

Soft computing



K.N. Toosi
University of
Technology

محاسبات نرم



Hasan Ghasemzadeh
<http://wp.kntu.ac.ir/ghasemzadeh>

Soft Computing

Artificial Intelligence and Soft computing



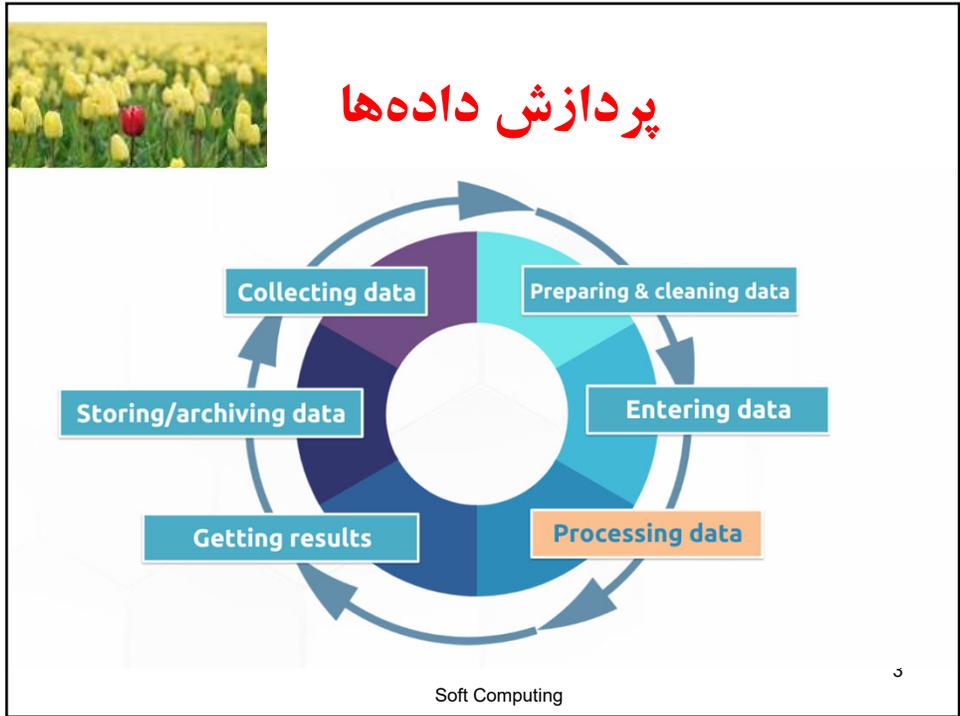
K.N. TOOSI
University of
Technology

پردازش داده‌ها



Soft Computing

2



پردازش داده‌ها

- پاکسازی داده‌ها
- داده‌های پوچ null
- روش وان هات One Hot Encoding

Soft Computing

4



پاکسازی داده‌ها

- موفقیت یک پروژه بطور قابل توجهی به پاکسازی داده‌ها وابسته است.
- داده‌ی خوب، بهتر از الگوریتم‌های پیچیده است.



- در پاکسازی، داده‌های گم‌شده، تکراری یا غیرمرتبط شناسایی و حذف می‌شوند.
- داده‌های غلط یا نامناسب می‌توانند عملکرد مدل یادگیری ماشین را به خطر بیندازند.

Soft Computing

پاکسازی داده‌ها

✓ خلاصه دستورهای پاکسازی داده‌ها

```
# Drop rows with missing values
df_cleaned = df.dropna()

# Fill missing values with a specific value (e.g., 0)
df_filled = df.fillna(0)

# Drop columns
df_dropped = df.drop(columns=['column_name'])

# Rename columns
df_renamed = df.rename(columns={'old_name': 'new_name'})

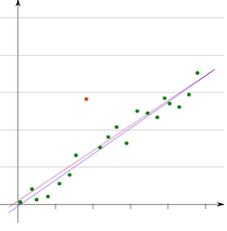
# Remove duplicates
df_no_duplicates = df.drop_duplicates()

# Convert data types
df['column_name'] = df['column_name'].astype('int')
```

