LAPI – Laboratorul de Analiza şi Prelucrarea Imaginilor

Universitatea POLITEHNICA din Bucureşti

Facultatea de Electronică, Telecomunicaţii şi Tehnologia Informaţiei

TACAI - Tehnici de Analiză și Clasificare Automată a Informației

Note de laborator

Dr.ing. Ionuț Mironică

Conf.dr.ing. Bogdan Ionescu

Laborator 2

Cuprins:

- Introducere în Matlab
- Clasificare de baze de date de imagini
- Prezentare baze de date utilizate
- Exerciții

I. Introducere în Matlab

Cuprins

- Laboratorul cuprinde o scurtă introducere și nu un tutorial complet Matlab:

  - detalii de bază;

  - avantajele și dezavantajele utilizării Matlab în funcție de alte limbaje.

I. Introducere în Matlab

Introducere Matlab

- MATLAB (MATrix LABoratory);
- Reprezintă un limbaj cu mare productivitate pentru dezvoltarea de algoritmi inginerești;
- Cuprinde algoritmi deja implementați, opțiuni de vizualizare a datelor și unelte pentru o ușoară dezvoltare și proiectare de algoritmi.

I. Introducere în Matlab

Dezavantaje Matlab

- Lent pentru anumite tipuri de probleme și procese;
- Poate fi cu greu implementat în aplicații web;
- Nu este gândit pentru dezvoltarea de sisteme de dimensiuni foarte mari care să ruleze sisteme din producție.

I. Introducere în Matlab

Structură mediu de programare Matlab

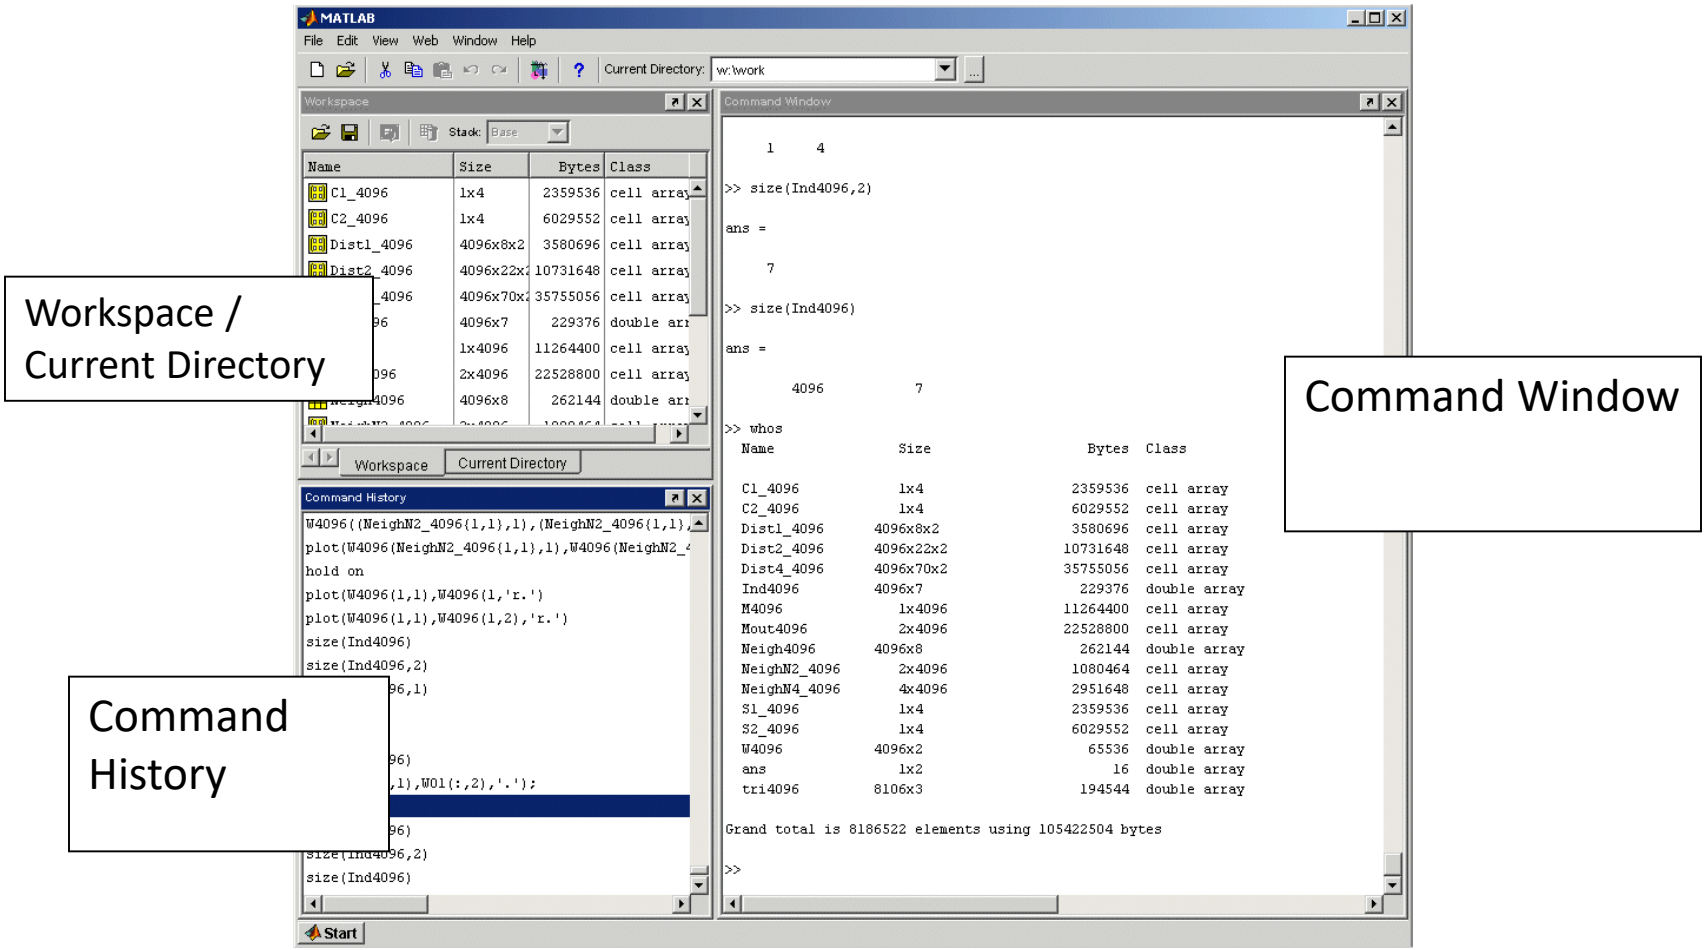

I. Introducere în Matlab

Structură mediu de programare Matlab

Command Window

– Generare de comenzi simple;

Current Directory

– Vizualizare foldere și fișiere

În format *.m (format Matlab)

Workspace

– vizualizare variabile

– Se pot vizualiza valoarea variabilelor prin Double click (se deschide fereastra Array Editor)

Command History

– Vizualizare istoric comenzi

– Salvarea unei sesiuni prin utilizarea unui jurnal de comenzi (diary)

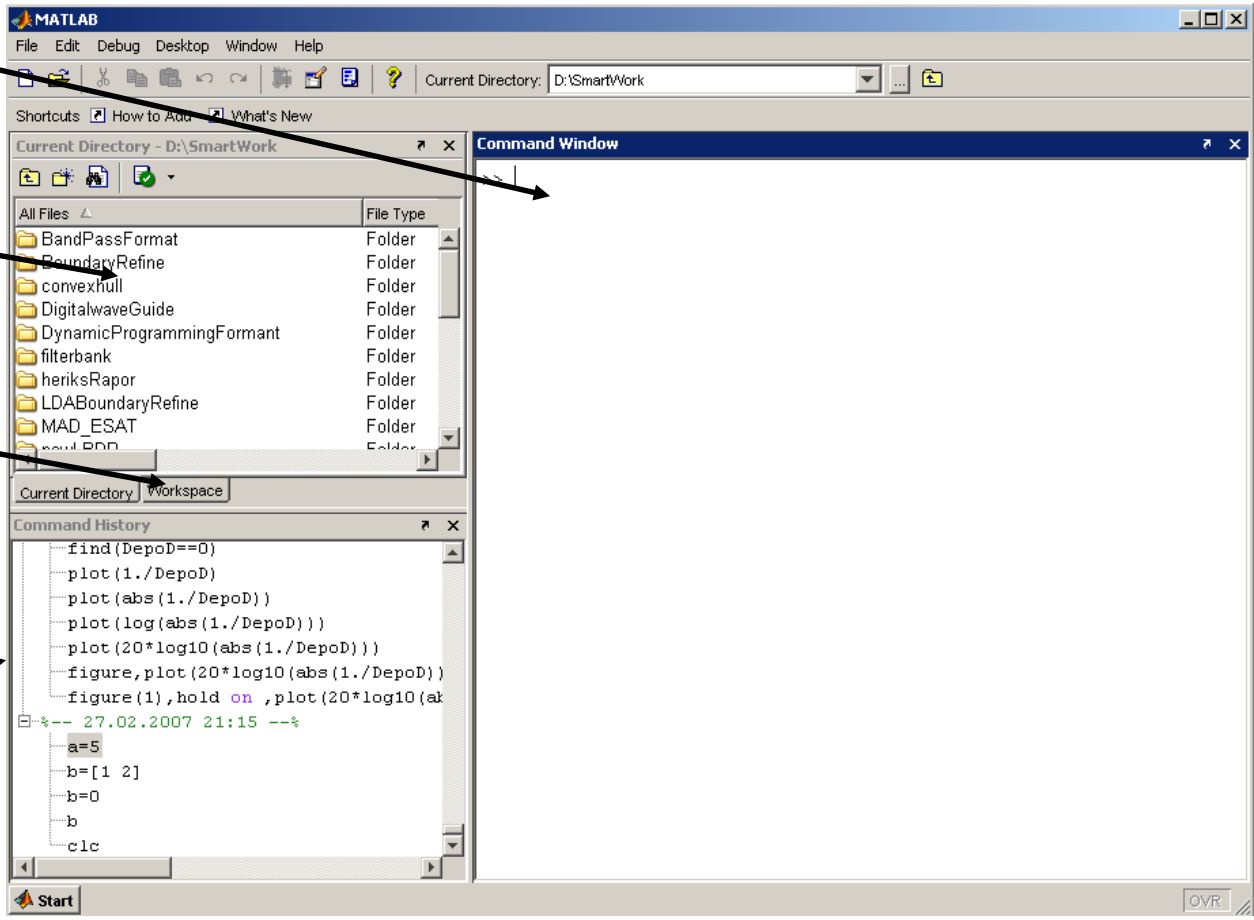

I. Introducere în Matlab

Variabile în Matlab

- În Matlab nu este nevoie să se inițializeze sau să se declare tipul variabilelor:

```
int a;
double b;
float c;
```

- Toate variabilele sunt create ca și matrici în format double

```
Examplu:
>>x=5;
>>x1=2;
```

- Conform exemplului anterior aceste variabile vor fi matrici de dimensiuni 1x1.

