記事
Minoru Horita · 2020年6月26日 6m read

アイリスデータセットのK平均クラスタリング

アイリスデータセットのK平均クラスタリング

みなさん、こんにちは。 今回はアイリスデータセットでk平均アルゴリズムを使用します。

注意：Ubuntu 18.04、Apache Zeppelin 0.8.0、python 3.6.5で以下を実行しました。

概要

K平均法は、クラスタリングの問題を解決する最も単純な教師なし学習アルゴリズムの1つです。 このアルゴリズムは、同じグループ内のオブジェクト（グループはクラスターです）が他のグループ内のオブジェクトよりも（意味的に）互いに類似するようにすべてのオブジェクトをグループ化します。
例えば、緑の芝生に赤いボールのある画像があるとします。
K平均法はすべてのピクセルを2つのクラスターに分割します。
1番目のクラスターにはボールのピクセルが含まれ、2番目のクラスターには芝生のピクセルが含まれます。

アイリスデータセットは、3種のアイリスの花の特徴をいくつか含むテーブルです。 種には「Iris-setosa」、「Iris-versicolor」、「Iris-virginica」があります。
それぞれの花には5つの特徴（**花びらの長さ**、**花びらの幅**、**がく片の長さ**、**がく片の幅**、**種**）があります。

要件の確認

まず、すべての要件を確認しましょう。 次のように、ターミナルに「**which python3**」貼り付けてください。

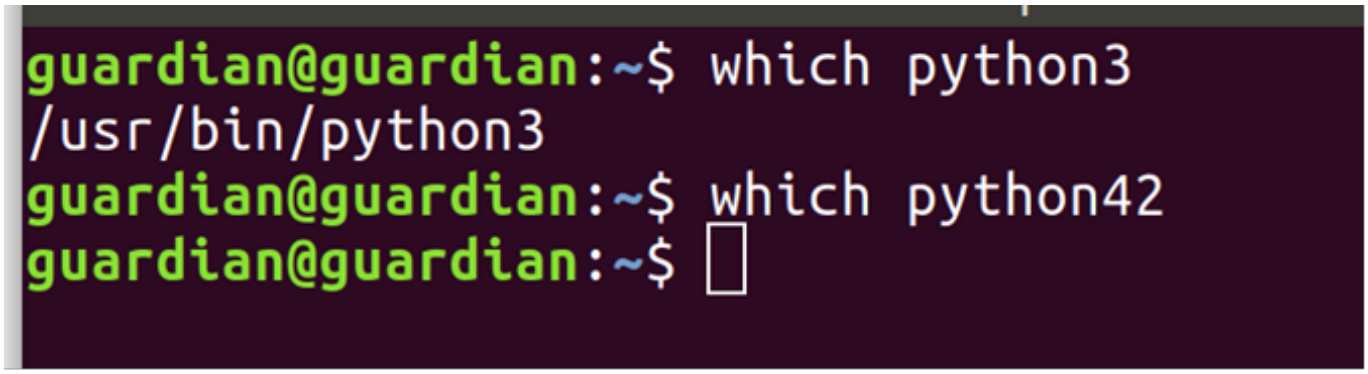

Python 3がインストール
されている場合は、最初のパスが表示されます。
空の場合（「**which python42**」の出力のように表示される場合）、ターミナルに以下を貼り付けてください。

```
sudo apt-get update

sudo apt-get -y upgrade

sudo apt install python3

sudo apt-get install -y python3-pip
```

次に、pysparkをインストールします。

```
pip3 install pyspark
```

Spark インタープリターの設定で、zeppelin.pyspark.python
を「which python3」で出力されたパスに変更してください。

zeppelin.pyspark.python	/usr/bin/python3

最後にSparkインタープリターで新しいメモを作成し、以下を新しい段落に貼り付けて実行してください。

```
%pyspark
import sys
print(sys.version)
```