Soft Computing

6

مراحل پاکسازی داده‌ها



- مرحله یک: حذف مشاهدات تکراری یا نامربوط
- مرحله دو: رفع خطاهای ساختاری
- مرحله سه: اصلاح داده‌های پرت ناخواسته مرحله چهار: مدیریت داده‌های گمشده
- مرحله پنج: اعتبارسنجی و پرسش و پاسخ

حذف نمونه داده‌های نامرتب

رفع خطاهای ساختاری

مدیریت داده‌های گمشده

مدیریت داده‌های پرت

Soft Computing

7

مراحل پاکسازی داده‌ها

مثال: بررسی فایل مسافران قطار

- ✓ وارد کردن کتابخانه‌های لازم
- ✓ بارگذاری مجموعه داده
- ✓ بررسی اطلاعات داده

```
import pandas as pd
import numpy as np

# Load the dataset
df = pd.read_csv('train.csv')
print(df.head())
```

survived	pclass	name	fare	cabin	embarked
0	3	Braund, Mr. Owen Harris	7.2500	NaN	S
1	1	Cumings, Mrs. John Bradley (Florence Briggs Th...	71.2833	C85	C
2	3	Heikinen, Miss. Laina	7.9250	NaN	S
3	1	Futrelle, Mrs. Jacques Heath (Lily May Peel)	53.1000	C123	S
4	3	Allen, Mr. William Henry	8.0500	NaN	S

[5 rows x 11 columns]

Soft Computing

8

مراحل پاکسازی داده‌ها

مثال: بررسی فایل مسافران قطار

```
<class 'pandas.core.frame.DataFrame'>
RangeIndex: 891 entries, 0 to 890
Data columns (total 11 columns):
#   Column      Non-Null Count  Dtype
---  -
0   survived    891 non-null    int64
1   pclass      891 non-null    int64
2   name        891 non-null    object
3   sex         891 non-null    object
4   age         714 non-null    float64
5   sibsp       891 non-null    int64
6   parch       891 non-null    int64
7   ticket      891 non-null    object
8   fare        891 non-null    float64
9   cabin       204 non-null    object
10  embarked    889 non-null    object
dtypes: float64(2), int64(4), object(5)
memory usage: 76.7+ KB
```

وارد کردن کتابخانه‌های لازم ✓

بارگذاری مجموعه داده ✓

بررسی اطلاعات داده ✓

```
df.info()
```

4 age 714 non-null float64 ←

9 cabin 204 non-null object ←

9

Soft Computing

مراحل پاکسازی داده‌ها

مثال

بررسی سطرهای تکراری ✓

```
0    False
1    False
2    False
3    False
4    False
...
886  False
887  False
888  False
889  False
890  False
Length: 891, dtype: bool
```

```
print(df.duplicated())
```

10

Soft Computing

مراحل پاکسازی داده‌ها

مثال

```
print(df.describe())
```

دیدن ساختار داده ✓

	survived	pclass	age	sibsp	parch	fare
count	891.000000	891.000000	714.000000	891.000000	891.000000	891.000000
mean	0.383838	2.308642	29.699118	0.523008	0.381594	32.204208
std	0.486592	0.836071	14.526497	1.102743	0.806057	49.693429
min	0.000000	1.000000	0.420000	0.000000	0.000000	0.000000
25%	0.000000	2.000000	20.125000	0.000000	0.000000	7.910400
50%	0.000000	3.000000	28.000000	0.000000	0.000000	14.454200
75%	1.000000	3.000000	38.000000	1.000000	0.000000	31.000000
max	1.000000	3.000000	80.000000	8.000000	6.000000	512.329200

Soft Computing

11

مراحل پاکسازی داده‌ها

بررسی ستون‌های دسته‌بندی و عددی ✓

```
# Categorical columns
cat_col = [col for col in df.columns if df[col].dtype == 'object']
print('Categorical columns :', cat_col)
```

```
Categorical columns : ['name', 'sex', 'ticket', 'cabin', 'embarked']
```

```
# Numerical columns
num_col = [col for col in df.columns if df[col].dtype != 'object']
print('Numerical columns :', num_col)
```

```
Numerical columns : ['survived', 'pclass', 'age', 'sibsp', 'parch', 'fare']
```