I. Introducere în Matlab

Structură Matlab

- Pentru a se vizualiza conținutul variabilelor trebuie doar sa se scrie numele variabilei în Command Window:

```
>> a
a =
12
>>
>> a*2
a =
24
>>
```

I. Introducere în Matlab

Structură Matlab

- Fereastra de Workspace reprezintă memoria curentă a Matlab-ului;
- Poate manipula variabilele stocate în workspace.

```
>> b=10;
>> c=a+b
c =
   22
>>
```

I. Introducere în Matlab

Workspace Matlab

- **Comenzi de manipulare a Workspace-ului**
- *whos* – prezintă variabilele și dimensiuna acestora

```
 Name      Size                Bytes  Class
  a        1x1                     8  double array
  b        1x1                     8  double array
  c        1x1                     8  double array
Grand total is 3 elements using 24 bytes
```

- *clear* – realizează ștergerea de variabile din workspace

```
>> clear a b; % delete a și b din workspace
>>
>> clear all; % șterge toate variabilele din workspace
>>
```

I. Introducere în Matlab

Operații matrici

- Nu este nevoie să se actualizeze / declare dimensiunile matricei:

```
>> A = [3 2 1; 5 1 0; 2 1 7]
A =
     3     2     1
     5     1     0
     2     1     7
>>
```

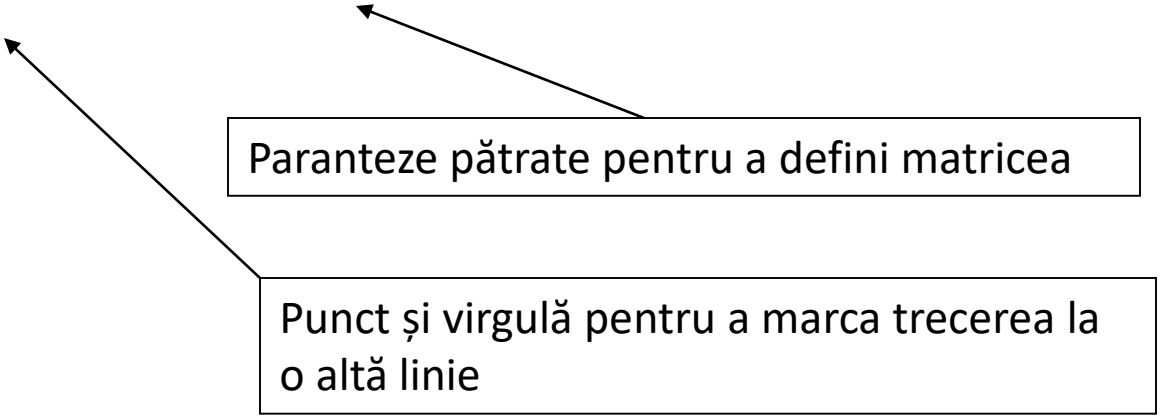

I. Introducere în Matlab

Accesarea valorilor unor matrici

- Accesarea elementelor unei matrici:

```
>> A(1,2)
ans=
2
```

Indicii elementelor unei matrici

```
A =
     3     2     1
     5     1     0
     2     1     7
```

I. Introducere în Matlab

Alocare valori matrici în Matlab

- un vector `x = [1 2 5 1]`

```
x =
     1     2     5     1
```

- o matrice `x = [1 2 3; 5 1 4; 3 2 -1]`

```
x =
     1     2     3
     5     1     4
     3     2    -1
```

I. Introducere în Matlab

Operatorul „:”

- Foarte utilizat în Matlab;
- În traducere ar însemna “de la X la Y”

```
t =1:10
  t =
       1    2    3    4    5    6    7    8    9
  10
k =2:-0.5:-1
  k =
       2   1.5   1   0.5   0   -0.5   -1
B = [1:4; 5:8]
  x =
     1     2     3     4
     5     6     7     8
```

I. Introducere în Matlab

Funcții definire funcții în Matlab

- zeros(M,N) - generează o matrice de valori de 0 de dimensiune MxN.

```
x = zeros(1,3)
x =
   0     0     0
```

- ones(M,N) - generează o matrice de valori de 1 de dimensiune MxN.

```
x = ones(1,3)
x =
   1     1     1
```

- rand(M,N) - generează o matrice de valori random distribuite uniform în intervalul (0,1) de dimensiune MxN.

```
x = rand(1,3)
x =
  0.9501   0.2311   0.6068
```

I. Introducere în Matlab

Indecșii matricilor

- Indecșii matricei încep de la 1 (nu de la 0 (ca în C))
- Indecșii matricei trebuie să fie numere întregi pozitive

```
A =

     3     5     3
     6     8     2
     2     7     3
```

```
>> A(6)

ans =

     7
```

```
>> A(3,2)

ans =

     7
```

```
>> A(2,:)

ans =

     6     8     2
```

```
>> A(1:2,2)

ans =

     5
     8
```

A(-2), A(0)

Error: ??? Subscript indices must either be real positive integers or logicals.

A(4,2)
Error: ??? Index exceeds matrix dimensions.

I. Introducere în Matlab

Concatenare matrici

- `x = [1 2], y = [4 5], z=[ 0 0]`

```
A = [ x y]

     1    2    4    5

B = [x ; y]

     1  2
     4  5
```

```
C = [x y ;z]
Error:
??? Error using ==> vertcat CAT arguments dimensions are not consistent.
```

I. Introducere în Matlab

Operații matrici

+ sumă
- diferență
* multiplicare
/ împărțire
^ putere
‘ transpusă

I. Introducere în Matlab

Operații matrici

Fie A și B:

```
>> A = [1 2 3;4 5 6;7 8 9]

A =

     1     2     3
     4     5     6
     7     8     9
```

```
>> B = [3 5 2; 5 2 8; 3 6 9]

B =

     3     5     2
     5     2     8
     3     6     9
```

Sumă

```
>> X = A + B

X =

     4     7     5
     9     7    14
    10    14    18
```

Diferență

```
>> Y = A - B

Y =

    -2    -3     1
    -1     3    -2
     4     2     0
```

Produs

```
>> Z = A * B

Z =

    22    27    45
    55    66   102
    88   105   159
```

Transpusă

```
>> T = A'

T =

     1     4     7
     2     5     8
     3     6     9
```

I. Introducere în Matlab

Operatorul „.” (element cu element)

.* multiplicare element cu element

./ împărțire element cu element

.^ ridicare la putere element cu element

I. Introducere în Matlab

Operatorul „.” (element cu element)

```
A = [1 2 3; 5 1 4; 3 2 1]
    A =
          1    2    3
          5    1    4
          3    2   -1
```

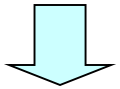

```
x = A(1,:)

x=
    1   2   3
```

```
y = A(3 ,:)

y=
    3  4  -1
```

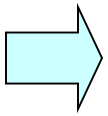

```
b = x .* y

b=
     3  8 -3
```

```
c = x . / y

c=
   0.33   0.5   -3
```

```
d = x .^2

d=
     1    4    9
```

```
K= x^2
Erorr:
 ??? Error using ==> mpower  Matrix must be square.
B=x*y
Erorr:
??? Error using ==> mtimes Inner matrix dimensions must agree.
```

I. Introducere în Matlab

Comenzi de informații

- *help*

>> help whos % afișează documentație pentru funcția whos

>> lookfor convert % caută funcțiile care conțin termenul convert în prima linie a răspunsului comenzii help

- Deschidere documentație Matlab

>> helpdesk

I. Introducere în Matlab

Realizare scripturi

- Mai multe comenzi matlab pot fi grupate în scripturi

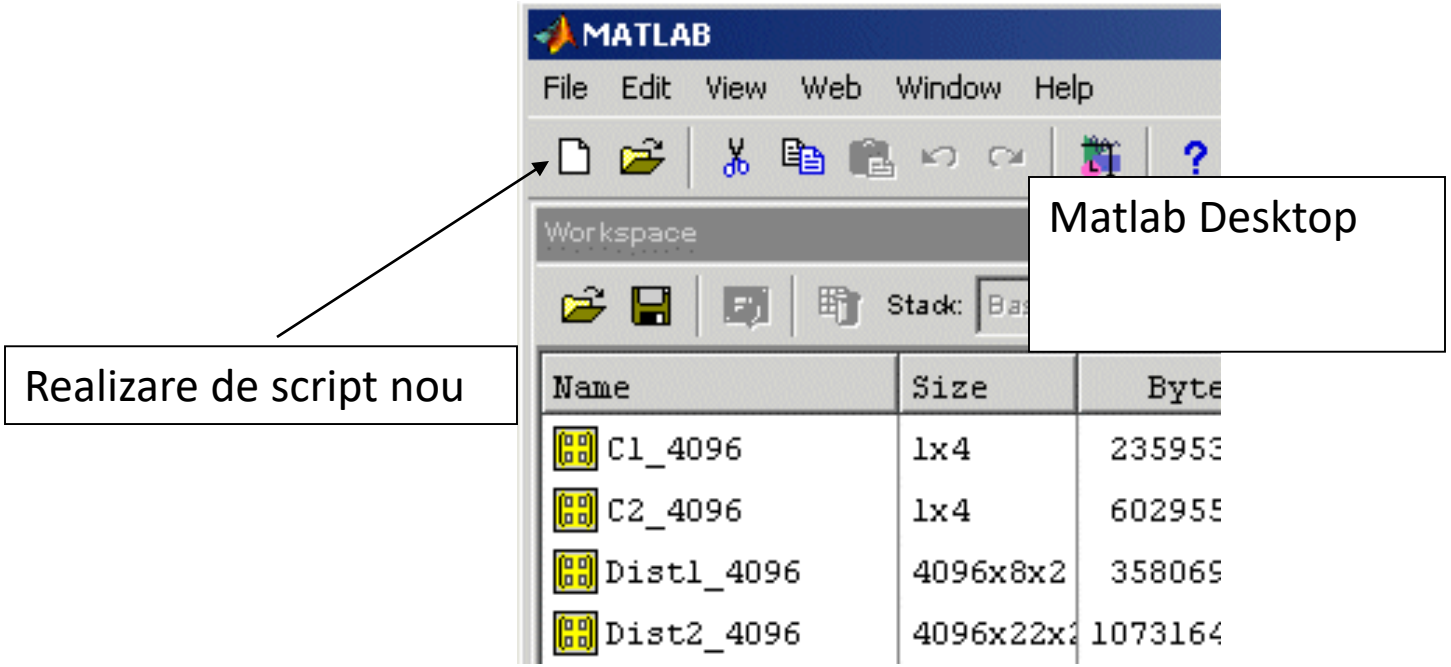

I. Introducere în Matlab

Realizare scripturi

- Scripturile vor manipula și stoca variabile în Matlab Workspace (memorie).
- Acestea pot fi chemate din linia de comandă Matlab prin scrierea fișierului scriptului.

  >> myscript

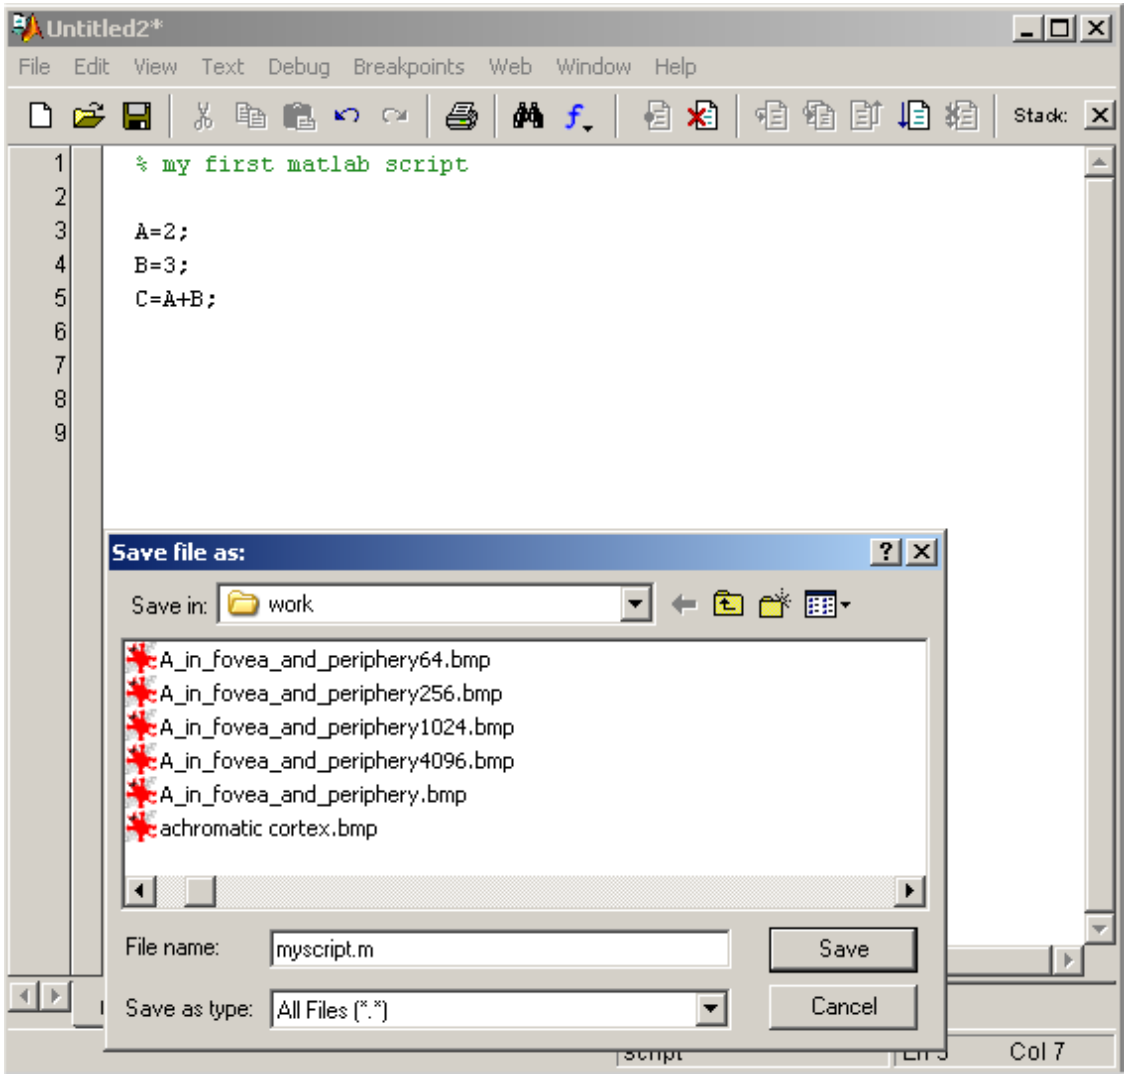

I. Introducere în Matlab

Funcții în Matlab

- Programarea în Matlab.
- Userii pot scrie funcții care pot fi chemate din linia de comandă.
- Funcțiile pot accepta variabile de intrare și pot avea ca ieșire un set de variabile de ieșire.
- Funcțiile nu manipulează variabilele din cadrul Matlab Workspace.
- Numele fișierului care conține funcția trebuie să fie același cu cel al funcției
- Atenție la cazurile în care mai multe funcții au același nume.
- Funcțiile deschise pentru editare prin utilizare comenzii **open**.