何も問題なければ、Pythonのバージョンが表示されます。

```
%pyspark
import sys
print(sys.version)

3.6.5 (default, Apr  1 2018, 05:46:30)
[GCC 7.3.0]
```

クラスタリング

InterSyst
ems IRISをセットアップし、ZeppelinおよびSparkと連携できるようにします。 例えば、 以前のInterSystems IRIS、Apache Zeppelin、Apache Spark接続に関する記事を参照してください。

まず、次のようにアイリスデータセットをロードします。

```
%pyspark
dataFrame=spark.read.format("com.intersystems.spark").\
option("url", "IRIS://localhost:51773/NEWSAMPLE").option("user", "dev").\
option("password", "123").\
option("dbtable", "DataMining.IrisDataset").load()

dataFrame.show()
```

```
+---+-----------+----------+-----------+----------+-----------+
| ID|PetalLength|PetalWidth|SepalLength|SepalWidth|    Species|
+---+-----------+----------+-----------+----------+-----------+
|  1|        1.4|       0.2|        5.1|       3.5|Iris-setosa|
|  2|        1.4|       0.2|        4.9|       3.0|Iris-setosa|
|  3|        1.3|       0.2|        4.7|       3.2|Iris-setosa|
|  4|        1.5|       0.2|        4.6|       3.1|Iris-setosa|
|  5|        1.4|       0.2|        5.0|       3.6|Iris-setosa|
|  6|        1.7|       0.4|        5.4|       3.9|Iris-setosa|
|  7|        1.4|       0.3|        4.6|       3.4|Iris-setosa|
|  8|        1.5|       0.2|        5.0|       3.4|Iris-setosa|
|  9|        1.4|       0.2|        4.4|       2.9|Iris-setosa|
| 10|        1.5|       0.1|        4.9|       3.1|Iris-setosa|
| 11|        1.5|       0.2|        5.4|       3.7|Iris-setosa|
| 12|        1.6|       0.2|        4.8|       3.4|Iris-setosa|
| 13|        1.4|       0.1|        4.8|       3.0|Iris-setosa|
| 14|        1.1|       0.1|        4.3|       3.0|Iris-setosa|
| 15|        1.2|       0.2|        5.8|       4.0|Iris-setosa|
```

Speciesの内容を確認するには、以下を新しい段落に貼り付けて実行してください。

```
%pyspark

dataFrame.select("Species").show(150)
```

先に進む前に、データの内容を検討することをお勧めします。
新しい段落を追加し、以下を貼り付けて実行してください。

```
%pyspark

z.show(dataFrame)
```

以下のように、テーブルには5つの特徴である**PetalLength（花びらの長さ）**、
PetalWidth（花びらの幅）、**SepalLength（がく片の長さ）**、
SepalWidth（がく片の幅）、**Species（種）**があります。