Soft Computing

12

مراحل پاکسازی داده‌ها

✓ تعداد کلی مقادیر منحصر به فرد در ستون‌های دسته‌بندی

```
print(df[cat_col].nunique())
```

```
name      891
sex        2
ticket    681
cabin     147
embarked   3
dtype: int64
```

Soft Computing

13

داده‌های پوچ

بسته به نوع داده بایستی تصمیم‌گیری نمود

- ✓ حذف کل سطر داده از داده‌ها
- ✓ قرار دادن داده قبلی یا بعدی به جای داده پوچ
- ✓ قرار دادن میانگین داده قبلی و بعدی به جای داده پوچ
- ✓ قرار دادن میانگین کل داده‌ها به جای داده پوچ

Soft Computing

14

آنالیز داده‌ها

```
# Calculate correlation matrix
correlation_matrix = df.corr()

# Calculate mean, median, mode
mean_value = df['column_name'].mean()
median_value = df['column_name'].median()
mode_value = df['column_name'].mode()

# Count unique values
unique_counts = df['column_name'].value_counts()

# Cross-tabulation
cross_tab = pd.crosstab(df['column1'], df['column2'])
```

Soft Computing

15

مشاهده داده‌ها

```
import matplotlib.pyplot as plt
import seaborn as sns

# Histogram
df['column_name'].hist()
plt.show()

# Box plot
sns.boxplot(x='category_column', y='numeric_column',
            data=df)
plt.show()

# Scatter plot
plt.scatter(df['column1'], df['column2'])
plt.show()

# Heatmap
sns.heatmap(df.corr(), annot=True)
plt.show()
```

Soft Computing

16

روش وان هات

اگر از افراد بپرسند که رنگ مورد علاقه آنها چیست، پاسخ‌های افراد محدود به یک سری گزینه خاص (مثلاً: سفید، آبی، قرمز، مشکی...) خواهد بود. وضعیت یک ساختمان پس از زلزله با چند گزینه مثل سالم، آسیب جزئی، آسیب کلی، تخریب شده قابل توصیف است. جهت پردازش یک روش استفاده از عدد یک داغ است.

بندر بارگیری چهار مقدار S و C و Q و nan را دارد

	A	B	C	D	E	F	G	H	I	J	K	L
1		survived	pclass	name	sex	age	sibsp	parch	ticket	fare	cabin	embarked
2	0	0	3	Braund, M	male	22	1	0	A/5 21171	7.25		S
3	1	1	1	Cumings, N	female	38	1	0	PC 17599	71.2833	C85	C
4	2	1	3	Heikinen, female		26	0	0	STON/O2.	7.925		S
5	3	1	1	Futrelle, M	female	35	1	0	113803	53.1	C123	S
6	4	0	3	Allen, Mr.	male	35	0	0	373450	8.05		S
7	5	0	3	Moran, Mr	male		0	0	330877	8.4583		Q
8	6	0	1	McCarthy, male		54	0	0	17463	51.8625	E46	S
9	7	0	3	Palsson, M	male	2	3	1	349909	21.075		S
10	8	1	3	Johnson, N	female	27	0	2	347742	11.1333		S
11	9	1	2	Nasser, Mr	female	14	1	0	237736	30.0708		C
12	10	1	3	Sandstrom	female	4	1	1	PP 9549	16.7	G6	S
13	11	1	1	Bonnell, M	female	58	0	0	113783	26.55	C103	S

17

Soft Computing

روش وان هات

در کدبندی وان هات، برای هر برجسب مثل انواع رنگ یک ستون مجزا در نظر گرفته می‌شود و برای هر نمونه فقط در ستون رنگ مربوطه یک قرارداد می‌شود.

