



# Învățare automată pentru clasificarea particulelor de polen



Chivu Gheorghe-Iulian

Coordonatori științifici:  
Conf. Dr. Ing. Horia Cucu  
Ing. Mihai Boldeanu

*Facultatea de Electronică, Telecomunicații și  
Tehnologia Informației*

Iulie 2021

# Cuprins

- Scopul lucrării
- Baza de date SAU-SRB
- Preprocesarea datelor
- Experimente și rezultate folosind metode clasice de clasificare
- Experimente și rezultate folosind rețele neurale convoluționale
- Sumar rezultate
- Contribuții personale
- Concluzii și dezvoltări viitoare

# Scopul lucrării

- Acuratețea clasificării manuale a polenului = 67% [1]
- Analiza și aplicarea algoritmilor de clasificare ce pot fi utilizați pentru clasificarea automată a polenului:
  - Algoritmi de clasificare clasici:
    - Bayes naiv
    - Cei mai apropiați k vecini
    - Proces gaussian
  - Clasificatori clasici neurali:
    - Perceptron
    - Perceptron multi strat
  - Algoritmi de învățare profundă:
    - Rețele neurale convoluționale

# Baza de date SAU-SRB

- Rapid-e : Serbia
- 14 specii de polen
- 182.187 eșantioane




Fig1: Vizualizarea celor 3 caracteristici din setul de date SAU-SRB

# Preprocesarea datelor

- $182.287 - 15.016 - 80.758 = 86.513$
- JSON – NPY
- 48 s – 1 s
- Normalizare
- PCA

| Număr | Specii de polen | Numărul inițial de eșantioane | Numărul de eșantioane după filtrare | Ponderea claselor raportată la dimensiunea întregului set de date |
|-------|-----------------|-------------------------------|-------------------------------------|-------------------------------------------------------------------|
| 1     | Acer            | 4399                          | 1335                                | 1,54%                                                             |
| 2     | Alnus           | 17471                         | 3874                                | 4,47%                                                             |
| 3     | Artemisia       | 25486                         | 15209                               | 17,58%                                                            |
| 4     | Betula          | 27347                         | 12544                               | 14,49%                                                            |
| 5     | Cedrus          | 5761                          | 1236                                | 1,42%                                                             |
| 6     | Corylus         | 26035                         | 15760                               | 18,21%                                                            |
| 7     | Cynodon         | 2728                          | 1302                                | 1,5%                                                              |
| 8     | Dactylis        | 5861                          | 1952                                | 2,25%                                                             |
| 9     | Fraxinus        | 10230                         | 5599                                | 6,47%                                                             |
| 10    | Picea           | 9702                          | 2456                                | 2,83%                                                             |
| 11    | Populus         | 16945                         | 7070                                | 8,17%                                                             |
| 12    | Quercus         | 4194                          | 1721                                | 1,98%                                                             |
| 13    | Salix           | 15755                         | 10086                               | 11,65%                                                            |
| 14    | Taxus           | 10373                         | 6369                                | 7,36%                                                             |

Tabela 1: Statistica bazei de date SAU-SRB

# Experimente și rezultate folosind metode clasice de clasificare




Fig 2: Rețea perceptron multi strat cu un singur strat ascuns

# Experimente și rezultate folosind metode clasice de clasificare




Fig 3: Rețea perceptron multi strat cu 3 straturi ascunse

# Experimente și rezultate folosind metode clasice de clasificare

| Clasificator                            | Acuratețea modelului pe setul de antrenare | Acuratețea modelului pe setul de testare | Timpul de antrenare |
|-----------------------------------------|--------------------------------------------|------------------------------------------|---------------------|
| Perceptron                              | 52%                                        | 47%                                      | 37 s                |
| Bayes naiv                              | 50%                                        | 49%                                      | 1 s                 |
| Algoritmul celor mai apropiați k vecini | 55%                                        | 53%                                      | 110 s               |
| MLP(900,300,30)                         | 98%                                        | 69%                                      | 536 s               |
| <b>MLP(100)</b>                         | <b>76%</b>                                 | <b>71%</b>                               | <b>210 s</b>        |

Tabela 2: Rezultate folosind algoritmi clasici de ML

# Experimente și rezultate folosind rețele neurale convoluționale




Fig 4: Reprezentarea arhitecturii LeNet-5 adaptată pentru imaginea de împrăștiere

