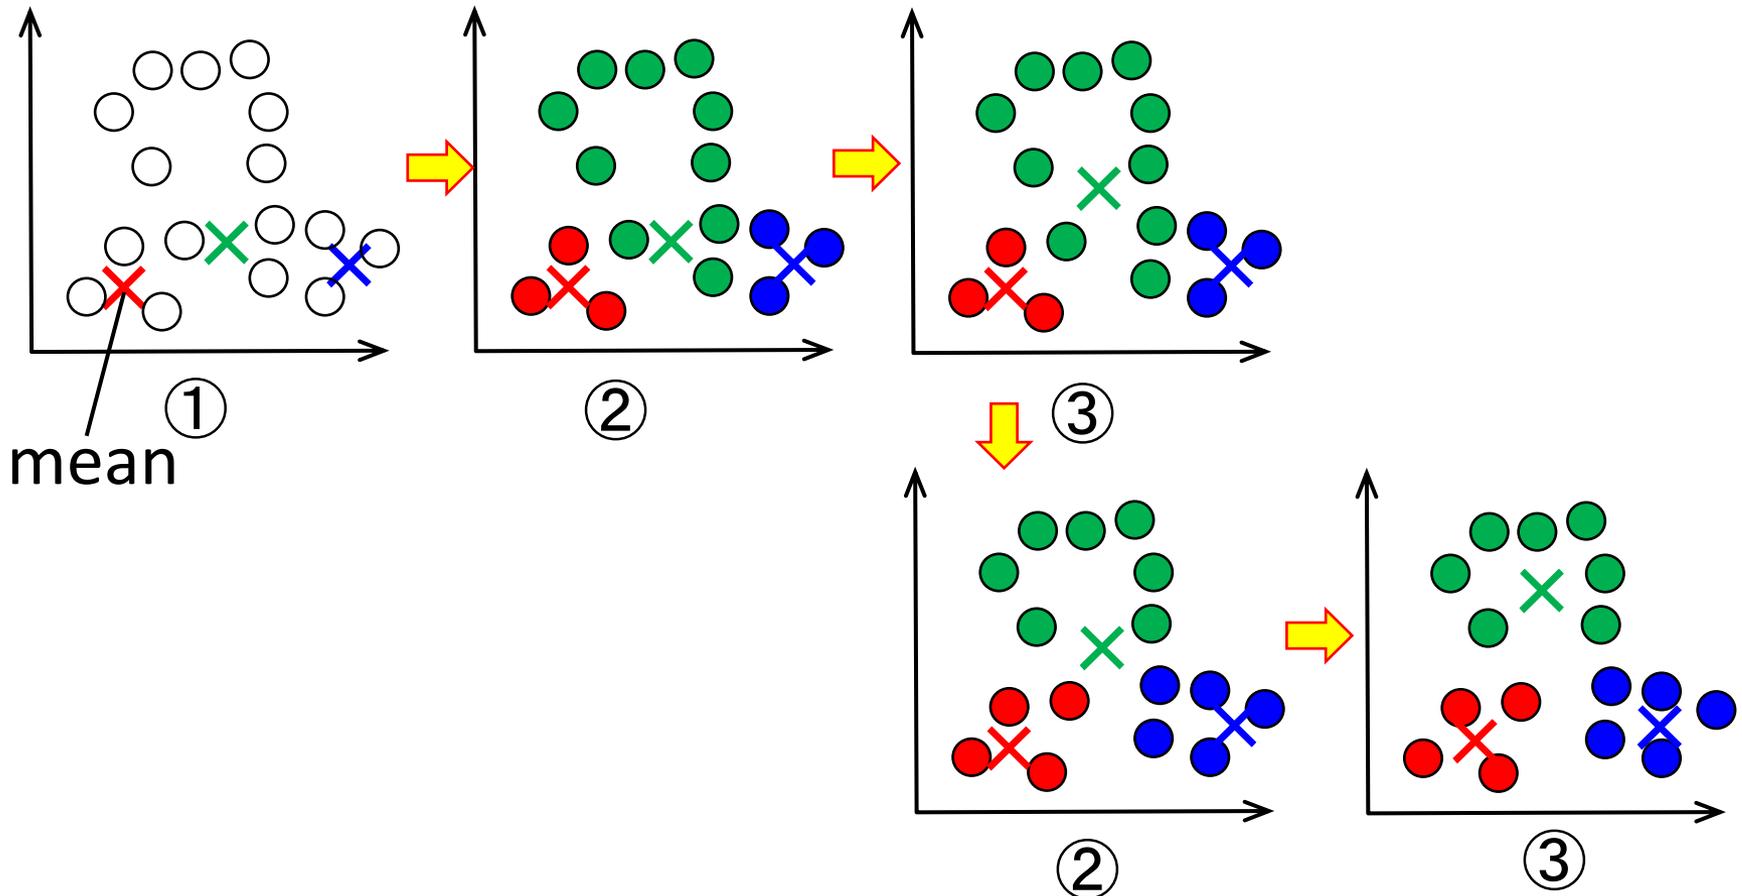


# k-means (k-平均法)

- ① データの中で適当のk個の"mean"を選択
- ② 最も近いmeanに基づいてk個に分割
- ③ k個のクラスタの重心を算出して、新たな"means"とする
- ④ 上記②、③を繰り返して、変わらなくなるまで繰り返す



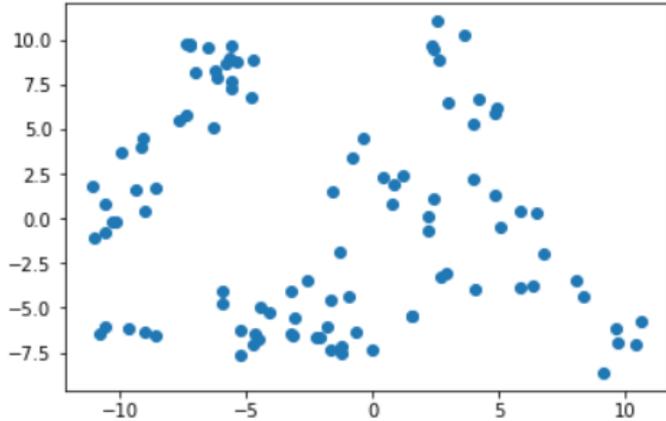
```
In [5]: %matplotlib inline
from sklearn import datasets
from sklearn.cluster import KMeans
import matplotlib.pyplot as plt
X,y = datasets.make_blobs(centers=20,random_state=5)
plt.scatter(X[:,0],X[:,1])
plt.show()
```

