

```

1  #Le programme présenté ici est en dimension n.
2  #Si on prend n=2, on se retrouve dans R^2, comme l illustration du cours
3
4
5  import numpy as np
6  import matplotlib.pyplot as plt
7  import random as rd
8  import time #pour faire des pauses dans l'affichage
9
10 #####
11 #####
12 # Première partie "facile": affichage dun nuage de points et de centres choisis au
   hasard
13
14
15 #génération d'un nuage de points
16 def points_random(n,p):
17     '''retourne une liste de p points de R^n, de coordnonnées aléatoires entre 0 et
   100'''
18     liste=[]
19     for i in range(p):
20         point=[rd.randint(0,100) for j in range(n)] #génère n coordonnées du point
21         liste.append(point)
22     return liste
23
24 #tracé de ce nuage
25 n=2 #on se place en dimension 2
26 p=300 #on va prendre 300 points
27 liste_points=points_random(n,p)
28 listeX=[liste_points[i][0] for i in range(p)] #on récupère les abscisses
29 listeY=[liste_points[i][1] for i in range(p)] #on récupère les ordonnées
30 plt.plot(listeX,listeY,'ob')
31 plt.show()
32
33 #choix de k centres au hasard
34 def debut(liste,k):
35     '''choisit au hasard k points distincts parmi la liste'''
36     #attention rd.choices(liste,k=k) ne fonctionne pas car il peut y avoir des
   répétions
37     choix=[]
38     while len(choix)<k:
39         x=rd.choice(liste)
40         if x not in choix:
41             choix.append(x)
42     return choix
43
44 #tracé des centres en plus du nuage
45 n=2 #on se place en dimension 2
46 p=300 #on va prendre 300 points
47 liste_points=points_random(n,p)
48 listeX=[liste_points[i][0] for i in range(p)] #on récupère les abscisses
49 listeY=[liste_points[i][1] for i in range(p)] #on récupère les ordonnées
50 plt.plot(listeX,listeY,'ob')
51
52 liste_centres=debut(liste_points,3) #on va faire 3 classes
53 listecX=[liste_centres[i][0] for i in range(3)] #on récupère les abscisses
54 listecY=[liste_centres[i][1] for i in range(3)] #on récupère les ordonnées
55 plt.plot(listecX,listecY,'*r')
56 plt.show()
57
58 #####
59 #####
60 # Programmation de l algorithme des k moyennes
61
62 def distance(A,B):
63     '''distance euclidienne entre deux points
   A et B sont deux couples si on est dans R^2(les coordonnées des deux points)'''
64     d=0
65     for i in range(len(A)):
66         d+=(A[i]-B[i])**2
67     return np.sqrt(d)
68
69

```

```

70 def centre(liste):
71     '''calcule l'isobarycentre d'une liste de points'''
72     p=len(liste) #le nombre de points
73     #p ne pourra pas être nul car il y aura toujours au moins le centre
74     n=len(liste[0]) #la dimension de nos points
75
76     c=[] #pour stocker les coordonnées du centre
77     for i in range(n):#calcul de la ième coordonnée du centre
78         s=0
79         for point in liste:
80             s+=point[i]
81         c.append(s/p)
82     return c
83
84
85
86 def clusters(Lc,Lp):
87     '''Lc est la liste des centres, Lp la liste des points,retourne la liste des
88     clusters'''
89     k=len(Lc) #le nombre de clusters
90     liste_clusters=[[[] for i in range(k)] #toutes les listes sont vides au début
91     for point in Lp: #on va affecter chaque point à un cluster
92         i_min=0
93         d_min=np.inf
94         for i in range(k):
95             d=distance(point,Lc[i])
96             if d<d_min:
97                 i_min=i
98                 d_min=d
99         liste_clusters[i_min].append(point)
100     return liste_clusters
101
102 def arret(Lc_old,Lc_new,epsilon):
103     '''retourne False si certains centres de classe ont bougé de plus de epsilon
104     retourne True sinon, dans ce cas on arretera le programme'''
105     k=len(Lc_old)
106     test=True
107     for i in range(k):
108         if distance(Lc_old[i],Lc_new[i])>epsilon:
109             test=False
110     #le test sera encore True si toutes les distances ont été plus petites que epsilon
111     return test
112
113
114 def kmeans(Lp,k,epsilon):
115     '''à partir d'une liste de points Lp, va retourner une liste de k centres
116     une liste de k clusters, et un compteur indiquant le nombre d'iterations'''
117     Lc=debut(Lp,k) #on initialise aléatoirement les centres
118     test=False
119     compteur=0 #pour savoir combien d'itérations seront nécessaires
120     while test==False:
121         compteur+=1
122         liste_clusters=clusters(Lc,Lp) #la liste des clusters
123
124         #on va recalculer tous les centres
125         Lc_new=[]
126         for liste in liste_clusters:
127             Lc_new.append(centre(liste))
128
129         test=arret(Lc,Lc_new,epsilon)
130
131         Lc=Lc_new #on actualise les centres
132
133     return Lc,liste_clusters,compteur
134
135
136 def kmeans_tracé(Lp,k,epsilon):
137     numéro=0 #pour numéroté les figures sauvegardées
138
139     #un choix de k couleurs au hasard
140     liste_couleurs = [[rd.random(),rd.random(),rd.random()] for i in range(k)]