Acuratețea modelului pe setul de testare = 57%

# Experimente și rezultate folosind rețele neurale convoluționale




Fig 5: Reprezentarea arhitecturii LeNet-5 adaptată pentru spectrul de fluorescență

Acuratețea modelului pe setul de testare = 59%

# Experimente și rezultate folosind rețele neurale convoluționale




Fig 6: Reprezentarea arhitecturii LeNet-5 adaptată pentru timpul de răspuns fluorescent

Acuratețea modelului pe setul de testare = 66%

# Experimente și rezultate folosind rețele neurale convoluționale




Fig 7: Reprezentarea arhitecturii multi-intrare bazată pe rețelele preantrenate

# Experimente și rezultate folosind rețele neurale convoluționale




Fig 8: Reprezentarea arhitecturii multi-intrare reantrenată pentru cele 3 caracteristici

# Sumar rezultate

| Algoritmi                         | Model                                | Acuratețe | Timp de antrenare |
|-----------------------------------|--------------------------------------|-----------|-------------------|
| de<br>clasificare<br>clasici (ML) | Perceptron                           | 47%       | 37 secunde        |
|                                   | Bayes<br>naiv                        | 49%       | 1 secunde         |
|                                   | Cei mai<br>aproiați<br>k vecini      | 53%       | 2 minute          |
|                                   | MLP (900,300,30)                     | 69%       | 9 minute          |
|                                   | MLP (100)                            | 71%       | 4 minute          |
| de<br>învățare<br>profundă (DL)   | LeNet-5 multi-intrare                | 73%       | 36 minute         |
|                                   | LeNet-5 multi-intrare<br>sumă ieșire | 75%       | 56 minute         |

Acuratețea  
procesului manual  
de clasificare = 67%

Alte lucrări de clasificare a  
polenului pe aceeași bază  
de date = 73% [2]

Tabela 3: Sumarul rezultatelor lucrării

# Contribuții personale

- Familiarizarea cu setul de date SAU-SRB
- Filtrarea și prelucrarea setului de date
- Aplicarea algoritmilor de preprocesare pe setul de date (PCA)
- Studiul algoritmilor de clasificare clasici (perceptron, Bayes naiv, cei mai apropiați k vecini, proces gaussian, MLP)
- Studiul algoritmilor de învățare profundă ce pot fi utilizați pentru clasificarea polenului (CNN) și optimizarea arhitecturilor și hiperparametrilor pe problema propusă
- Utilizarea algoritmilor și implementarea experimentelor în limbajul de programare Python cu ajutorul diverselor biblioteci
- Realizarea experimentelor și interpretarea rezultatelor pentru îmbunătățirea performanțelor

# Concluzii și dezvoltări viitoare

- Îmbunătățirea modului de căutare a hiperparametrilor.
- Optimizarea hiperparametrilor arhitecturii CNN multi-intrare bazată pe arhitecturile obținute în urma experimentelor pe fiecare caracteristică în parte.
- Adaptarea unei arhitecturi CNN mai complexă decât LeNet-5 (AlexNet).

Vă mulțumesc pentru atenție

# DEMO

Eșantion 1. Doar predicția CNN multi-intrare corectă:

Eticheta = Acer(1)  
Predicție CNN imagine = Corylus(6)  
Predicție CNN spectru = Populus(11)  
Predicție CNN timp = Artemisia(3)  
Predicție CNN multi-intrare = Acer(1)

Ieșirea rețelelor înainte de softmax:

