

imputation

Guangyao Zhao

2022-10-18

Contents

单变量插补	1
多变量插补	2

拿到的数据中，经常会有缺失值，最简单的办法当然是直接删除 (`pd.dropna()`)，但是如果仅有几个特征有缺失值的话，直接删除未免有点可惜，更好的策略是估算缺失值，即从数据的已知部分推断出缺失值。

- 单变量插补：平均值，众数等
- 多元插补算法：KNN

```
1 import numpy as np
2 from sklearn import impute
3
4 X = np.array([[1, 2], [np.nan, 3], [7, 6]])
5 print('X:\n ', X)
```

X:

```
[[ 1.  2.]
 [nan  3.]
 [ 7.  6.]
```

单变量插补

```

1 imp = impute.SimpleImputer(missing_values= np.nan, strategy='mean') # 单变量插补
2 imp.fit(X)
3
4 X_simple = imp.transform(X)
5 print('X_simple:\n ', X_simple)

```

```

X_simple:
  [[1. 2.]
   [4. 3.]
   [7. 6.]]

```

同样的策略还有: median, most_frequent, constant。如果 strategy=constant, 则使用 fill_value 参数填补定值, 更多介绍请参考[官方文档](#)。

多变量插补

多变量插补相比稍显复杂, 但原理也很简单, 它将每个包含缺失值的特征建模为其他特征的函数, 并将该估计值用于插补。最常用的是 KNN:

```

1 imp = impute.KNNImputer(n_neighbors=2, weights='uniform')
2 imp.fit(X)
3
4 X_KNN = imp.transform(X)
5 print('X_KNN:\n ', X_KNN)

```

```

X_KNN:
  [[1. 2.]
   [4. 3.]
   [7. 6.]]

```