I. Introducere în Matlab

Funcții în Matlab

```
>> I=iterate(5)
I =
    1    4    9   16   25
```

Numele funcției

Variabile de intrare

Lista de variabile de ieșire

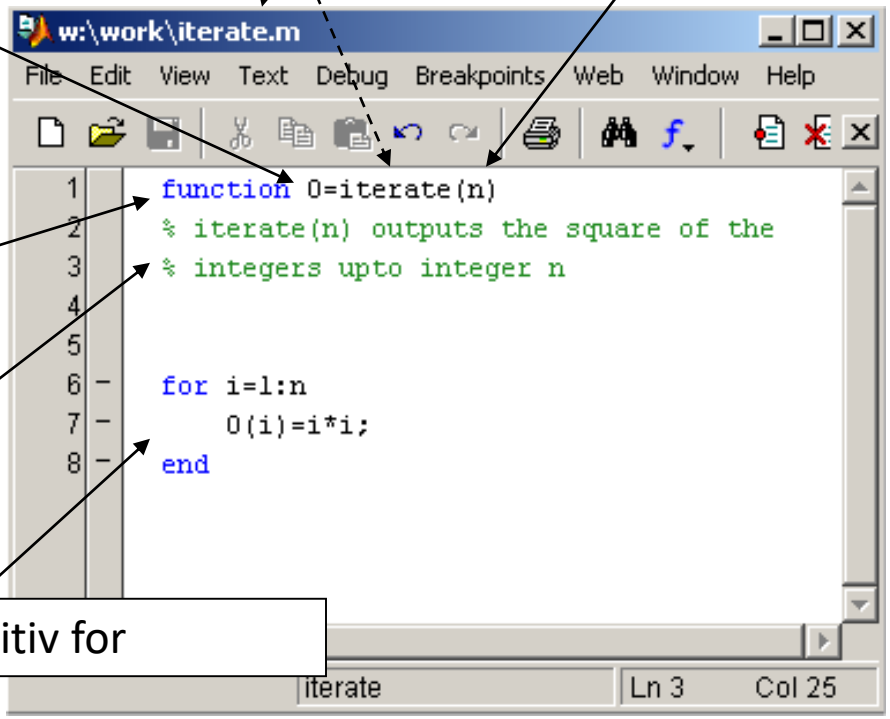

function keyword

Comentarii referitoare la funcție

Bloc repetitiv for

Accesează comentariile din funcția Matlab cu funcția help
>> help iterate

I. Introducere în Matlab

Funcții în Matlab

```
>> [i j]=sort2(2,4)
i =
     4
j =
     2
>>
```

Funcțiile pot avea mai multe variabile de ieșire.

Bloc condițional if

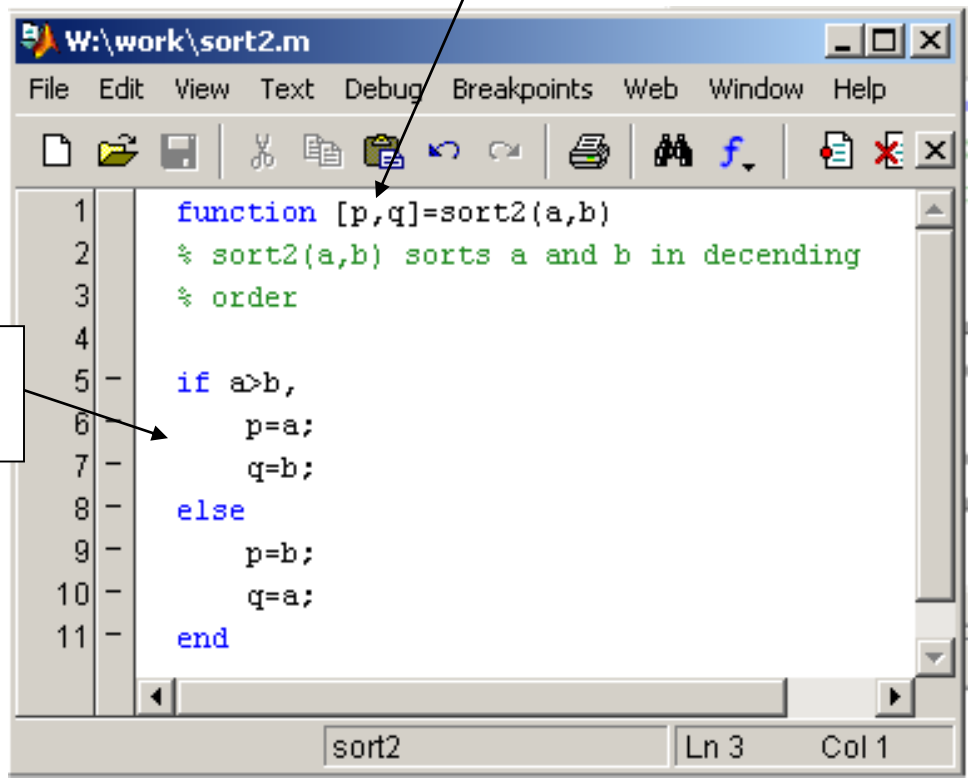

I. Introducere în Matlab

Instrucțiuni condiționale

- Sintaxă:

```
if (Condition_1)
        instrucțiuni
elseif (Condition_2)
        instrucțiuni
elseif (Condition_3)
        instrucțiuni
else
        instrucțiuni
end
```

Exemple

```
if ((a>3) & (b==5))
    instrucțiuni;
end
```

```
if (a<3)
    instrucțiuni;
elseif (b~=5)
    instrucțiuni;
end
```

```
if (a<3)
    instrucțiuni;
else
    instrucțiuni;
end
```

I. Introducere în Matlab

Instrucțiuni repetitive

- Sintaxă intrucțiune for

```
for i=Index_Array
    instrucțiuni
end
```

Exemple

```
for i=1:100
    instrucțiuni;
end
```

```
for j=1:3:200
    instrucțiuni;
end
```

```
for m=13:-0.2:-21
    Some Matlab Commands;
end
```

```
for k=[0.1 0.3 -13 12 7 -9.3]
    instrucțiuni;
end
```

I. Introducere în Matlab

Instrucțiuni repetitive

- Sintaxă instrucțiune while

while (condition)

Matlab Commands

end

Exemplu

```
while  ((a>3) & (b==5))
    instrucțiuni;
end
```

I. Introducere în Matlab

Debugging

- Atașare de breakpoints

```
>> [i j]=sort2(2,4)
K>>
K>> whos
 Name      Size              Bytes  Class
  a         1x1                 8  double array
  b         1x1                 8  double array
Grand total is 2 elements using 16 bytes
K>> a
a =
     2
K>> return
i =

     4
j =
     2
```

local function workspace

exit debug mode

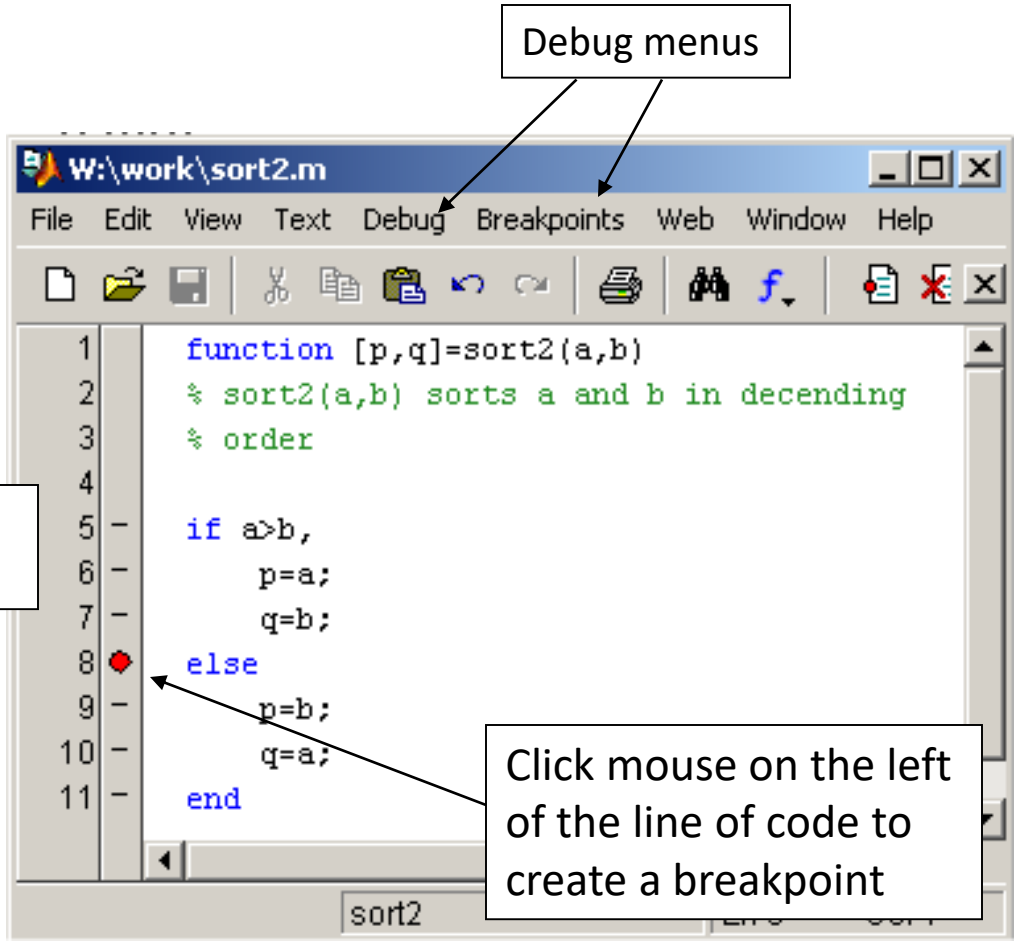

I. Introducere în Matlab

Prelucrare imagini

În Matlab imaginile color pot fi tratate ca niște matrici tri-dimensionale! (MxNx3):