|                          |   |   |      |       |       |       |        |       |       |      |       |       |       |       |       |       |   |
|--------------------------|---|---|------|-------|-------|-------|--------|-------|-------|------|-------|-------|-------|-------|-------|-------|---|
| Clasa                    | = | [ | 1    | 2     | 3     | 4     | 5      | 6     | 7     | 8    | 9     | 10    | 11    | 12    | 13    | 14    | ] |
| Ieșire CNN imagine       | = | [ | 3.51 | 1.57  | -2.87 | 3.63  | -6.26  | 4.11  | -7.02 | 0.28 | -1.30 | 0.58  | -1.31 | 3.52  | -0.61 | -3.51 | ] |
| Ieșire CNN spectru       | = | [ | 2.53 | -1.11 | 2.11  | -1.37 | -2.13  | -1.25 | -0.99 | 0.91 | -1.04 | -1.04 | 2.98  | -0.56 | 1.42  | -2.24 | ] |
| Ieșire CNN timp          | = | [ | 1.90 | 0.02  | 3.43  | -0.63 | -1.71  | -3.07 | -0.63 | 1.45 | -2.27 | -1.13 | 0.11  | 0.56  | 1.79  | -0.95 | ] |
| Ieșire CNN multi-intrare | = | [ | 7.94 | 0.49  | 2.68  | 1.64  | -10.10 | -0.22 | -8.64 | 2.63 | -4.61 | -1.59 | 1.77  | 3.52  | 2.60  | -6.70 | ] |

Probabilitățile rețelelor:

|                             |   |   |      |      |      |      |      |      |      |      |      |      |      |      |      |      |   |
|-----------------------------|---|---|------|------|------|------|------|------|------|------|------|------|------|------|------|------|---|
| Clasa                       | = | [ | 1    | 2    | 3    | 4    | 5    | 6    | 7    | 8    | 9    | 10   | 11   | 12   | 13   | 14   | ] |
| Predicție CNN imagine       | = | [ | 0.19 | 0.03 | 0.00 | 0.22 | 0.00 | 0.35 | 0.00 | 0.01 | 0.00 | 0.01 | 0.00 | 0.19 | 0.00 | 0.00 | ] |
| Predicție CNN spectru       | = | [ | 0.25 | 0.01 | 0.17 | 0.01 | 0.00 | 0.01 | 0.01 | 0.05 | 0.01 | 0.01 | 0.39 | 0.01 | 0.08 | 0.00 | ] |
| Predicție CNN timp          | = | [ | 0.12 | 0.02 | 0.57 | 0.01 | 0.00 | 0.00 | 0.01 | 0.08 | 0.00 | 0.01 | 0.02 | 0.03 | 0.11 | 0.01 | ] |
| Predicție CNN multi-intrare | = | [ | 0.97 | 0.00 | 0.01 | 0.00 | 0.00 | 0.00 | 0.00 | 0.00 | 0.00 | 0.00 | 0.00 | 0.01 | 0.00 | 0.00 | ] |

Figure 1





Fig 9: Prezentarea ieșirilor rețelelor pentru un eșantion clasificat corect doar de CNN multi-intrare

# DEMO

Eșantion 2. Toate predicțiile corecte:

Eticheta = Acer(1)

Predicție CNN imagine = Acer(1)

Predicție CNN spectru = Acer(1)

Predicție CNN timp = Acer(1)

Predicție CNN multi-intrare = Acer(1)

Ieșirea rețelelor înainte de softmax:

|                          |   |   |       |       |       |        |        |       |        |       |       |       |      |       |      |       |   |
|--------------------------|---|---|-------|-------|-------|--------|--------|-------|--------|-------|-------|-------|------|-------|------|-------|---|
| Clasa                    | = | [ | 1     | 2     | 3     | 4      | 5      | 6     | 7      | 8     | 9     | 10    | 11   | 12    | 13   | 14    | ] |
| Ieșire CNN imagine       | = | [ | 2.89  | -0.72 | 0.50  | 0.72   | -6.15  | 0.68  | -8.04  | 2.21  | 2.05  | -0.05 | 1.15 | 2.53  | 1.47 | -3.27 | ] |
| Ieșire CNN spectru       | = | [ | 5.24  | -1.78 | 1.40  | -2.61  | -2.05  | -0.88 | 1.04   | 4.47  | -1.90 | -0.21 | 3.82 | -1.72 | 1.15 | -3.39 | ] |
| Ieșire CNN timp          | = | [ | 8.93  | 4.55  | -1.21 | -8.76  | -2.73  | -4.06 | -3.03  | 5.02  | -2.55 | -1.10 | 4.79 | 2.84  | 3.22 | 2.10  | ] |
| Ieșire CNN multi-intrare | = | [ | 17.05 | 2.05  | 0.69  | -10.65 | -10.93 | -4.26 | -10.02 | 11.70 | -2.40 | -1.37 | 9.76 | 3.65  | 5.84 | -4.56 | ] |

