

```

1  #-----
2  #-----
3  #Ejemplo: Clasificación de las letras J y Q
4  #
5  #En este ejemplo se diseña un clasificador simple que
6  #clasifique una de las dos letras 'J' y 'Q'.
7  #
8  #Por tanto se definen dos clases:
9  #clase 0 --> letra J, y
10 #clase 1 --> la letra Q.
11 #-----
12 #-----
13
14
15 #-----
16 #0. Setup inicial
17 #
18 #Librerías necesarias para que funcione el algoritmo.
19 #-----
20 #=====
21 import numpy as np
22 import matplotlib.pyplot as plt
23 from scipy.ndimage.morphology import binary_fill_holes
24 import seaborn as sns
25 #=====
26
27
28 #-----
29 #1. Carga de Imágenes
30 #
31 #Hay 50 imágenes por letra.
32 #Las imágenes de la letra J están almacenadas en char_01_xxx.png
33 #Las imágenes de la letra Q están almacenadas en char_02_xxx.png
34 #donde xxx = 001, 002, ..., 050
35 #-----
36 #=====
37 !wget https://www.dropbox.com/s/0xtuulag67h2gp2/JQ.zip
38 !unzip JQ.zip
39 #=====
40
41
42 #-----
43 # Funciones necesarias para que se pueda cargar una imagen individual
44 #-----
45 #=====
46 def num2fixstr(x,d):
47     # example num2fixstr(2,5) returns '00002'
48     # example num2fixstr(19,3) returns '019'
49     st = '%0*d' % (d,x)
50     return st
51
52 def ImageLoad(prefix,num_char,num_img,echo='off'):
53     # img = ImageLoad('example/char_',1,3) loads image 'example/char_01_003.png'
54     # img = ImageLoad('example/char_',2,15) loads image 'example/char_02_015.png'
55     st = prefix + num2fixstr(num_char,2) + '_' + num2fixstr(num_img,3) + '.png'
56     if echo == 'on':
57         print('loading image '+st+'...')
58     img = plt.imread(st)
59     return img
60 #=====
61
62
63 #-----
64 # Lectura de una imagen J
65 #-----
66 #=====
67 fig = plt.figure()
68 ax = fig.add_subplot(111)
69 img = ImageLoad('example/char_',1,3,echo='on')

```

```

70  imshow = plt.imshow(img,cmap='gray')
71  #=====
72
73
74  #-----
75  # Lectura de una imagen Q
76  #-----
77  #=====
78
79  fig      = plt.figure()
80  ax       = fig.add_subplot(111)
81  img      = ImageLoad('example/char_',2,43,echo='on')
82  imshow   = plt.imshow(img,cmap='gray')
83  #=====
84
85
86  #-----
87  #2. Extracción de Características
88  #-----
89  #=====
90  # La letra Q es más grande en pixeles que la letra J
91  # La característica a extraer es el area normalizada, definida como el numero de
92  # pixeles de la letra (rellena, sin agujeros) dividido por el número de pixeles de la
93  # imagen. Esta característica es un número entre 0 y 1, es invariante al tamaño
94  # y además invariante a la rotación.
95
96  def AreaNormalizada(img,echo='off'):
97      R = img>0.5 # segmentacion, R ahora es una imagen binaria
98      R = binary_fill_holes(R).astype(int) # imagen con relleno de agujeros
99      CharArea = np.sum(R) # area de la letra en pixeles
100     ImgArea   = R.shape[0]*R.shape[1] # numero de pixeles de la imagen
101     AreaN     = CharArea/ImgArea # area normalizada
102     if echo=='on':
103         imshow = plt.imshow(R,cmap='gray')
104         print('Area normalizada = '+str(AreaN))
105     return AreaN
106 #=====
107
108
109 #-----
110 # Ejemplo de esta característica para una letra J
111 #-----
112 #=====
113 imgJ = ImageLoad('example/char_',1,13,echo='on')
114 AreaNJ = AreaNormalizada(imgJ,echo='on')
115 #=====
116
117
118 #-----
119 # Ejemplo de esta característica para una letra Q
120 #-----
121 #=====
122 imgQ = ImageLoad('example/char_',2,19,echo='on')
123 AreaNQ = AreaNormalizada(imgQ,echo='on')
124 #=====
125
126
127 #-----
128 # Extracción de la característica AreaNormalizada en todas las imágenes
129 # Clase 0 = 'J' : Clase 1 = 'Q'
130 #-----
131 #=====
132 K = 2 # número de clases
133 N = 50 # número de imágenes por clase
134
135 X = np.zeros((N,K))
136
137 for j in range(K): # para cada clase
138     for i in range(N): # para cada imagen de la clase