Color	Red	Yellow	Green
Red	1	0	0
Red	1	0	0
Yellow	0	1	0
Green	0	0	1
Yellow	0	1	0

تابع unique مقادیر منحصر به فرد را می‌دهد

18

Soft Computing

روش وان هات

تابع unique مقادیر منحصر به فرد را می دهد

```
# Determin unique data
print(df['embarked'].unique())
```

خروجی

```
['S' 'C' 'Q' nan]
```

در این مثال مقادیر پوچ را لازم نداریم و داده‌های مربوطه را می توانیم حذف کنیم

```
# Drop houses where the target is missing
df.dropna(axis=0, subset=['embarked'], inplace=True)
target = df.embarked
print(target.unique())
```

خروجی

```
['S' 'C' 'Q']
```

19

Soft Computing

روش وان هات

```
# One hot encoding
one_hot_encoded_embarked = pd.get_dummies(df,
columns = ['embarked'])
print(one_hot_encoded_embarked)
```

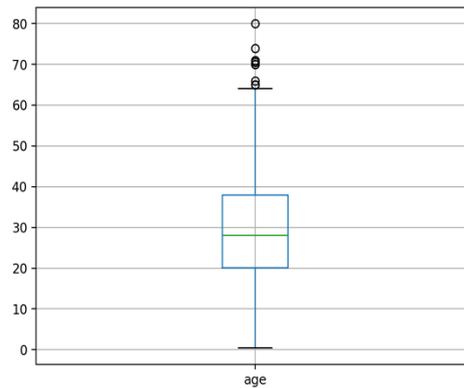
survived	pclass	name	sex	cabin	embarked_C	embarked_Q	embarked_S
0	0	Braund, Mr. Owen Harris	male	NaN	False	False	True
1	1	Cumings, Mrs. John Bradley (Florence Briggs Th...	female	C85	True	False	False
2	1	Heikkinen, Miss. Laina	female	NaN	False	False	True
3	1	Futrelle, Mrs. Jacques Heath (Lily May Peel)	female	C123	False	False	True
4	0	Allen, Mr. William Henry	male	NaN	False	False	True
...
886	0	Montvila, Rev. Juozas	male	NaN	False	False	True
887	1	Graham, Miss. Margaret Edith	female	B42	False	False	True
888	0	Johnston, Miss. Catherine Helen "Carrie"	female	NaN	False	False	True
889	1	Behr, Mr. Karl Howell	male	C148	True	False	False
890	0	Dooley, Mr. Patrick	male	NaN	False	True	False

20

Soft Computing

رسم جعبه داده

```
# example of Box Plots raw data
df.boxplot(column='age',return_type='axes')
```



Soft Computing

23

رسم جعبه داده قبل از اصلاح

```
# Create subplots: 1 plot per column
fig, axs = plt.subplots(nrows=len(num_col), , dpi=80, figsize=(10,
6))

# Ensure axs is iterable even if there is only one column
if len(num_col) == 1:
    axs = [axs]

# Plot each numerical column in a separate subplot
for i, column in enumerate(num_col):
    df.boxplot(column=column, ax=axs[i], vert=False)
    axs[i].set_title(column) # Set the title as the column name

plt.tight_layout() # Adjust layout to prevent overlap
plt.show()
```

Soft Computing

24



پاکسازی داده ها

```
# data cleaning
# Identify the quartiles
i = 0
for col in num_col:
    q1, q3 = np.percentile(df[col], [25, 75])
    # Calculate the interquartile range
    iqr = q3 - q1
    # Calculate the lower and upper bounds
    lower_bound = q1 - (1.5 * iqr)
    upper_bound = q3 + (1.5 * iqr)
    # Drop the outliers
    clean_data = df[(df[col] >= lower_bound)
                    & (df[col] <= upper_bound)]
    i+=1
```

Soft Computing

26

اصلاح داده ها

```
print(df.describe())
```

	survived	pclass	age	sibsp	parch	fare
count	891.000000	891.000000	714.000000	891.000000	891.000000	891.000000
mean	0.383838	2.308642	29.699118	0.523008	0.381594	32.204208
std	0.486592	0.836071	14.526497	1.102743	0.806057	49.693429
min	0.000000	1.000000	0.420000	0.000000	0.000000	0.000000
25%	0.000000	2.000000	20.125000	0.000000	0.000000	7.910400
50%	0.000000	3.000000	28.000000	0.000000	0.000000	14.454200
75%	1.000000	3.000000	38.000000	1.000000	0.000000	31.000000
max	1.000000	3.000000	80.000000	8.000000	6.000000	512.329200

```
print(clean_data.describe())
```