Probabilitățile rețelelor:

|                             |   |   |      |      |      |      |      |      |      |      |      |      |      |      |      |      |   |
|-----------------------------|---|---|------|------|------|------|------|------|------|------|------|------|------|------|------|------|---|
| Clasa                       | = | [ | 1    | 2    | 3    | 4    | 5    | 6    | 7    | 8    | 9    | 10   | 11   | 12   | 13   | 14   | ] |
| Predicție CNN imagine       | = | [ | 0.29 | 0.01 | 0.03 | 0.03 | 0.00 | 0.03 | 0.00 | 0.15 | 0.13 | 0.02 | 0.05 | 0.20 | 0.07 | 0.00 | ] |
| Predicție CNN spectru       | = | [ | 0.57 | 0.00 | 0.01 | 0.00 | 0.00 | 0.00 | 0.01 | 0.26 | 0.00 | 0.00 | 0.14 | 0.00 | 0.01 | 0.00 | ] |
| Predicție CNN timp          | = | [ | 0.95 | 0.01 | 0.00 | 0.00 | 0.00 | 0.00 | 0.00 | 0.02 | 0.00 | 0.00 | 0.02 | 0.00 | 0.00 | 0.00 | ] |
| Predicție CNN multi-intrare | = | [ | 0.99 | 0.00 | 0.00 | 0.00 | 0.00 | 0.00 | 0.00 | 0.00 | 0.00 | 0.00 | 0.00 | 0.00 | 0.00 | 0.00 | ] |

Figure 2




Fig 10: Prezentarea ieșirilor rețelelor pentru un eșantion clasificat corect de toate CNN-urile

# DEMO

Eșantion 3. Doar predicția CNN imagine de împrăștiere corectă:

Eticheta = Acer(1)  
Predicție CNN imagine = Acer(1)  
Predicție CNN spectru = Cynodon(7)  
Predicție CNN timp = Dactilis(8)  
Predicție CNN multi-intrare = Dactilis(8)

Ieșirea rețelelor înainte de softmax:

|                          |   |   |      |       |       |       |       |       |       |      |       |       |      |       |       |      |   |
|--------------------------|---|---|------|-------|-------|-------|-------|-------|-------|------|-------|-------|------|-------|-------|------|---|
| Clasa                    | = | [ | 1    | 2     | 3     | 4     | 5     | 6     | 7     | 8    | 9     | 10    | 11   | 12    | 13    | 14   | ] |
| Ieșire CNN imagine       | = | [ | 3.57 | -0.19 | -1.00 | -0.61 | -5.37 | -0.14 | -6.53 | 2.99 | -1.51 | 1.90  | 2.39 | 2.26  | 1.65  | 0.02 | ] |
| Ieșire CNN spectru       | = | [ | 0.70 | -0.37 | -1.51 | -1.01 | -2.78 | 0.47  | 1.46  | 0.14 | -0.18 | -1.18 | 1.04 | -1.01 | -0.96 | 1.01 | ] |
| Ieșire CNN timp          | = | [ | 1.24 | 2.79  | 1.26  | -4.06 | -0.96 | -2.61 | -0.04 | 2.82 | -3.99 | -1.78 | 2.23 | -0.32 | 1.92  | 0.79 | ] |
| Ieșire CNN multi-intrare | = | [ | 5.50 | 2.23  | -1.24 | -5.68 | -9.12 | -2.28 | -5.11 | 5.95 | -5.68 | -1.05 | 5.67 | 0.93  | 2.61  | 1.81 | ] |

Probabilitățile rețelelor:

|                             |   |   |      |      |      |      |      |      |      |      |      |      |      |      |      |      |   |
|-----------------------------|---|---|------|------|------|------|------|------|------|------|------|------|------|------|------|------|---|
| Clasa                       | = | [ | 1    | 2    | 3    | 4    | 5    | 6    | 7    | 8    | 9    | 10   | 11   | 12   | 13   | 14   | ] |
| Predicție CNN imagine       | = | [ | 0.39 | 0.01 | 0.00 | 0.01 | 0.00 | 0.01 | 0.00 | 0.22 | 0.00 | 0.07 | 0.12 | 0.10 | 0.06 | 0.01 | ] |
| Predicție CNN spectru       | = | [ | 0.11 | 0.04 | 0.01 | 0.02 | 0.00 | 0.09 | 0.24 | 0.06 | 0.05 | 0.02 | 0.16 | 0.02 | 0.02 | 0.15 | ] |
| Predicție CNN timp          | = | [ | 0.06 | 0.27 | 0.06 | 0.00 | 0.01 | 0.00 | 0.02 | 0.28 | 0.00 | 0.00 | 0.15 | 0.01 | 0.11 | 0.04 | ] |
| Predicție CNN multi-intrare | = | [ | 0.26 | 0.01 | 0.00 | 0.00 | 0.00 | 0.00 | 0.00 | 0.41 | 0.00 | 0.00 | 0.30 | 0.00 | 0.01 | 0.01 | ] |