```

```

139     # Lectura de la imagen
140     img      = ImageLoad('example/char_',j+1,i+1,echo='on')
141     # Extracción de característica
142     X[i,j] = AreaNormalizada(img)
143     #=====
144
145
146     #-----
147     # Definición de conjuntos de training y testing
148     #-----
149     # Training: las primeras 40 letras de cada clase
150     #-----
151     #=====
152     X0_train = X[0:40,0]
153     X1_train = X[0:40,1]
154     #=====
155     #-----
156     # Testing: las ultimas 10 letras de cada clase
157     #-----
158     #=====
159     X0_test = X[40:50,0]
160     X1_test = X[40:50,1]
161     #=====
162     #-----
163     # Estadísticas del Training
164     #-----
165     #=====
166     x0_max = np.max(X0_train)
167     x1_max = np.max(X1_train)
168
169     x0_min = np.min(X0_train)
170     x1_min = np.min(X1_train)
171
172     x0_mean = np.mean(X0_train)
173     x1_mean = np.mean(X1_train)
174
175     print('Estadísticas de la característica extraída en el Training:')
176
177     print('Clase 0 (J):')
178     print('>>>> min   = '+str(x0_min))
179     print('>>>> mean  = '+str(x0_mean))
180     print('>>>> max   = '+str(x0_max))
181     print(' ')
182     print('Clase 1 (Q):')
183     print('>>>> min   = '+str(x1_min))
184     print('>>>> mean  = '+str(x1_mean))
185     print('>>>> max   = '+str(x1_max))
186     #=====
187
188
189     #-----
190     # Distribución de frecuencias por clase
191     #-----
192     #=====
193     sns.displot([X0_train,X1_train],bins=20)
194     #=====
195     #-----
196     # en este gráfico se muestra como distribuye la letra J (clase 0 a la izquierda),
197     # y la letra Q (clase 1 a la derecha)
198     #-----
199
200
201     #-----
202     #3. Clasificación
203     #-----
204     #-----
205     # La clasificación se puede hacer usando un umbral (th) calculado como el
206     # promedio de las medias de cada clase
207     #-----

```

```

208 #=====
209 th = (x0_mean + x1_mean)/2
210
211 print('th = '+str(th))
212 #=====
213
214
215 #-----
216 #3. Clasificación
217 #-----
218 #=====
219 Y = (X>th) # Clase 0 es menor o igual que el umbral, Clase 1 es mayor que el umbral
220 #=====
221
222
223 #-----
224 # Clasificación del conjunto de testing
225 #-----
226 #=====
227 Y0_test = Y[40:50,0] # clasificación de las letras J de testing
228 Y1_test = Y[40:50,1] # clasificación de las letras Q de testing
229 #=====
230
231
232 #-----
233 #4. Evaluación
234 #-----
235 # Evaluación del conjunto Testing
236 #-----
237 # Letras bien clasificadas
238 #-----
239 #=====
240 Jtrue = np.sum(Y0_test==0) # letras J bien clasificadas
241 Qtrue = np.sum(Y1_test==1) # letras Q bien clasificadas
242 #=====
243
244 #-----
245 # Letras mal clasificadas
246 #-----
247 #=====
248 Jfalse = np.sum(Y0_test==1) # letras J mal clasificadas
249 Qfalse = np.sum(Y1_test==0) # letras Q mal clasificadas
250 #=====
251
252 #-----
253 # Matriz de confusión MC[i,j] = letras de clase i clasificadas como clase j
254 #-----
255 #=====
256 MC = np.zeros((2,2))
257 MC[0,0] = Jtrue
258 MC[0,1] = Jfalse
259 MC[1,0] = Qfalse
260 MC[1,1] = Qtrue
261 #=====
262
263 #-----
264 # Accuracy (% de aciertos)
265 #-----
266 #=====
267 Acc = (Jtrue+Qtrue)/(Jtrue+Jfalse+Qfalse+Qtrue)*100
268
269 print('Matriz de Confusión:')
270 print(MC[0,:])
271 print(MC[1,:])
272
273 print('')
274 print('Accuracy = '+str(Acc)+'%')
275 #=====
276 #=====

```