```

```

141
142 Lc=debut(Lp,k) #on initialise aléatoirement les centres
143
144 #tracé de tous les individus et des premiers centres
145 liste_x=[coord[0] for coord in Lp]
146 liste_y=[coord[1] for coord in Lp]
147 plt.plot(liste_x,liste_y,'ob')
148 listec_x=[coord[0] for coord in Lc]
149 listec_y=[coord[1] for coord in Lc]
150 plt.scatter(listec_x,listec_y,s=300,marker='*',color='red')
151 plt.savefig('étape'+str(numéro)+'.png')
152 plt.show()
153 time.sleep(3) #pause de 2 secondes
154 numéro+=1
155
156 test=False
157 compteur=0 #pour savoir combien d'itérations seront nécessaires
158 while test==False and compteur<3:
159
160     compteur+=1
161     liste_clusters=clusters(Lc,Lp) #la liste des clusters
162
163     #le tracé
164     i=0
165     for liste in liste_clusters:
166         couleur=liste_couleurs[i]
167         liste_x=[coord[0] for coord in liste]
168         liste_y=[coord[1] for coord in liste]
169         plt.plot(liste_x,liste_y,'o',color=couleur)
170         i+=1
171     listec_x=[coord[0] for coord in Lc]
172     listec_y=[coord[1] for coord in Lc]
173     plt.scatter(listec_x,listec_y,s=300,marker='*',color='red')
174     plt.savefig('étape'+str(numéro)+'.png')
175     plt.show()
176     time.sleep(2) #pause de 2 secondes
177     numéro+=1
178
179     #on va recalculer tous les centres
180     Lc_new=[]
181     for liste in liste_clusters:
182         Lc_new.append(centre(liste))
183
184
185     test=arret(Lc,Lc_new,epsilon)
186
187     Lc=Lc_new #on actualise les centres
188
189     #le tracé
190     i=0
191     for liste in liste_clusters:
192         couleur=liste_couleurs[i]
193         liste_x=[coord[0] for coord in liste]
194         liste_y=[coord[1] for coord in liste]
195         plt.plot(liste_x,liste_y,'o',color=couleur)
196         i+=1
197     listec_x=[coord[0] for coord in Lc]
198     listec_y=[coord[1] for coord in Lc]
199     plt.scatter(listec_x,listec_y,s=300,marker='*',color='red')
200     plt.savefig('étape'+str(numéro)+'.png')
201     plt.show()
202     time.sleep(2) #pause de 2 secondes
203     numéro+=1
204
205     print(compteur)
206
207 #exécution de notre programme
208 n=2 #on se place en dimension 2
209 p=300 #on va prendre 300 points
210 liste_points=points_random(n,p)
211
212 kmeans_tracé(liste_points,3,0.0001)

```