Încărcarea unei imagini:

a = imread('picture.jpg');
% citire imagine
imshow(a); %afișare imagine

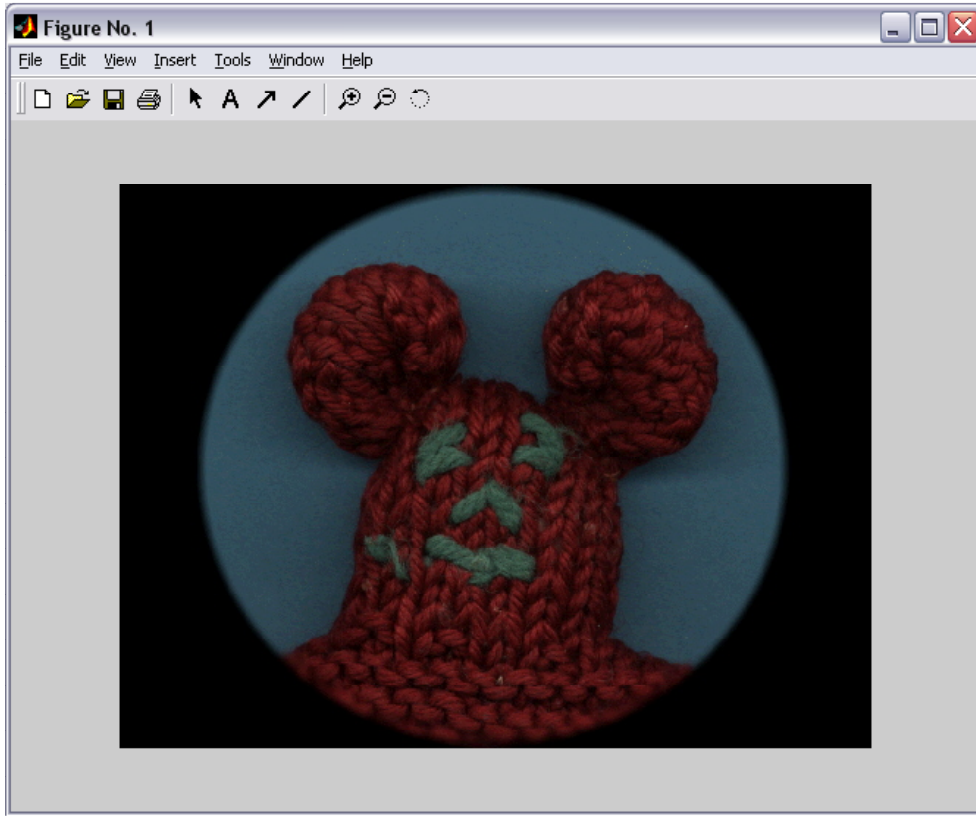

I. Introducere în Matlab

Prelucrare imagini

Afișarea planului roșu:

```
a(:,:,2:3) = 0;
imshow(a);
```

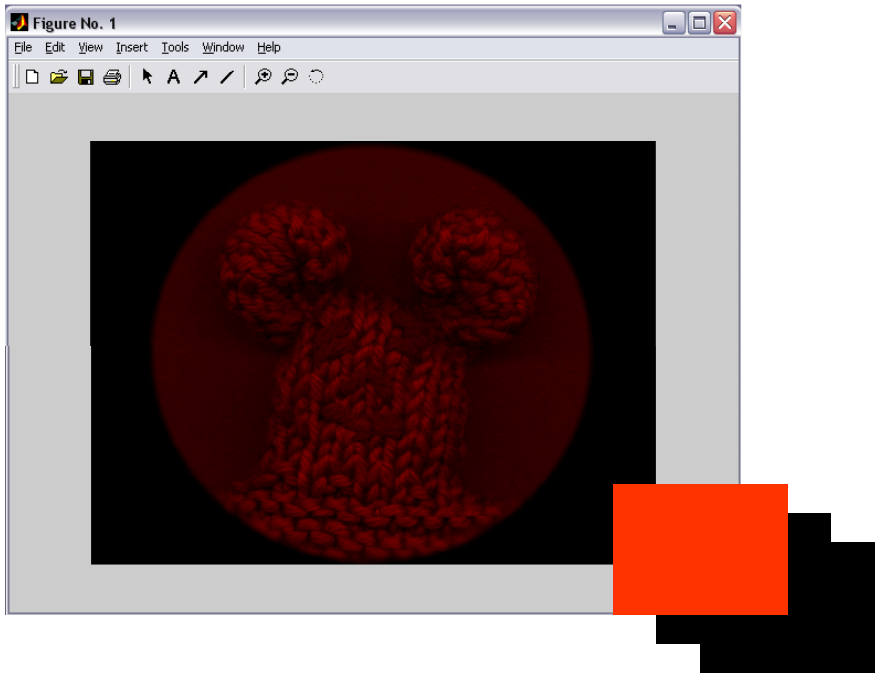

Afișarea planului verde:

```
a(:,:,[1 3]) = 0;
imshow(a);
```

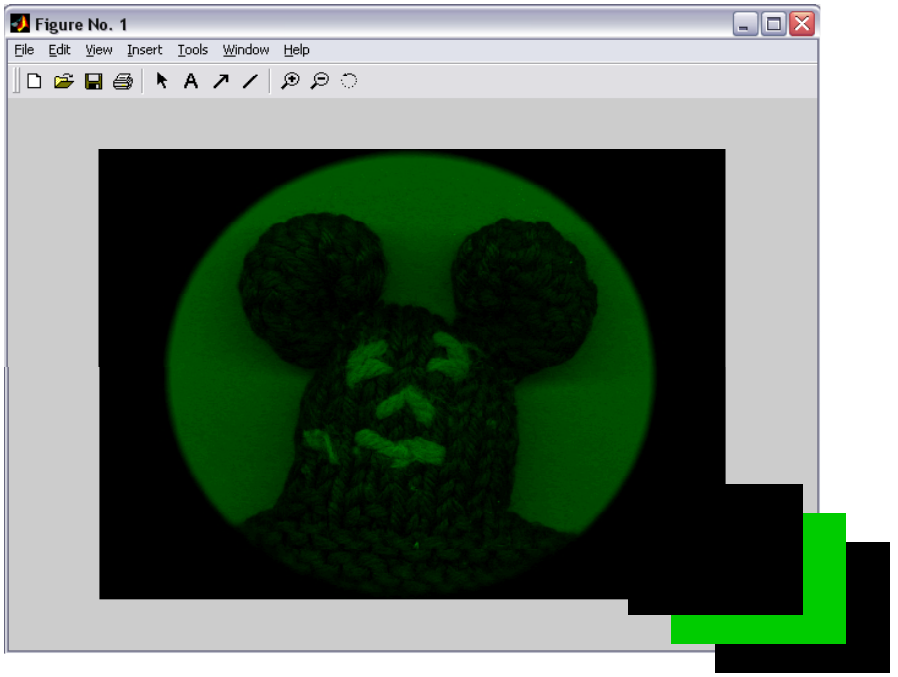

I. Introducere în Matlab

Citire fișiere text

Funcția:

[A,B,C,...] = textread(filename,format)

Ex: pentru fișierul

1 2
3 4

utilizăm [A B] = textread(filename,'%d %d')
vom obține A = [1;3] și B=[2;4]

I. Introducere în Matlab

Citire fișiere csv

Funcția:

[A] = csvread(filename)

Ex: pentru fișierul

1,2
3,4

utilizăm *[A] = csvread(filename)*
vom obține A = [1 2;3 4]

I. Introducere în Matlab

Scriere fișiere csv

Funcția:

csvwrite(filename, variabilă)

Ex: pentru fișierul

A = [1 2; 3 4]
csvwrite(filename,A)

vom obține fișierul cu conținutul:
1,2
3,4

II. Clasificare de baze de date de imagini

Schemă generală





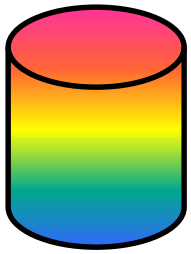

Baza de date imagini

Extragere trăsături

Generare descriptori de Imagini (vectori cu componente)

Algoritm de clasificare

Decizie

Imagine trimisă spre clasificare

II. Clasificare de baze de date de imagini

Descriptori de imagini

pixeli

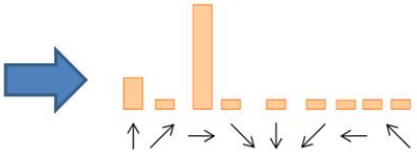

muchii

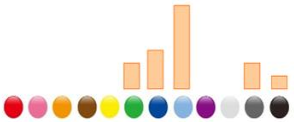

culoare

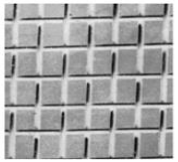

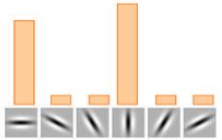

textură

formă

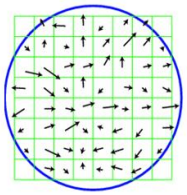

puncte de interes

II. Clasificare de baze de date de imagini

Color moments (CM)

- Se împarte imaginea în 3x3 regiuni;
- Pentru fiecare celulă se calculează media, deviația standard și skewness pe o regiune a imaginii

$$E_i = \frac{1}{N}\sum_{j=1}^{N} p_{ij} \quad , \quad \sigma_i = \left(\frac{1}{N}\sum_{j=1}^{N}(p_{ij} - E_i)^2\right)^{\frac{1}{2}} \quad \text{and} \quad s_i = \left(\frac{1}{N}\sum_{j=1}^{N}(p_{ij} - E_i)^3\right)^{\frac{1}{3}}$$

- Se concatenează cei trei parametri pentru fiecare celulă (3x3x3 = 81 elemente).

Stricker M., Dimai A. Spectral Covariance and Fuzzy Regions for Image Indexing. Machine Vision and Applications, vol. 10., p. 66-73, 1997

II. Clasificare de baze de date de imagini

Color moments (CM)

- Pentru prelucrarea descriptorului se va utiliza funcția Matlab:

cm = extractCM(im);

unde *cm* reprezintă descriptorul rezultat iar *im* este o matrice de dimensiune (L x l x 3) asociată imaginii RGB.

II. Clasificare de baze de date de imagini

Locally Binary Patterns (LBP)

- Pentru fiecare pixel din imagine se aplică un prag egal cu valoarea punctului central din nucleul de căutare;
- Pentru fiecare pixel *(xc, yc)* se va calcula următorul parametru:

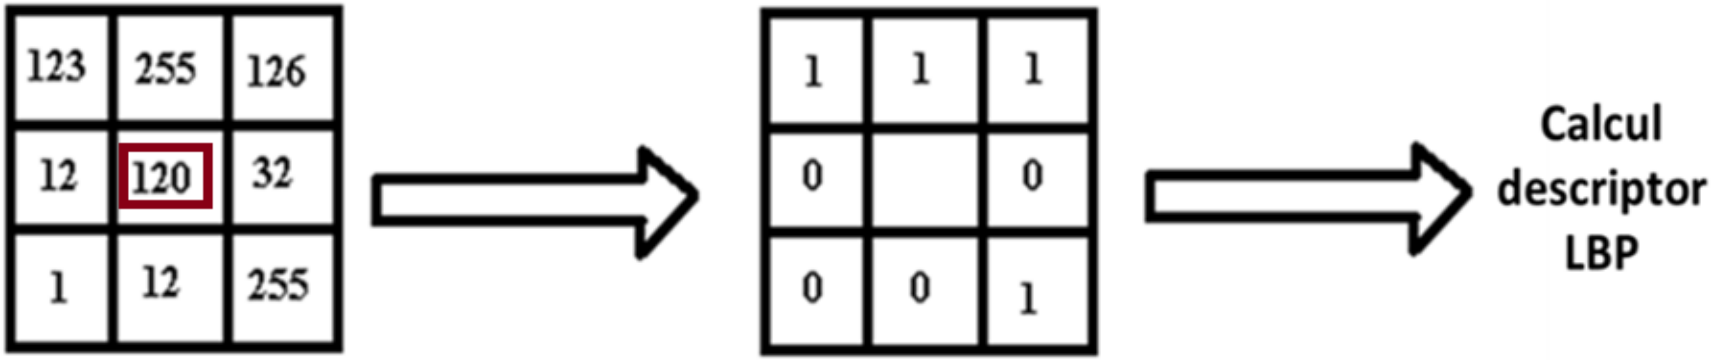

- Se creează o histogramă a valorilor generate (256 de combinații posibile);
- În cazul în care se repetă acest proces pe mai multe nuclee / scale ale imaginilor, descriptorul final va fi generat din concatenarea histogramelor generate

II. Clasificare de baze de date de imagini

Locally Binary Patterns (LBP)

- Pentru prelucrarea descriptorului se va utiliza funcția Matlab:

lbp = extractLBP(im);

unde *lbp* reprezintă descriptorul rezultat iar im este o matrice de dimensiune *(L x l x 3)* asociată imaginii.