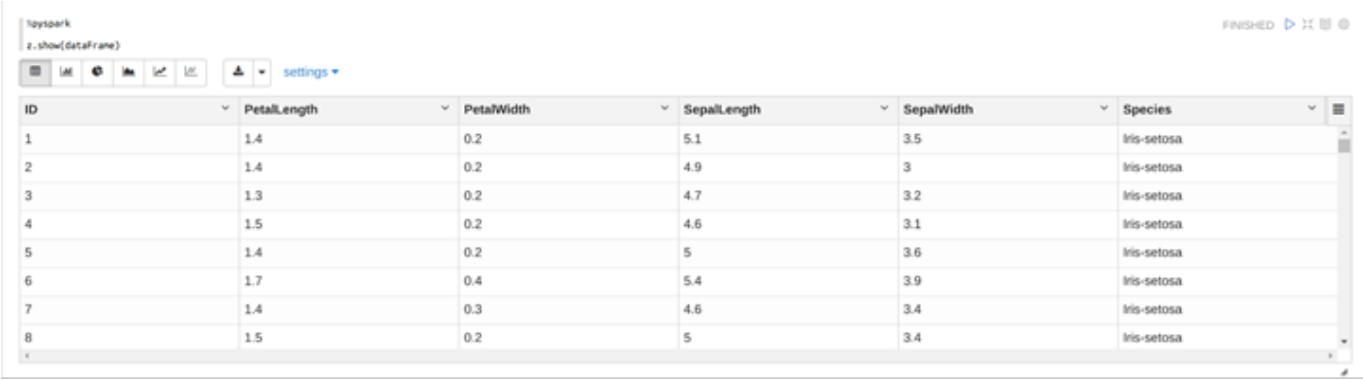

ID	PetalLength	PetalWidth	SepalLength	SepalWidth	Species
1	1.4	0.2	5.1	3.5	Iris-setosa
2	1.4	0.2	4.9	3	Iris-setosa
3	1.3	0.2	4.7	3.2	Iris-setosa
4	1.5	0.2	4.6	3.1	Iris-setosa
5	1.4	0.2	5	3.6	Iris-setosa
6	1.7	0.4	5.4	3.9	Iris-setosa
7	1.4	0.3	4.6	3.4	Iris-setosa
8	1.5	0.2	5	3.4	Iris-setosa

Scatter Chart（散布図）を選択してください。
ここでは、以下の画像でクラスターを確認できます（4次元ベクトルのため、完全な画像は確認できません）。
別の視点からクラスターを確認する場合は、**xAxis**および**yAxis**パラメータを変更してください。