	survived	pclass	age	sibsp	parch	fare
count	775.000000	775.000000	613.000000	775.000000	775.000000	775.000000
mean	0.339355	2.480000	28.946574	0.437419	0.340645	17.822091
std	0.473796	0.73439	14.368139	0.899838	0.785914	13.578085
min	0.000000	1.000000	0.420000	0.000000	0.000000	0.000000
25%	0.000000	2.000000	20.000000	0.000000	0.000000	7.895800
50%	0.000000	3.000000	28.000000	0.000000	0.000000	13.000000
75%	1.000000	3.000000	37.000000	1.000000	0.000000	26.000000
max	1.000000	3.000000	80.000000	5.000000	6.000000	65.000000

Soft Computing

27

رسم جعبه داده بعد از اصلاح

```
# Create subplots: 1 plot per column
fig, axs = plt.subplots(nrows=len(num_col), ncols=1, , dpi=80,
figsize=(10, 6))

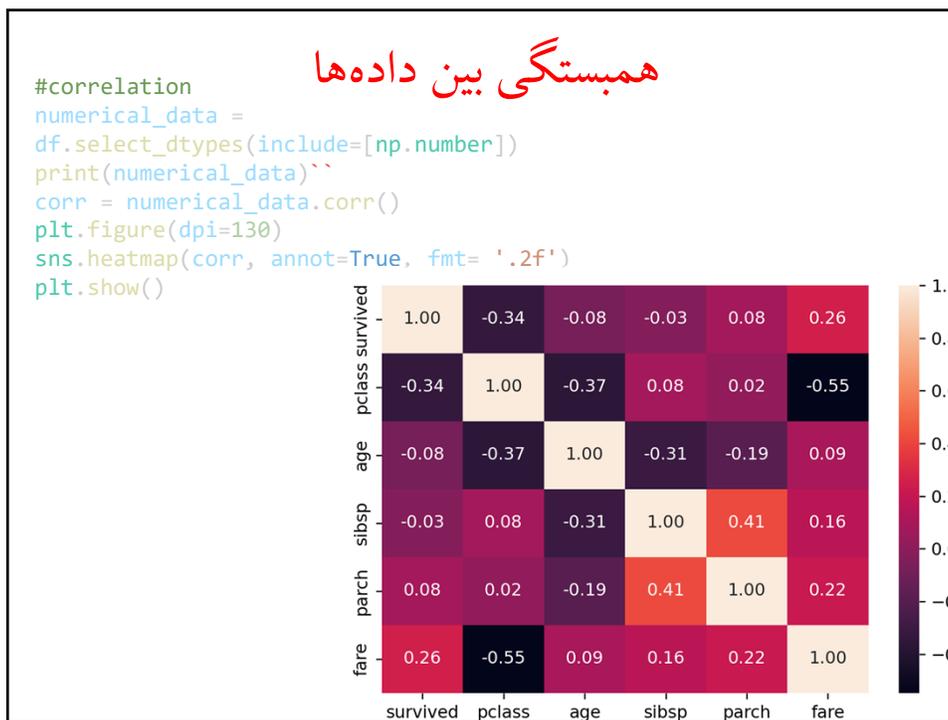
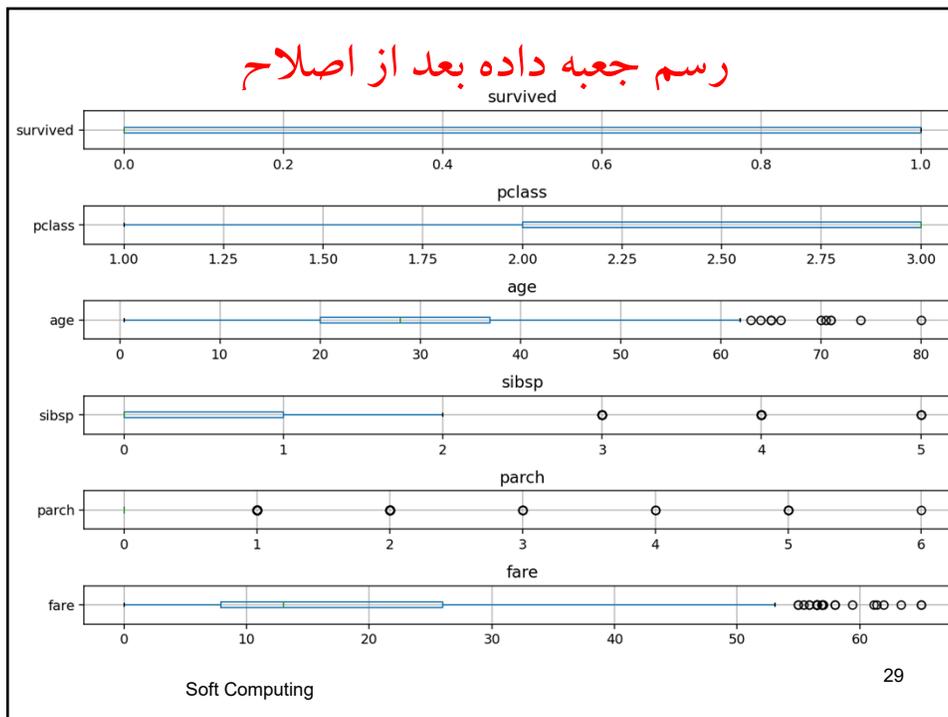
# Ensure axs is iterable even if there is only one column
if len(num_col) == 1:
    axs = [axs]

# Plot each numerical column in a separate subplot
for i, column in enumerate(num_col):
    clean_data.boxplot(column=column, ax=axs[i], vert=False)
    axs[i].set_title(column) # Set the title as the column name

plt.tight_layout() # Adjust layout to prevent overlap
plt.show()
```