II. Clasificare de baze de date de imagini

Histograms of Oriented Gradients (HoG)

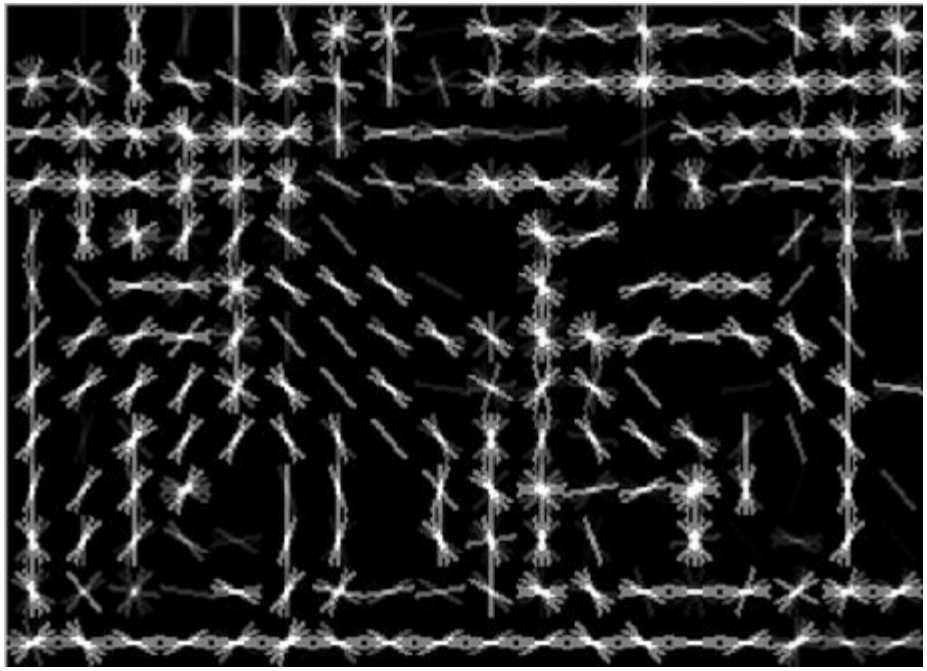

Pentru generarea descriptorului se va utiliza funcția:

hog = extractHoG(im);

III. Modele de Machine Learning

Rețele neuronale

- Reţelele neuronale reprezintă o mulțime de elemente de prelucrare neliniară care operează în paralel și care sunt legate intre ele în structuri ce seamană cu rețelele neuronale biologice.
- Model inspirat din rețelele neuronale din creierul uman.

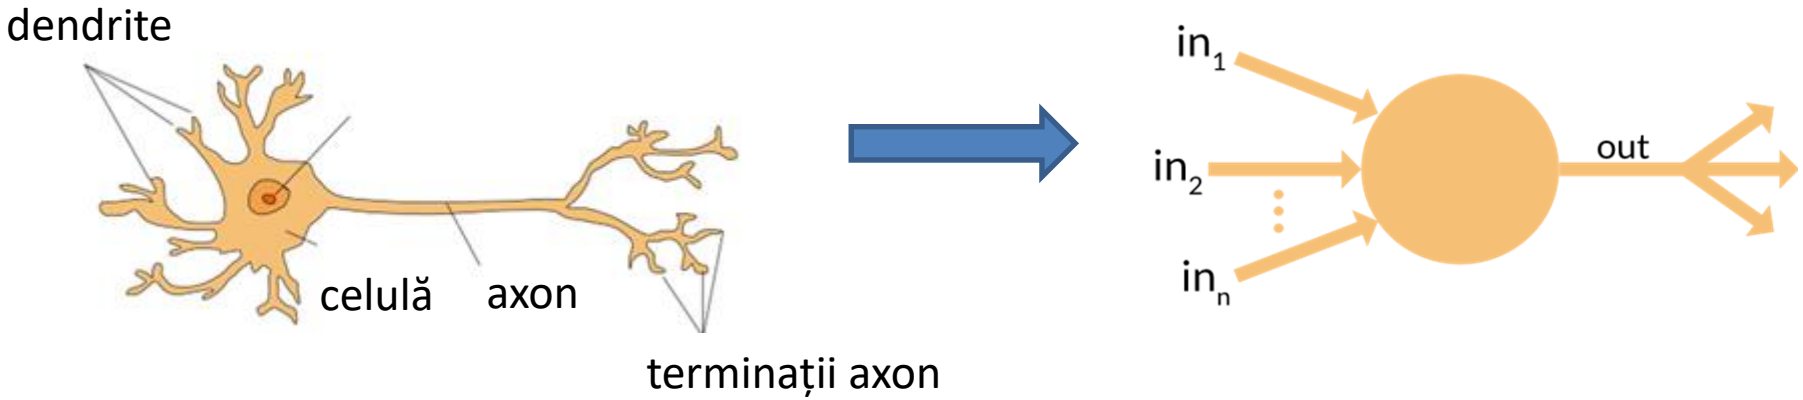

III. Modele de Machine Learning

Rețele neuronale

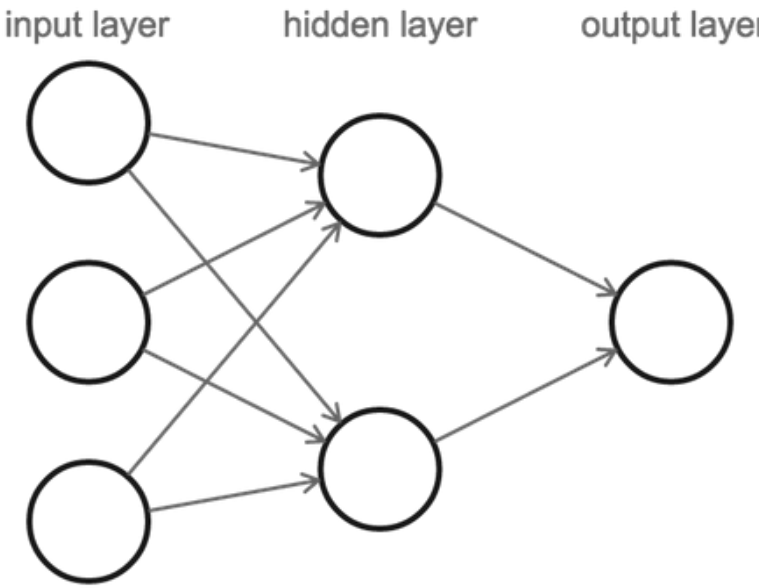

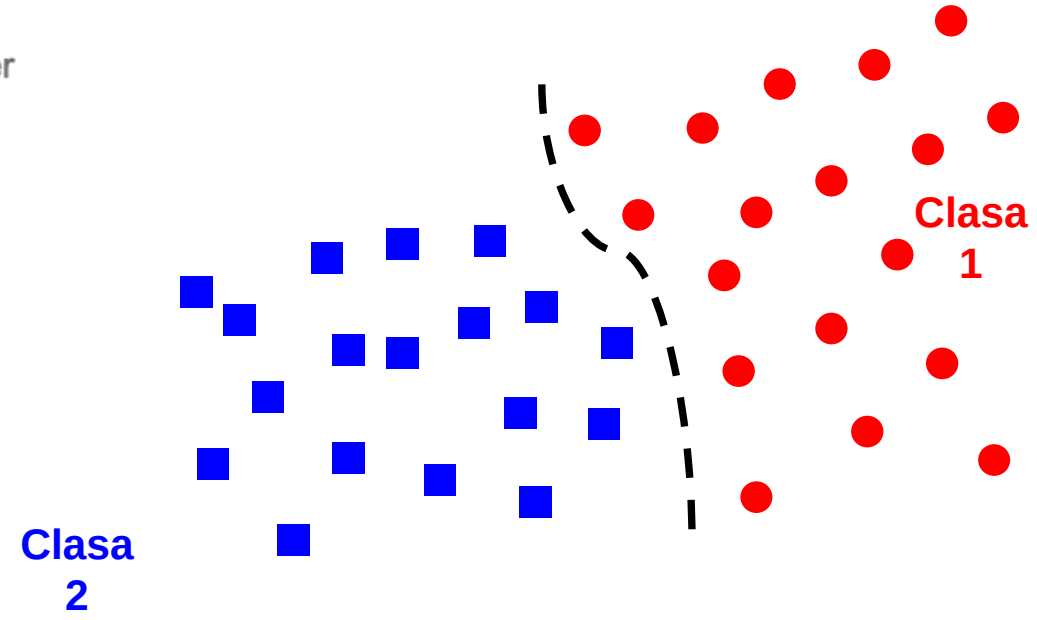

- Modele foarte bine adaptate pentru a găsi cea mai bună separație între două clase
- Structură complicată cu mulți parametri care nu sunt ușor de optimizat.
- Apare destul de des fenomenul de overfitting.