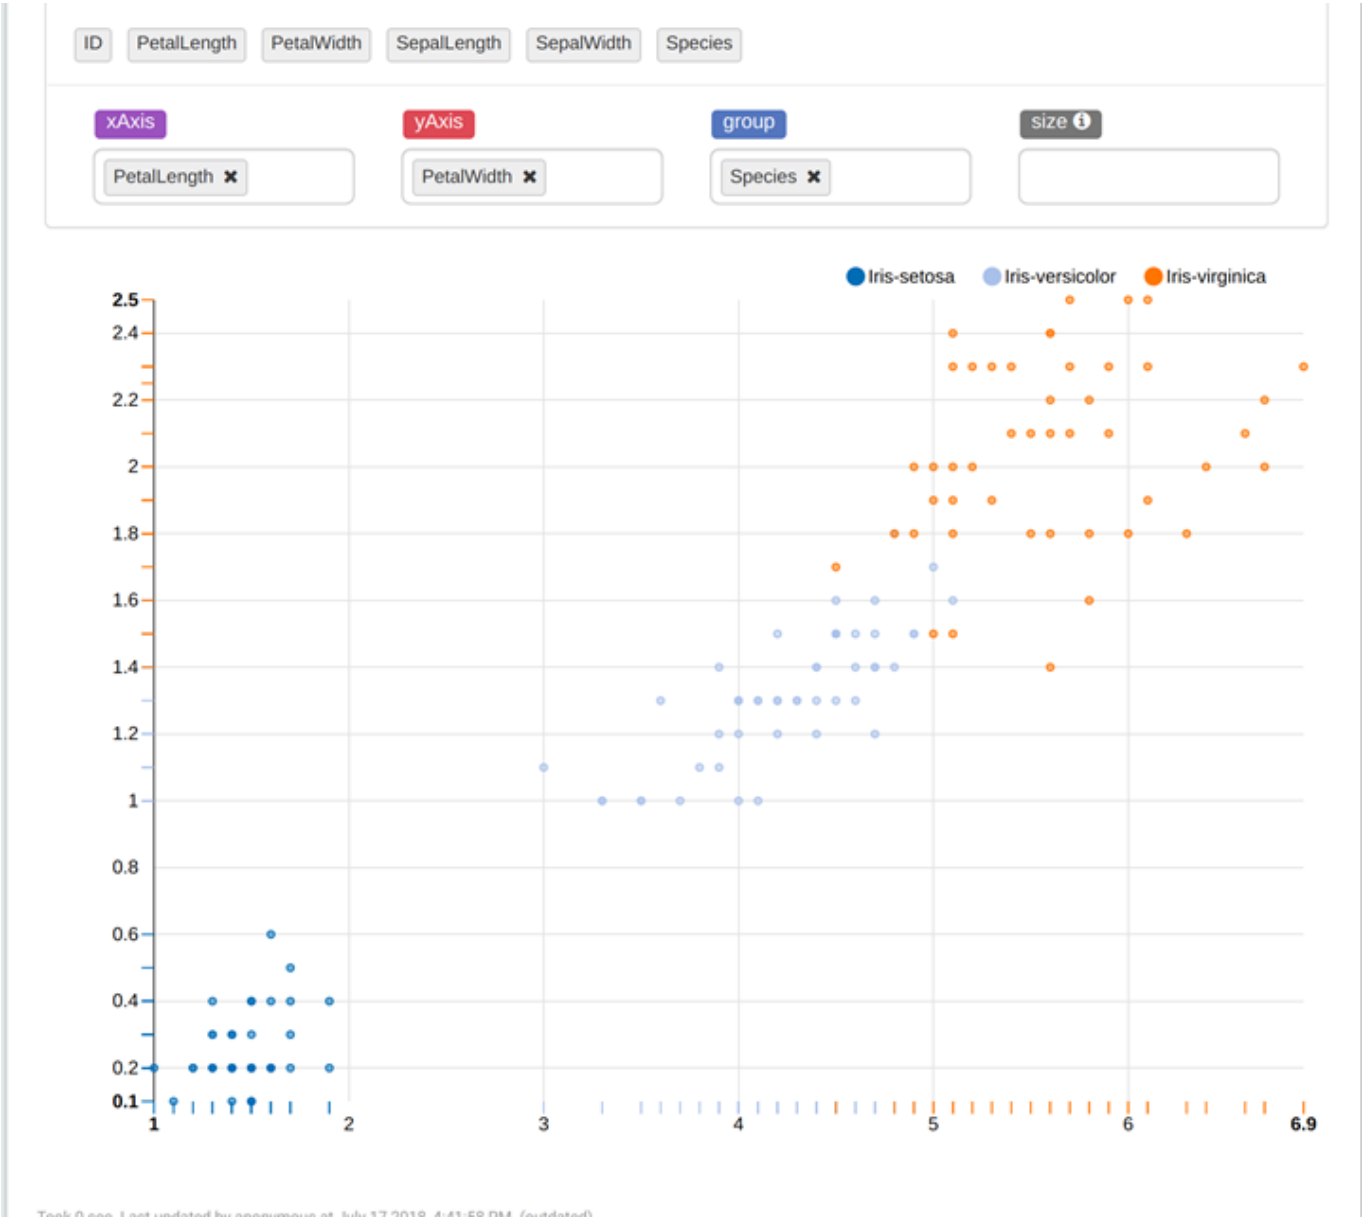

そして、私たちの目的は特徴を使用して花の種類を予測することです。
新しい段落を追加し、そこに以下を貼り付けて実行してください。

```
%pyspark
```

```
from pyspark.ml.linalg import Vectors

from pyspark.ml.feature import VectorAssembler

assembler = VectorAssembler(inputCols = ["PetalLength", "PetalWidth", "SepalLength",
"SepalWidth"], outputCol="features")
// inputColsで指定された4つのパラメータをでベクトルを作成し、outputColで名前を指定しています。

irisFeatures = assembler.transform(dataFrame) // これはベクトルを含む outputCol
列をテーブルに追加します。

irisFeatures.show(5)
```