データセットを読み込

KMeansを読み込

塊の数

xに0列目、yに1列目の値を入れた散布図

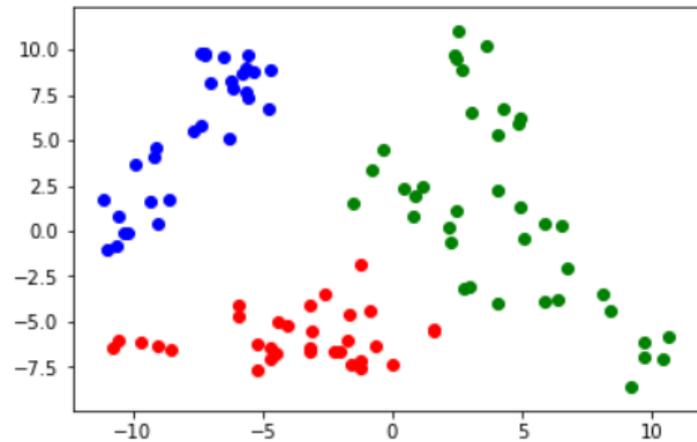


kmeansでクラスタリング実行

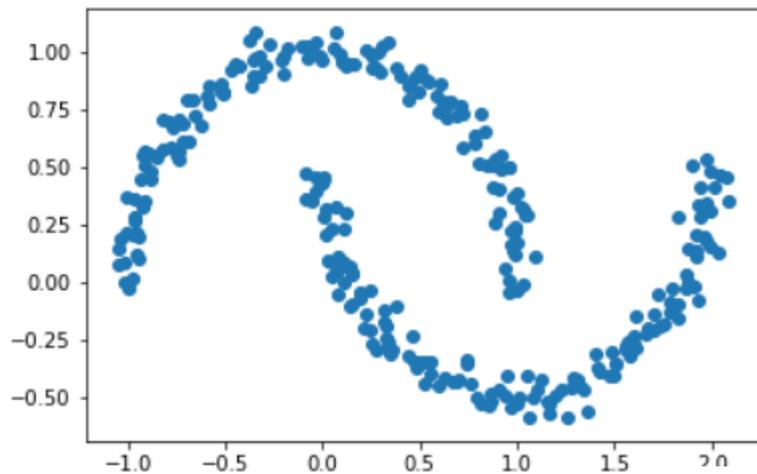
クラスタは3種類

```
In [7]: kmeans = KMeans(n_clusters=3)
kmeans.fit(X)
plt.scatter(X[kmeans.labels_==0,0],X[kmeans.labels_==0,1],c="red")
plt.scatter(X[kmeans.labels_==1,0],X[kmeans.labels_==1,1],c="blue")
plt.scatter(X[kmeans.labels_==2,0],X[kmeans.labels_==2,1],c="green")
plt.show()
```

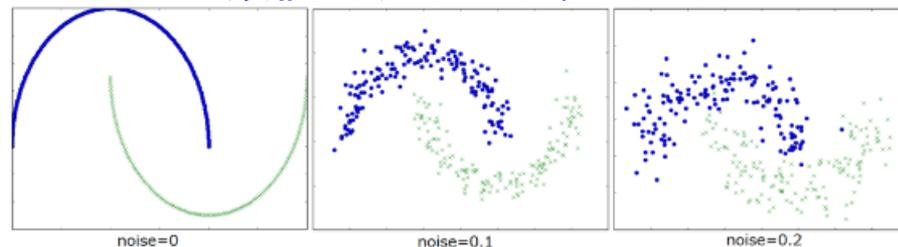
クラスタ0の0列目をx、1列目をyにして赤色で散布図



In [11]: `X,y = datasets.make_moons(n_samples=300,noise=.05)` ← 月形状のデータセットを読み込  
`plt.scatter(X[:,0],X[:,1])` ← xに0列目、yに1列目の値を入れた散布図  
`plt.show()`



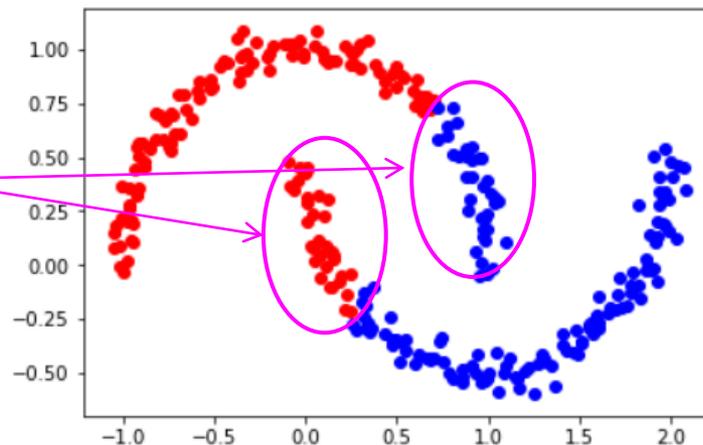
noiseの数値で以下のようにプロット



kmeansでクラスタリング実行  
クラスタは2種類

In [12]: `kmeans = KMeans(n_clusters=2)`  
`kmeans.fit(X)`  
`plt.scatter(X[kmeans.labels_==0,0],X[kmeans.labels_==0,1],c="red")`  
`plt.scatter(X[kmeans.labels_==1,0],X[kmeans.labels_==1,1],c="blue")`  
`plt.show()`

クラスタ0の0列目をx、1列目をyにして  
赤色で散布図



kmeans法では、クラスタリング失敗