III. Modele de Machine Learning

Rețele neuronale

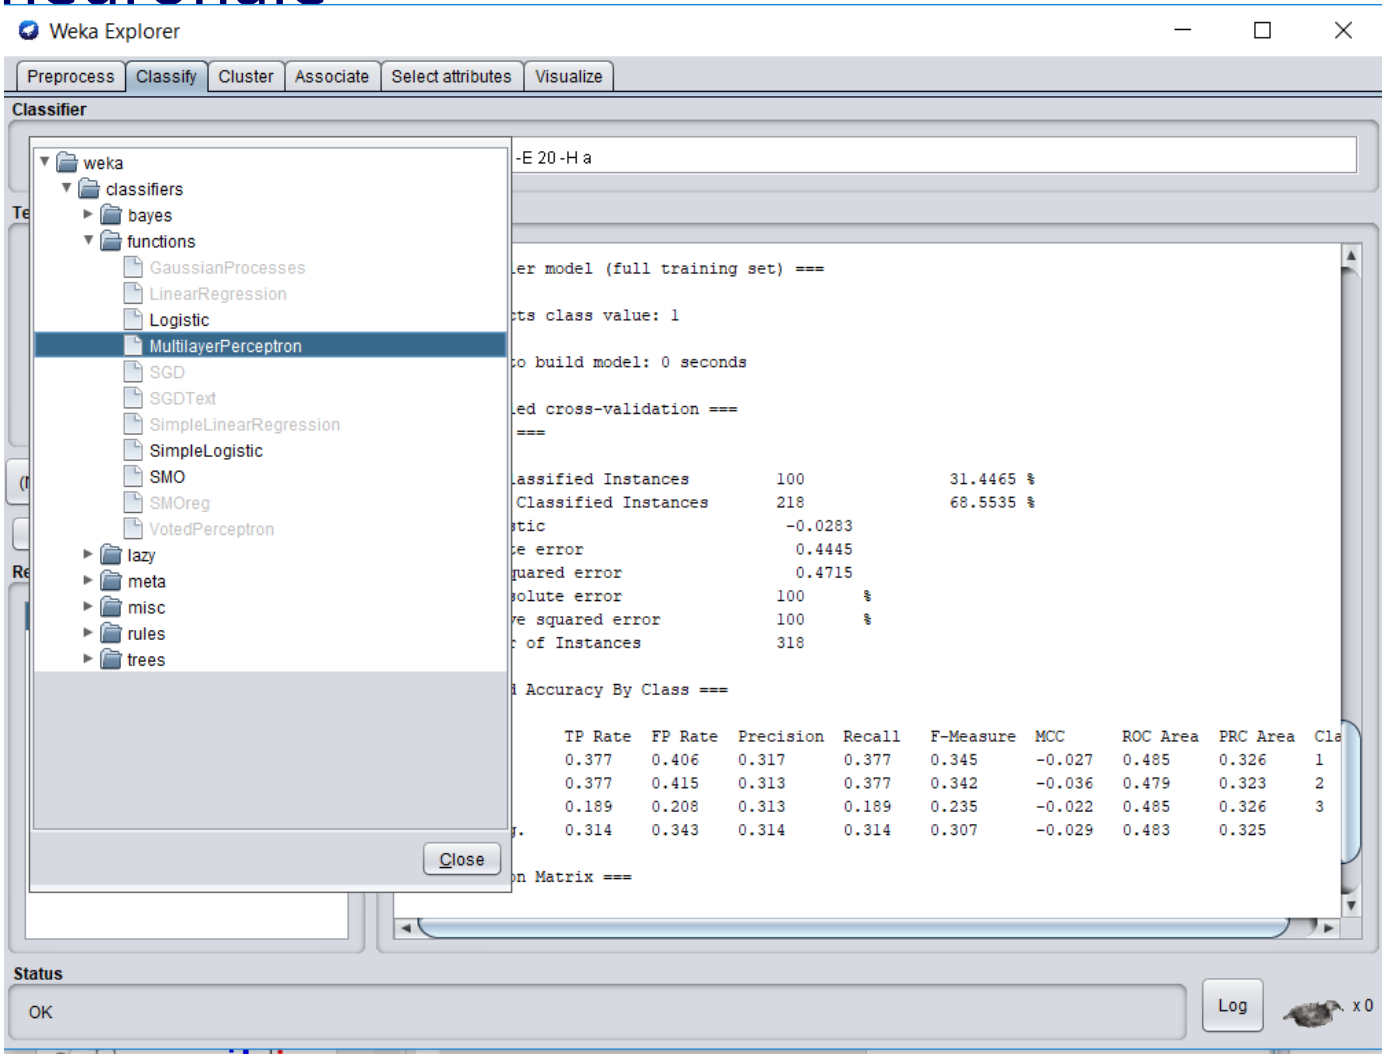

III. Modele de Machine Learning

Parametrii rețelelor neuronale

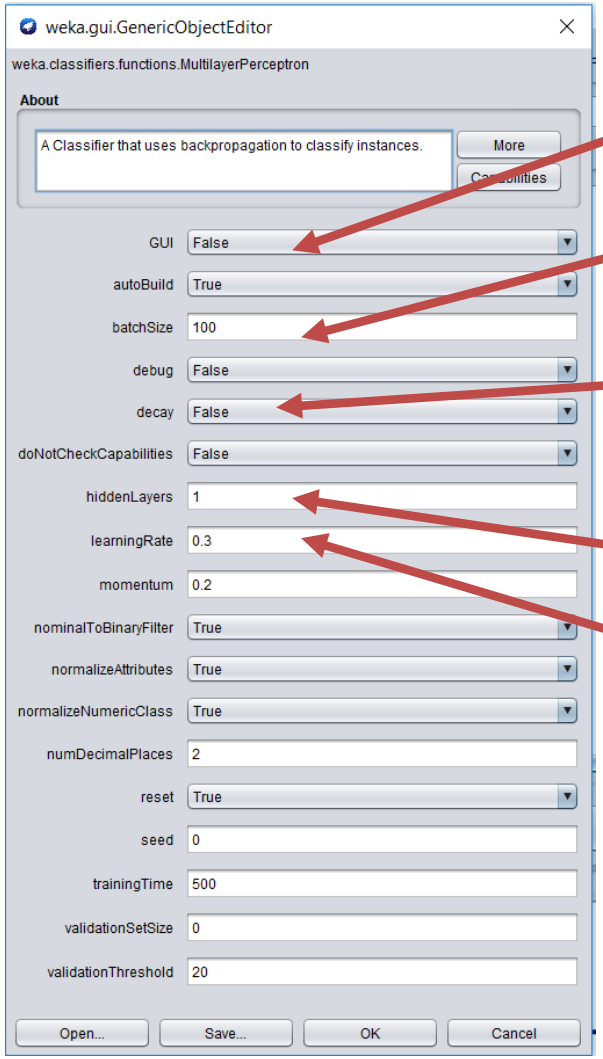

Afișare arhitectură rețea

Numărul de elemente dintr-un batch de antrenare

Valoarea ratei de învățare scade odată cu fiecare epocă

Numărul de straturi ascunse dintr-o rețea

Rata de învățare

V. Modele de Machine Learning

Support Vector Machines – model liniar

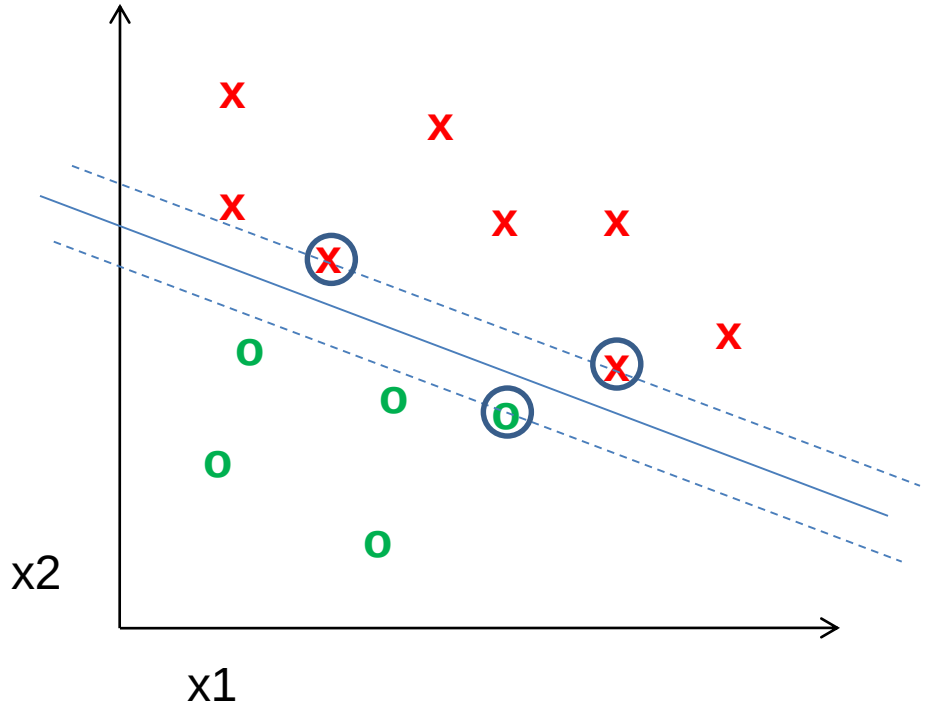

- Caută o funcţie ce separă două clase în mod optim:

$$f(\mathbf{x}) = \text{sgn}(\mathbf{w} \cdot \mathbf{x} + b)$$

III. Modele de Machine Learning

Support Vector Machines – model liniar

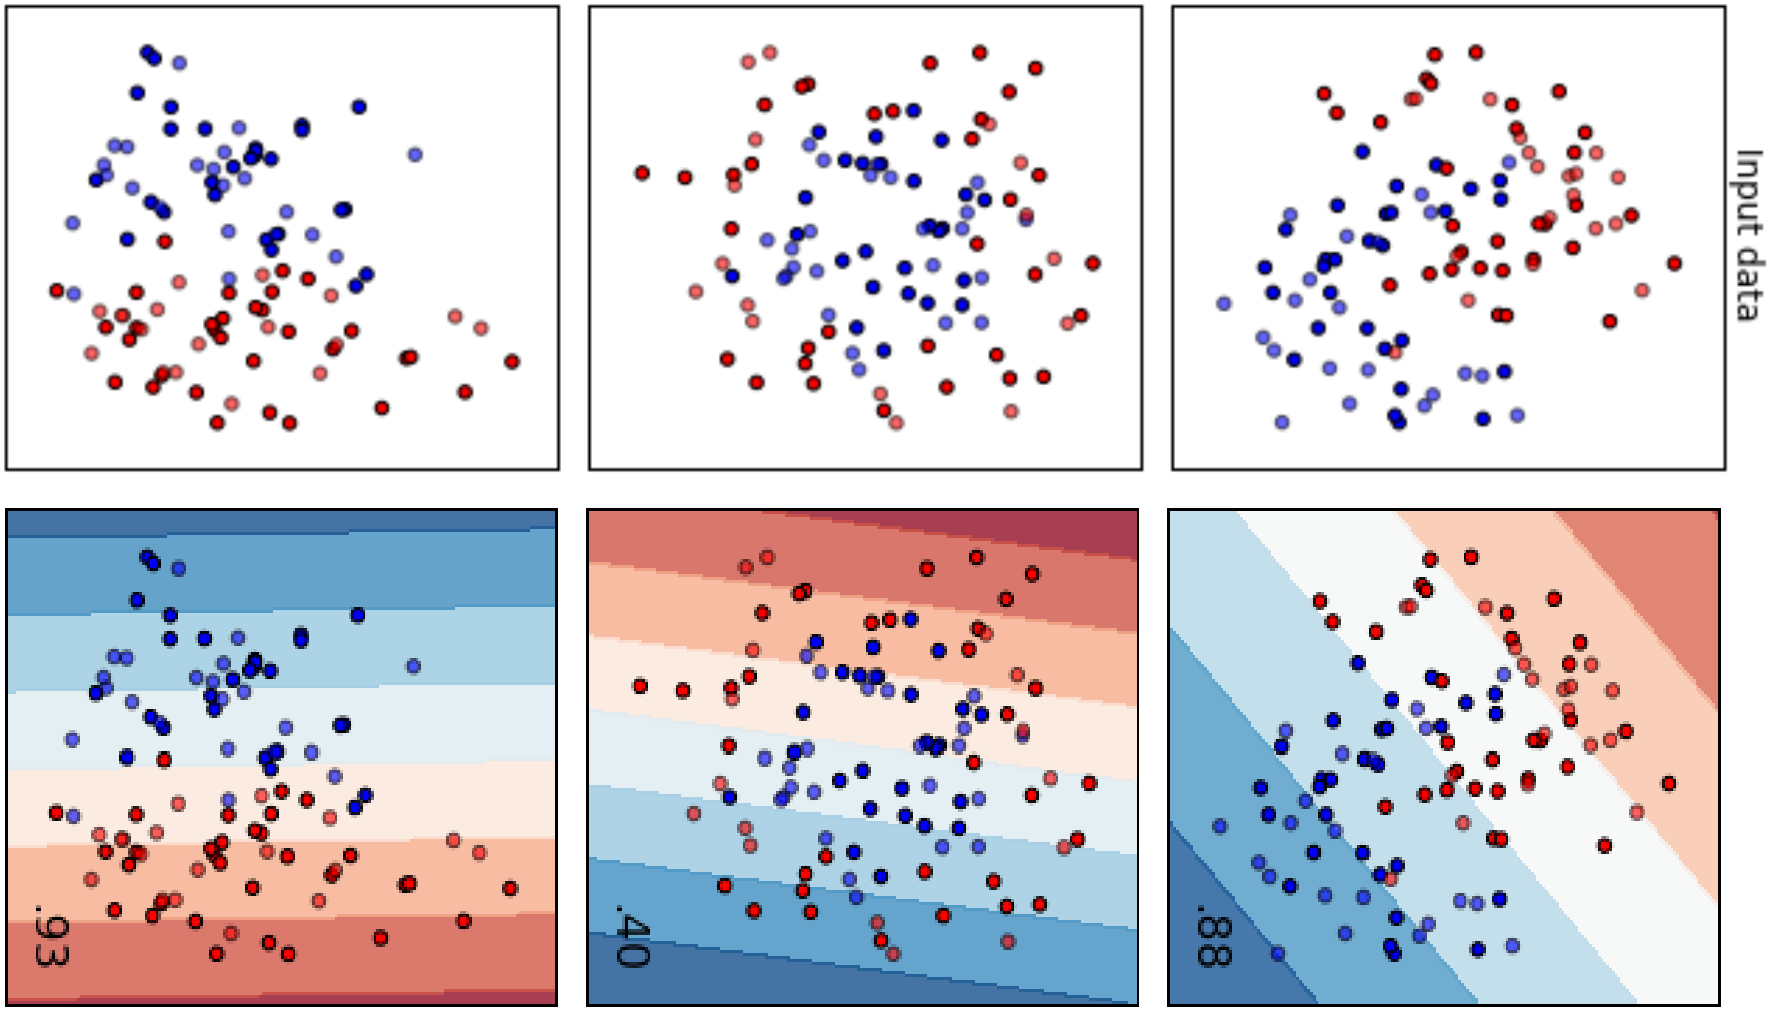

III. Modele de Machine Learning

Support Vector Machines – model neliniar

- Idee de bază: spaţiul iniţial poate fi mapat către un spaţiu multidimensional în care trăsăturile de antrenare devin liniar separabile.