次に、以下を新しい段落に貼り付けて実行します。

```
%pyspark

from pyspark.ml.clustering import KMeans

(trainingData, testData) = irisFeatures.randomSplit([0.7, 0.3]) // データをランダムに2つの部分に分割します

]kmeans = KMeans().setK(3).setSeed(101010) //
3つのクラスターを持つK平均モデルです。setSeedは再現可能な結果を作成します。

model = kmeans.fit(trainingData) // KMeansモデルをトレーニングします。

transformed = model.transform(trainingData) // 予測結果を含む新しい列をテーブルに追加します。

transformed.show(150)
```

```
%pyspark
from pyspark.ml.clustering import KMeans

(trainingData, testData) = irisFeatures.randomSplit([0.7, 0.3])
kmeans = KMeans().setK(3).setSeed(101010)
model = kmeans.fit(trainingData)

transformed = model.transform(trainingData)
transformed.show(150)
```

```
+---+-----------+----------+-----------+----------+--------------+----------------+----------+
| ID|PetalLength|PetalWidth|SepalLength|SepalWidth|       Species|        features|prediction|
+---+-----------+----------+-----------+----------+--------------+----------------+----------+
|  3|        1.3|       0.2|        4.7|       3.2|   Iris-setosa|[1.3,0.2,4.7,3.2]|         0|
|  4|        1.5|       0.2|        4.6|       3.1|   Iris-setosa|[1.5,0.2,4.6,3.1]|         0|
|  5|        1.4|       0.2|        5.0|       3.6|   Iris-setosa|[1.4,0.2,5.0,3.6]|         0|
|  7|        1.4|       0.3|        4.6|       3.4|   Iris-setosa|[1.4,0.3,4.6,3.4]|         0|
|  9|        1.4|       0.2|        4.4|       2.9|   Iris-setosa|[1.4,0.2,4.4,2.9]|         0|
| 10|        1.5|       0.1|        4.9|       3.1|   Iris-setosa|[1.5,0.1,4.9,3.1]|         0|
| 11|        1.5|       0.2|        5.4|       3.7|   Iris-setosa|[1.5,0.2,5.4,3.7]|         0|
| 12|        1.6|       0.2|        4.8|       3.4|   Iris-setosa|[1.6,0.2,4.8,3.4]|         0|
| 15|        1.2|       0.2|        5.8|       4.0|   Iris-setosa|[1.2,0.2,5.8,4.0]|         0|
| 16|        1.5|       0.4|        5.7|       4.4|   Iris-setosa|[1.5,0.4,5.7,4.4]|         0|
| 17|        1.3|       0.4|        5.4|       3.9|   Iris-setosa|[1.3,0.4,5.4,3.9]|         0|
| 18|        1.4|       0.3|        5.1|       3.5|   Iris-setosa|[1.4,0.3,5.1,3.5]|         0|
| 19|        1.7|       0.3|        5.7|       3.8|   Iris-setosa|[1.7,0.3,5.7,3.8]|         0|
| 22|        1.5|       0.4|        5.1|       3.7|   Iris-setosa|[1.5,0.4,5.1,3.7]|         0|
| 24|        1.7|       0.5|        5.1|       3.3|   Iris-setosa|[1.7,0.5,5.1,3.3]|         0|
```

次のように、testDataでモデルを使用します。

```
%pyspark

predictions = model.transform(testData)

predictions.show(151)
```

そして、モデルの精度を計算します。

```
%pyspark

SpeciesAndPreds = predictions.select("Species", "prediction").collect()

def getCluster(specie):

if specie == "Iris-setosa":

return 0

elif specie == "Iris-versicolor":

return 1

else:
```

```
return 2

def getAccuracy(flowers):

counter = 0;

for flower in flowers:

if getCluster(flower[0]) == flower[1]:

counter += 1

return counter / len(flowers)

accuracy = getAccuracy(SpeciesAndPreds)

print("accuracy is " + str(accuracy))

// 私の結果は0.9090909090909091です
```

