [6]: training_dataset_path = os.path.join("B:\PrutArcgis\DeepLearning\TrainingData", nume_esantion)
```

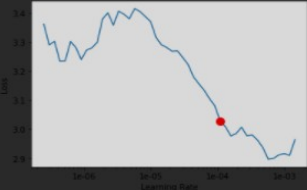
```
In [7]: imagini = arcgis.learn.prepare_data(training_dataset_path,  
batch_size=2,  
chip_size=128,  
dataset_type="RCNN_Masks",  
imagery_type="Fus")  
# class_mapping={1:"Flood", 2:"Permanent water", 3:"Land"}  
Please check your dataset. 6 images dont have the corresponding label files.
```

```
In [9]: imagini.show_batch(rows=1)
```



```
In [8]: model_flood = arcgis.learn.MaskRCNN(imagini, backbone=resnet152)
```

```
In [9]: out_lr = model_flood.lr_find()  
out_lr
```



```
Out[9]: 0.00010964781961431851
```

```
In [10]: model_flood.fit(epochs=10, lr=out_lr, early_stopping=True)
```

epoch	train_loss	valid_loss	time
0	1.714983	1.578086	10:12
1	1.353876	1.352428	10:53
2	1.175212	1.156176	11:38
3	1.037947	1.107754	11:49
4	0.904103	0.975696	12:44
5	0.858006	0.935332	12:50
6	0.721084	0.852204	12:12

Obiective	Activitati	2024								2025											
		Luna 1	Luna 2	Luna 3	Luna 4	Luna 5	Luna 6	Luna 7	Luna 8	Luna 9	Luna 10	Luna 11	Luna 12	Luna 13	Luna 14	Luna 15	Luna 16	Luna 17	Luna 18	Luna 19	Luna 20
O1	A1	█	█																		
	A2			█	█	█	█	█													
	A3								█	█	█	█									
O2	A4											█	█								
	A5													█	█	█	█	█			
O4	A6																			█	█

A1). Crearea bazei de date prin colectarea imaginilor satelitare și a datelor *in situ* de calitate a apei (Luna 1 – Luna 2)
 – **grad de finalizare 100%**

- colectarea a 735 de imagini satelitare Landsat si Sentinel



A2. Pre-procesarea datelor (satelitare și *in situ*), esantionarea lacurilor, și crearea modelului de deep learning prin utilizarea rețelei neurale convoluționale U-Net. (Luna 3 – Luna 7). - **grad de finalizare 10%**

Va multumesc pentru atentie!

CONTACT:

sabin.rotaru@geoecomar.ro

andrei.toma@geoecomar.ro