Soft Computing

28



نوشتن داده ها در فایل اکسل

```
# write raw and clean data to excel file
# Specify a writer
writer = pd.ExcelWriter('train_clean_data.xlsx',
engine='xlsxwriter')
# Write your DataFrame to a file
df.to_excel(writer, 'raw data')
clean_data.to_excel(writer, 'clean data')
# Save the result
writer.close()
```

Soft Computing

31

نوشتن داده ها در فایل اکسل

	A	B	C	D	E	F	G	H	I	J	K	L
1		survived	pclass	name	sex	age	sibsp	parch	ticket	fare	cabin	embarked
2	0	0	3	Braund, M	male	22	1	0	A/5 21171	7.25		S
3	2	1	3	Heikkinen, female		26	0	0	STON/O2.	7.925		S
4	3	1	1	Futrelle, M	female	35	1	0	113803	53.1	C123	S
5	4	0	3	Allen, Mr.	male	35	0	0	373450	8.05		S
6	5	0	3	Moran, Mr	male		0	0	330877	8.4583		Q
7	6	0	1	McCarthy, male		54	0	0	17463	51.8625	E46	S
8	7	0	3	Palsson, M	male	2	3	1	349909	21.075		S
9	8	1	3	Johnson, M	female	27	0	2	347742	11.1333		S
10	9	1	2	Nasser, Mr	female	14	1	0	237736	30.0708		C
11	10	1	3	Sandstrom	female	4	1	1	PP 9549	16.7	G6	S
12	11	1	1	Bonnell, M	female	58	0	0	113783	26.55	C103	S
13	12	0	3	Saunders	male	20	0	0	A/5. 2151	8.05		S
14	13	0	3	Andersson	male	39	1	5	347082	31.275		S

Soft Computing

32

تمرین برنامه نویسی

تمرین سوم : یک برنامه به زبان پایتون بنویسید که یک فایل داده را بگیرد و داده ها پرت را تعیین کند.

Depth (m)	Temperature (c)
0.0	4.3
2.7	4.3
5.4	4.3
8.2	4.4
10.9	4.4
13.7	4.4
16.4	4.5
19.2	4.5
21.9	4.6
24.7	4.6
27.4	4.7
30.2	4.7
32.9	4.8
35.7	4.9

۱- داده ها را رسم کنید

۲- تعداد داده های پرت را بیابید

۳- داده ها پرت را حذف کنید

۴- از روش وان هات طبقه بندی داده انجام دهید

۵- داده های ورودی، خروجی و گرافها را

در شیت های مختلف فایل اکسل ذخیره نمایید