Figure 3




Fig 9: Prezentarea ieșirilor rețelelor pentru un eșantion clasificat corect doar de CNN imagine

# DEMO

Eșantion 4. Nici o predicție corectă:

Eticheta = Acer(1)  
Predicție CNN imagine = Artemisia(3)  
Predicție CNN spectru = Taxus(14)  
Predicție CNN timp = Salix(13)  
Predicție CNN multi-intrare = Salix(13)

Ieșirea rețelelor înainte de softmax:

| Clasa                    | = | [ | 1     | 2     | 3     | 4     | 5     | 6     | 7     | 8     | 9     | 10    | 11    | 12    | 13   | 14    | ] |
|--------------------------|---|---|-------|-------|-------|-------|-------|-------|-------|-------|-------|-------|-------|-------|------|-------|---|
| Ieșire CNN imagine       | = | [ | 1.01  | -0.78 | 3.10  | 0.97  | -4.56 | -0.50 | -5.52 | 1.32  | -1.25 | 1.47  | 0.47  | 1.51  | 0.58 | 0.17  | ] |
| Ieșire CNN spectru       | = | [ | -1.62 | 0.59  | -0.59 | -0.68 | -1.69 | -0.12 | 0.38  | -1.22 | -0.10 | -0.87 | -0.29 | -2.91 | 0.28 | 2.85  | ] |
| Ieșire CNN timp          | = | [ | 1.52  | 0.86  | -0.12 | -0.30 | -2.96 | -0.47 | -3.13 | 1.74  | -5.97 | 0.34  | 2.14  | 2.99  | 3.47 | -1.82 | ] |
| Ieșire CNN multi-intrare | = | [ | 0.91  | 0.67  | 2.38  | -0.01 | -9.21 | -1.09 | -8.28 | 1.84  | -7.32 | 0.95  | 2.31  | 1.58  | 4.33 | 1.20  | ] |

Probabilitățile rețelelor:

| Clasa                       | = | [ | 1    | 2    | 3    | 4    | 5    | 6    | 7    | 8    | 9    | 10   | 11   | 12   | 13   | 14   | ] |
|-----------------------------|---|---|------|------|------|------|------|------|------|------|------|------|------|------|------|------|---|
| Predicție CNN imagine       | = | [ | 0.06 | 0.01 | 0.48 | 0.06 | 0.00 | 0.01 | 0.00 | 0.08 | 0.01 | 0.09 | 0.03 | 0.10 | 0.04 | 0.03 | ] |
| Predicție CNN spectru       | = | [ | 0.01 | 0.07 | 0.02 | 0.02 | 0.01 | 0.03 | 0.05 | 0.01 | 0.03 | 0.02 | 0.03 | 0.00 | 0.05 | 0.65 | ] |
| Predicție CNN timp          | = | [ | 0.06 | 0.03 | 0.01 | 0.01 | 0.00 | 0.01 | 0.00 | 0.07 | 0.00 | 0.02 | 0.11 | 0.26 | 0.42 | 0.00 | ] |
| Predicție CNN multi-intrare | = | [ | 0.02 | 0.02 | 0.09 | 0.01 | 0.00 | 0.00 | 0.00 | 0.05 | 0.00 | 0.02 | 0.08 | 0.04 | 0.63 | 0.03 | ] |

Figure 4






Fig 9: Prezentarea ieșirilor rețelelor pentru un eșantion clasificat incorect de toate CNN-urile


Matrice confuzie pentru CNN imagine



Matrice confuzie pentru CNN spectru



Matrice confuzie pentru CNN timp



Matrice confuzie pentru CNN multi-input

