

Spark mllib API- feature

作者: [Zing](#)

原文链接: <https://ld246.com/article/1461139570018>

来源网站: [链滴](#)

许可协议: [署名-相同方式共享 4.0 国际 \(CC BY-SA 4.0\)](#)

spark中大部分的向量转换采用训练 (fit) -转化 (transform) 形式, 因此会有对应的训练类和模型。

该模块主要包括了, 标准化、归一化、分词、特征选择

```
##pyspark.mllib.feature.Normalizer(p=2.0)
```

使用Lp范式对样本进行归一化。

若 $1 <= p < \text{float}('inf')$, 使用 $\text{sum}(\text{abs}(\text{vector})^p)^{1/p}$ 范式。

若 $p = \text{float}('inf')$, 使用 $\text{max}(\text{abs}(\text{vector}))$ 范式。

- transform(vector)
 - 参数: vector - 需要正则化的RDD
 - 返回: 正则化的向量RDD

```
##pyspark.mllib.feature.StandardScaler(withMean=False, withStd=True)
```

使用训练集的列统计信息, 通过修改均值和范围进行标准化

- fit(dataset):StandardScalerModel

计算均值和方差, 并以模型保存, 以便后续使用。相当于训练模型。

pyspark.mllib.feature.StandardScalerModel(java_mod)

表示可以把特征转化为正态分布的StandardScaler模型

- setWithMean(withMean)
参数为boolean, 决定是否使用均值
- setWithStd(withStd)
参数为boolean, 决定是否使用std
- transform(vector)
对特征进行标准变换

```
##pyspark.mllib.feature.HashingTF(numFeatures=1048576)
```

使用hash建立起 项-频度 映射。

- numFeatures: 向量维度
- indexOf(term): 返回指定项的索引
- transform(document): 将输入转化为项-频度向量

```
##pyspark.mllib.feature.IDF(minDocFreq=0)
```

IDF为逆向文件频率，公式如下：

$$\text{idf} = \log((m + 1) / (d(t) + 1))$$

其中m为文件总数，d(t)为出现项t的文件数。

- 参数：minDocFreq

通过minDocFreq参数，可以利用IDF过滤掉一些在文档中出现次数过少的词。若设置为0，则返回TF-IDF

- 方法：fit(dataset)

计算数据集的IDF

```
##pyspark.mllib.feature.IDFModel(java_model)
```

IDF模型

- IDF(): 返回当前IDF向量
 - transform(x): 将TF向量转化为TF-IDF向量
-

```
##pyspark.mllib.feature.Word2Vec
```

Word2Vec 创建了一个表示语料库中词语的的向量。算法首先从语料库中创建一个词汇表，然后创建应到词汇表中单词的向量。在自然语言处理和机器学习算法中，该向量可以直接使用。

我们使用skip-gram模型实现，并且使用分层softmax方法来训练模型。

- fit(data):使用data进行训练，计算向量
 - setLearningRate(learningRate): 设置初始学习率
 - setMinCount(minCount): 设置最少出现的token次数，默认5
 - setNumIterations(numIterations): 设置迭代次数，默认1
 - setNumPartitions(numPartitions): 设置分区个数，默认1
 - setSeed(seed): 设置随机种子
 - setVectorSize(vectorSize): 设置向量维度，默认100
-

```
##pyspark.mllib.feature.Word2VecModel(java_model)
```

Word2Vec fit得到的模型

- findSynonyms(word, num): 找到指定word的num个同义词
 - getVectors(): 返回代表向量的单词表
 - transform(word): 将单词转化为向量
-

pyspark.mllib.feature.ChiSqSelector(numTopFeatures)

创建一个卡方向量选择器，用于特征选择

- 参数: numTopFeatures 保留的卡方较大的特征的数量。
- fit(data): 对LabeledPoint格式的RDD进行训练，返回ChiSqSelectorModel，这个类将输入数据化到降维的特征空间。

```
##pyspark.mllib.feature.ChiSqSelectorModel(java_model)
```

由ChiSqSelector训练得到的模型

- transform(vector), 对RDD进行转换，转化到降维的特征空间。

```
##pyspark.mllib.feature.ElementwiseProduct(scalingVector)
```

使用输入的scalingVector作为每一列的权值，对每一列进行扩展。

- transform(vector): 对向量进行Hadamard卷积。