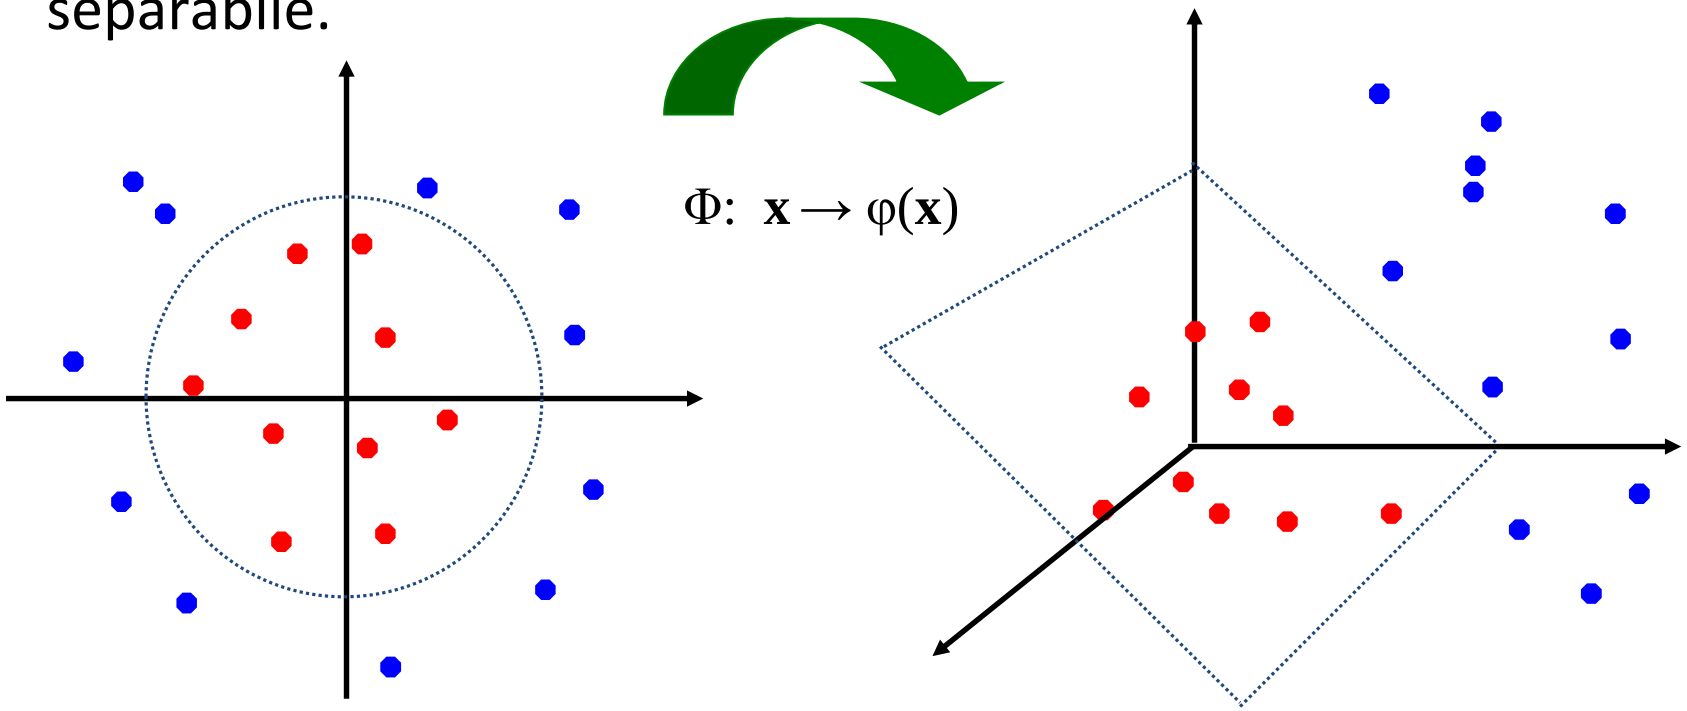

III. Modele de Machine Learning

Support Vector Machines – model neliniar

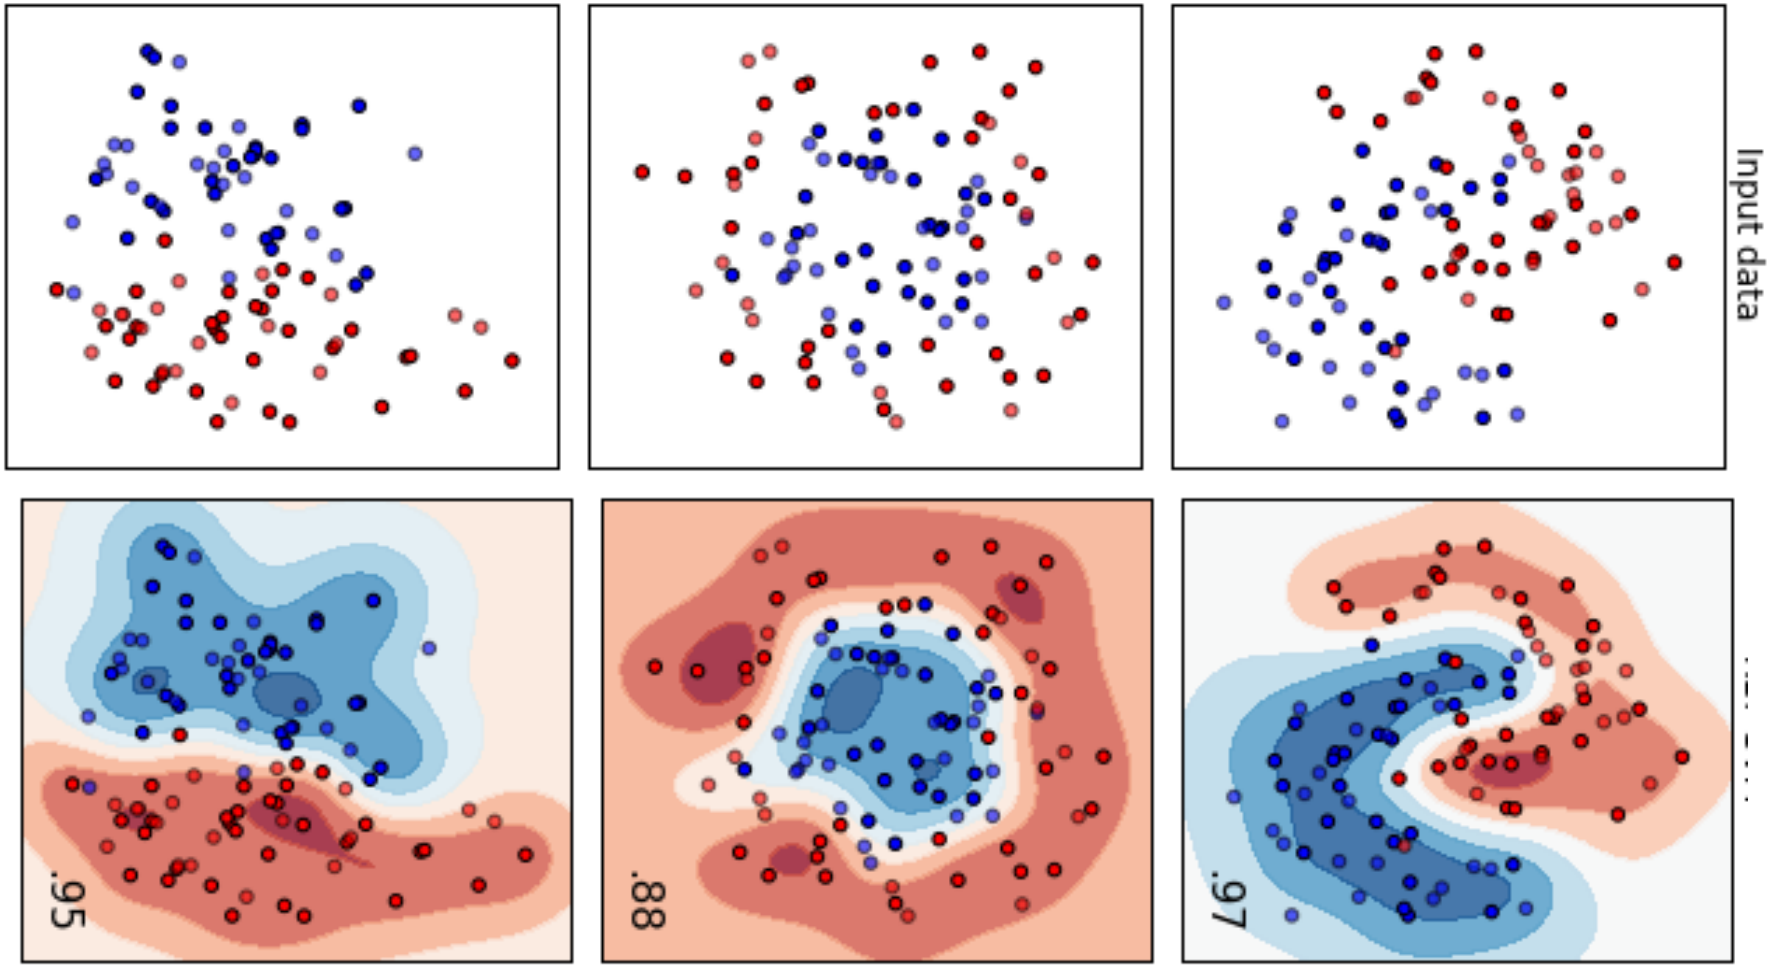

III. Modele de Machine Learning

Optimizare SVM

- C

  Modalitatea de calcul a hiperplanului de despărțire a claselor:
  - dacă modelul este prea adaptat pe date (C are o valoare mare) – modelul va suferi un proces de overfiting
  - dacă modelul va fi foarte simplu acesta nu va putea generaliza