各クラスターにある花の数を確認するには、「z.show(predictions)」を使用してBar Chart（棒グラフ）を選択します。

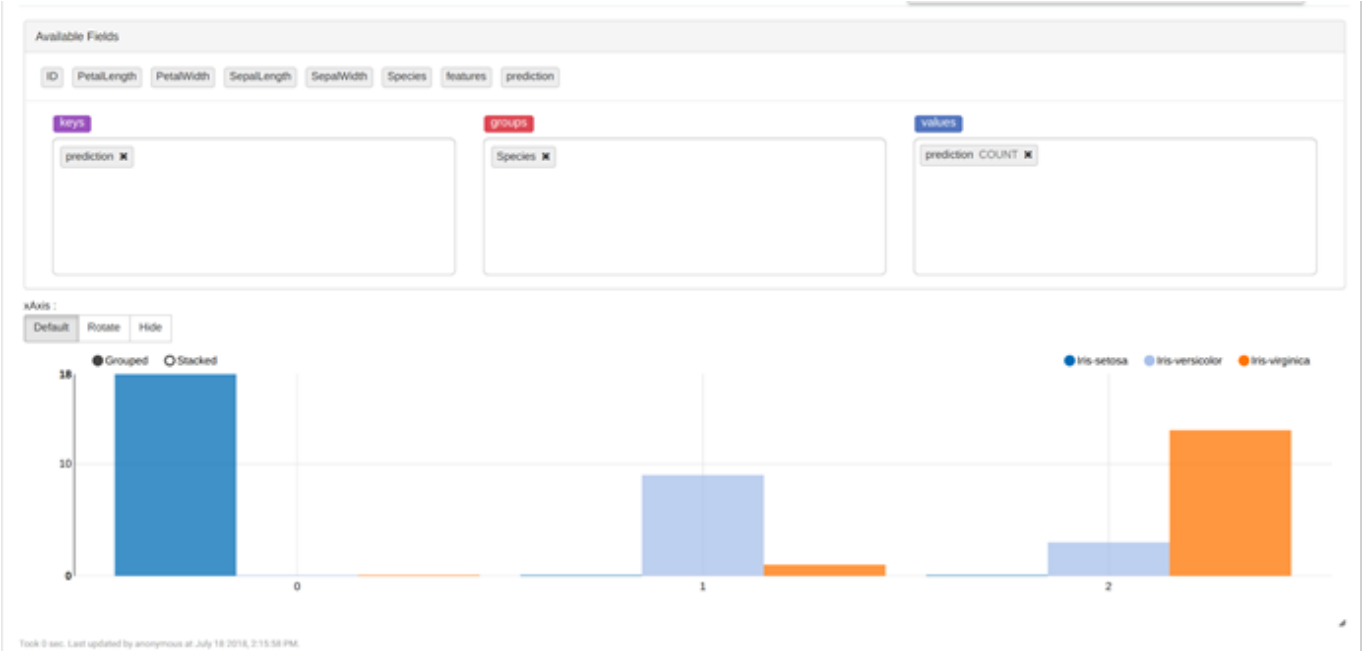

まとめ

ここでは、InterSystems
IRISでアイリスの花の種をかなり正確に予測するモデルを作成しました（0.9超の精度）。 また、「Iris-setosa」は分離可能であり、「Iris-virginica」と「Iris-
versicolor」はK平均アルゴリズムでは分離できないことが分かりました。
そのため、精度を高めるためには別の方法を使用することをお勧めします。

リンク

Apache Spark + Apache Zeppelin + InterSystems IRISを起動する方法

Spark SQL、データフレームおよびデータセットガイド

機械学習ライブラリガイド

K平均法

クラスタリング（ただし、このAPIはRDD用であるため、アルゴリズムに関する関連情報を参照するだけにしてください）

アイリス花データセット

#Artificial Intelligence (AI) #API #Python #初心者 #Machine Learning (ML) #InterSystems IRIS

ソースURL:
https://jp.community.intersystems.com/post/%E3%82%A2%E3%82%A4%E3%83%AA%E3%82%B9%E3%83%87%E3%83%BC%E3%82%BF%E3%82%BB%E3%83%83%E3%83%88%E3%81%AEk%E5%B9%B3%E5%9D%87%E3%82%AF%E3%83%A9%E3%82%B9%E3%82%BF%E3%83%AA%E3%83%B3%E3%82%B0