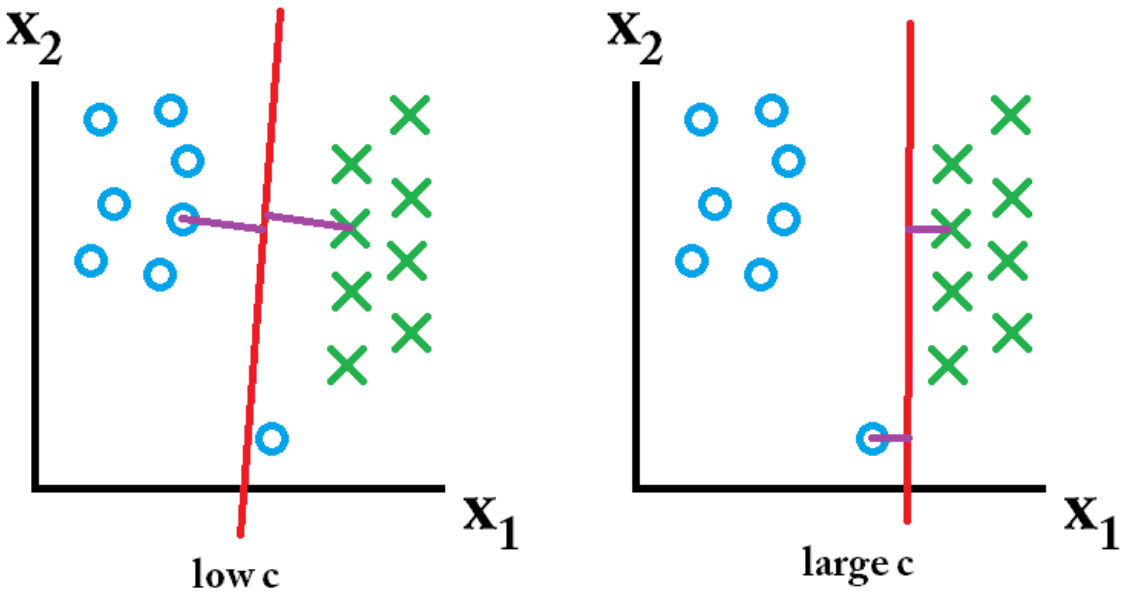

- Gamma și tipul de nucleu utilizat

III. Modele de Machine Learning

Optimizare SVM

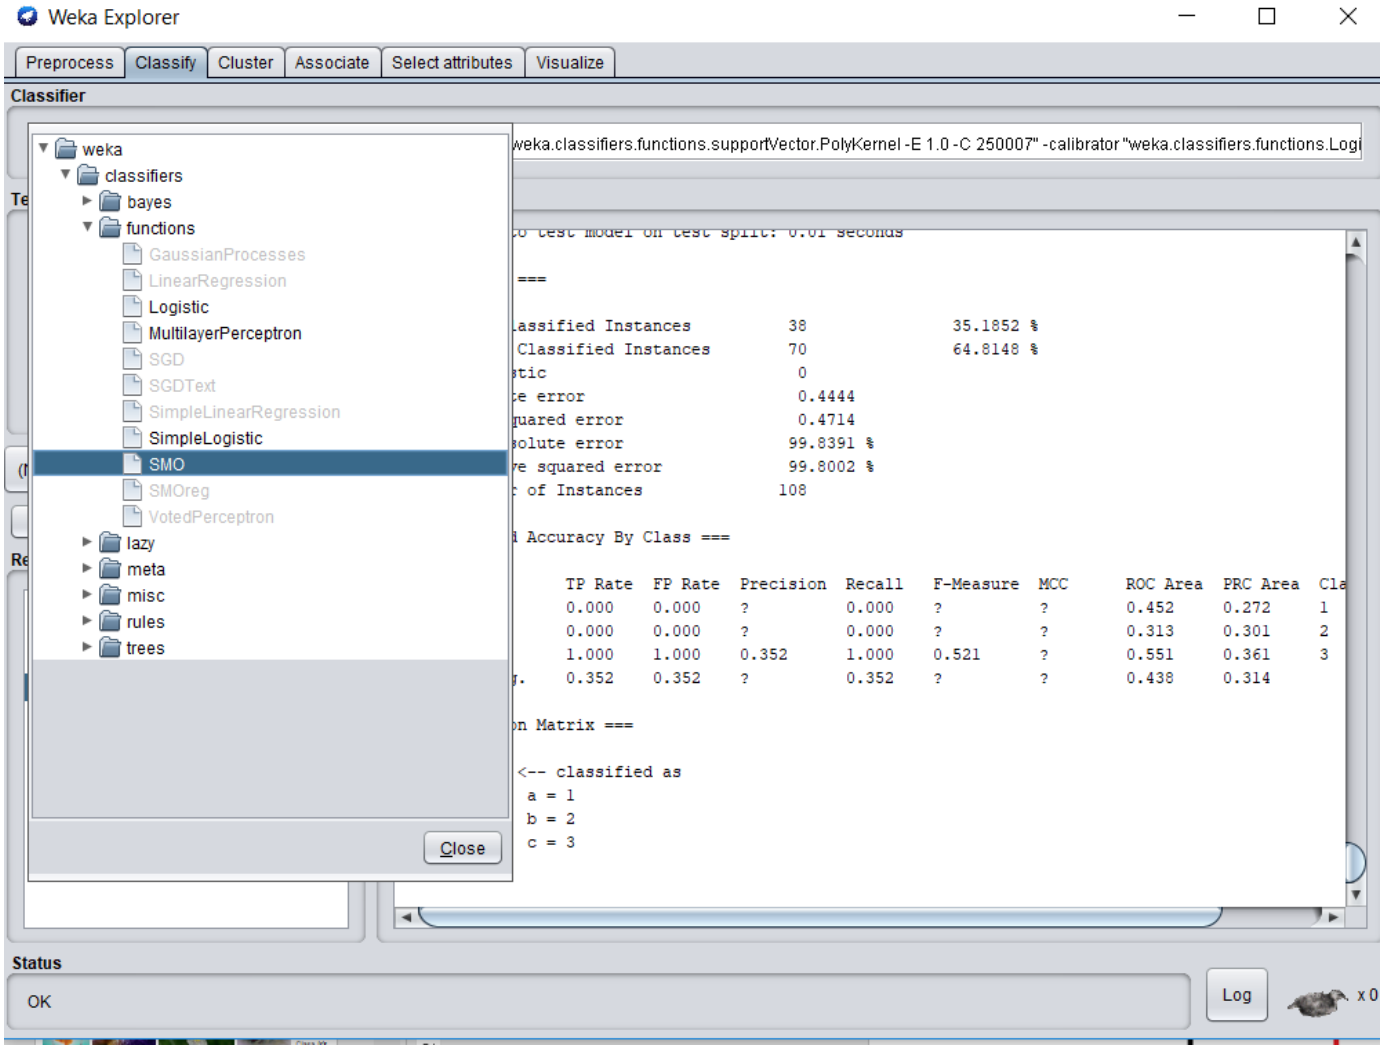

III. Modele de Machine Learning

OptimizareSVM

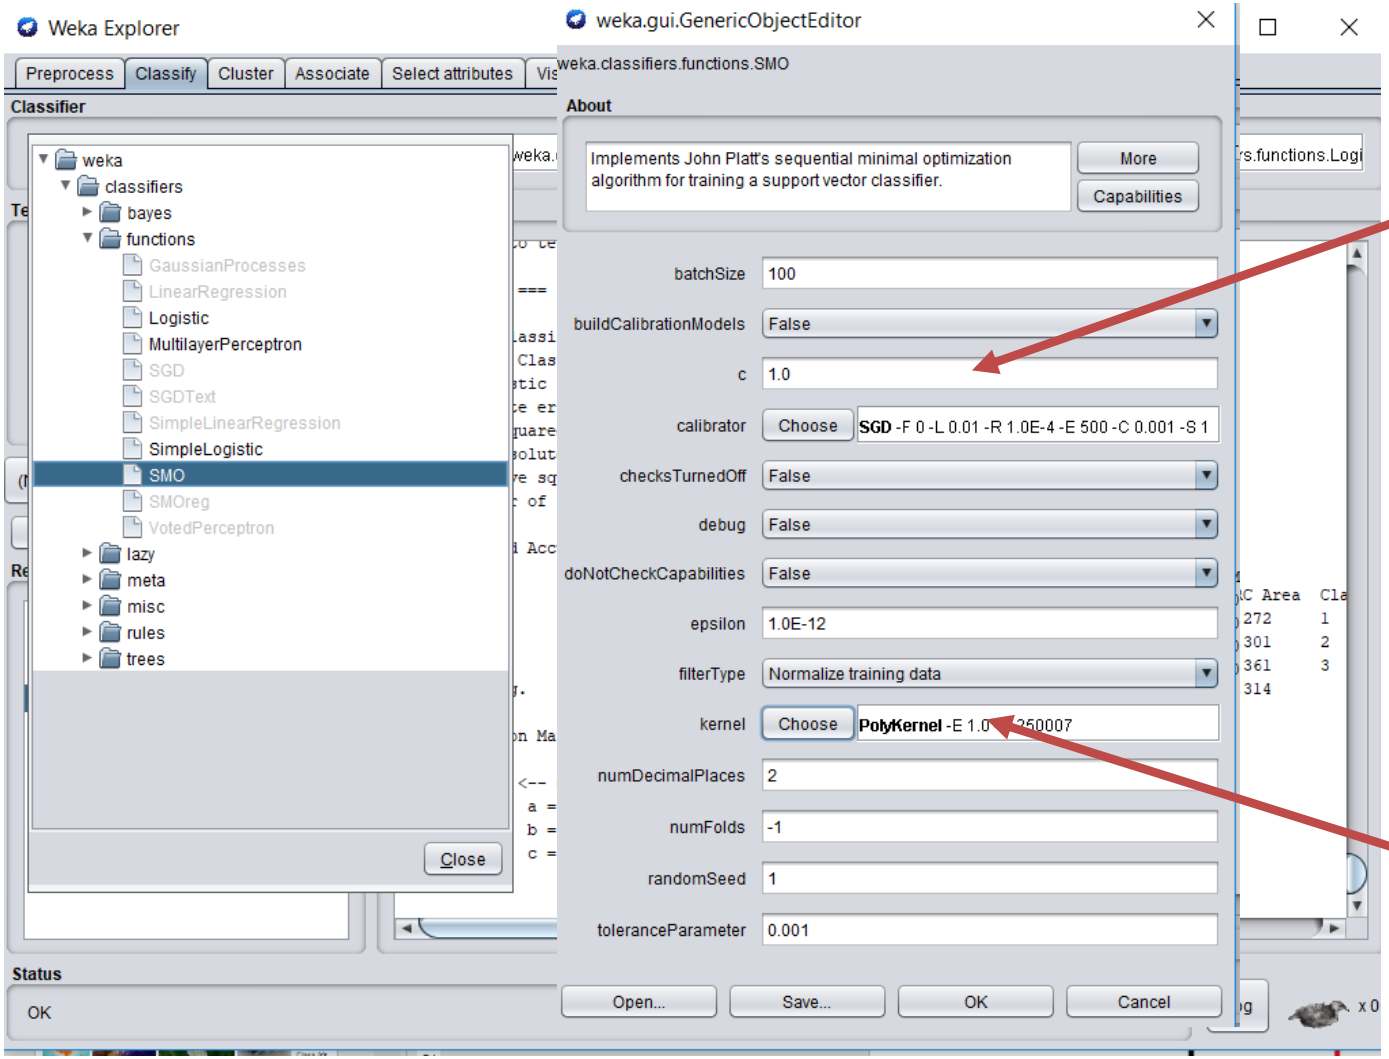

Parametrul C

Tipul de nucleu

IV. Clasificare de baze de date de imagini

Baze de date experimente laborator

Experimentele se vor efectua pe două baze de date:

- Bază de date de texturi (parte a bazei de texturi KTH – *„Textures under varying Illumination, Pose and Scale”*)
  - conține 4 clase (81 de imagini pe clasă)

- Bază de date de imagini naturale (conține 3 clase preluate din baza *Caltech 101*: prăjituri / irișI și monede) -> 3 clase (106 imagini pe clasă).

http://www.nada.kth.se/cvap/databases/kth-tips/

http://www.vision.caltech.edu/Image_Datasets/Caltech101/

IV. Clasificare de baze de date de imagini

Texturi

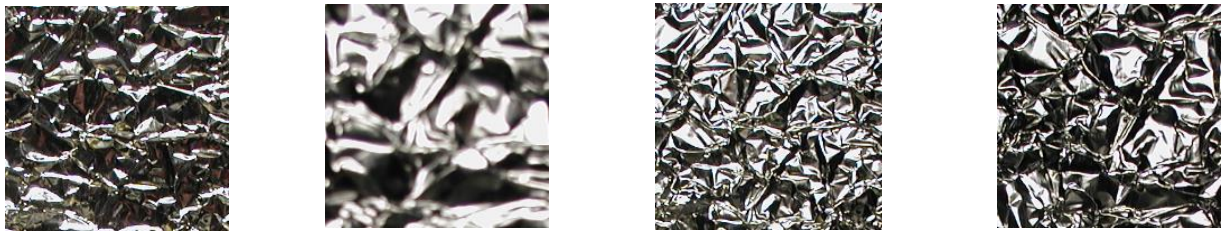

Clasa *aluminiu*

Clasa *pâine*

Clasa *țesătură*

Clasa *bumbac*

Sursă imagini **http://www.nada.kth.se/cvap/databases/kth-tips/**

IV. Clasificare de baze de date de imagini

Imagini naturale





Clasa *cake*




Clasa *coins*




Clasa *iris*

Sursă imagini **http://www.vision.caltech.edu/Image_Datasets/Caltech101/**

V. Exerciții

Pentru cele două baze de date (texturi și imagini naturale):

- Realizați un program în Matlab care calculează rând pe rând cei trei descriptori (Color Moments, LBP și HoG):
  - Salvați descriptorii în fișiere csv;
  - Transformați aceste fișiere în format arff.
- Schemă algoritm

Citește fișier de configurare (train.txt) (imagePaths, labels)

descriptors %inițializare spațiu pentru export în fișier arff

pentru fiecare imagine din bază (contor i)

- im = citesteImagine(i)

- desc = CalculDescriptor(im);

- Adaugă variabilei descriptors -» concat (desc, labels(i))

Salvează variabila descriptors în fișier

V. Exerciții

- Importați rând pe rând aceste fișiere în Weka.

- Utilizați ca și clasificatori: ZeroR, arbori de decizie (J48), Nearest Neighbor (IBK), Naive Bayes, Support Vector Machines și rețele neuronale.

- Verificați care este cea mai bună pereche clasificator / descriptor.

IV. Exerciții

- Optimizați modelul SVM (încercați mai multe valori ale lui C și mai multe tipuri de nuclee)

- Optimizați modelul de rețea neuronală utilizat

Spor!