

Soft computing

محاسبات نرم

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

Soft Computing

Artificial Intelligence and Soft computing

طبقه بندی چند کلاسی

Multi Classification

Soft Computing

2

## نمونه رگرسیون لجستیک با بیش از یک ویژگی

Age	Heart Rate	Heart Attack
45	50	N
50	50	N
55	50	Y
60	50	N
65	70	N
70	70	Y
75	90	Y
80	90	Y
85	90	N
90	90	Y
95	90	Y

مثال: احتمال حمله قلبی با دو ویژگی ضربان قلب و سن فرد  
احتمال حمله قلبی شخصی ۲۰ ساله با ضربان قلب ۸۰ چقدر است؟

بسیاری از عوامل دیگر مانند فشار خون، سطح کلسترول، سابقه خانوادگی، و عادات زندگی (مثل سیگار کشیدن و ورزش نکردن) نیز در تعیین خطر حمله قلبی مؤثرند، که در این جدول لحاظ نشده است.

$$P(Y = 1 | X = x) = p(x) = \frac{1}{1 + e^{-(\theta_0 + \theta_1 x_1 + \theta_2 x_2 + \dots)}}$$

$$P(Heart\ Attack = 1 | X = Age, Heart\ rate) = \frac{1}{1 + e^{-(\theta_0 + \theta_1 .Age + \theta_2 .Heart\ rate)}}$$

Soft Computing

3

## نمونه رگرسیون لجستیک با بیش از یک ویژگی

Age	Heart Rate	Heart Attack
45	50	N
50	50	N
55	50	Y
60	50	N
65	70	N
70	70	Y
75	90	Y
80	90	Y
85	90	N
90	90	Y
95	90	Y

مثال: احتمال حمله قلبی با دو ویژگی ضربان قلب و سن فرد

بسیاری از عوامل دیگر مانند فشار خون، سطح کلسترول، سابقه خانوادگی، و عادات زندگی (مثل سیگار کشیدن و ورزش نکردن) نیز در تعیین خطر حمله قلبی مؤثرند، که در این جدول لحاظ نشده است.

$$P(Y = 1 | X = x) = p(x) = \frac{1}{1 + e^{-(\theta_0 + \theta_1 x_1 + \theta_2 x_2 + \dots)}}$$

$$P(Heart\ Attack = 1 | X = Age, Heart\ rate) = \frac{1}{1 + e^{-(\theta_0 + \theta_1 .Age + \theta_2 .Heart\ rate)}}$$

Soft Computing

4

## نمونه رگرسیون لجستیک با بیش از یک ویژگی

```

import pandas as pd           8 regression logistic two feature.py
import numpy as np
import matplotlib.pyplot as plt
from sklearn.linear_model import LogisticRegression
from sklearn.model_selection import train_test_split

# Define the dataset
data = {
    'Age': [45, 50, 55, 60, 65, 70, 75, 80, 85, 90, 95],
    'Heart Rate': [50, 50, 50, 50, 70, 70, 90, 90, 90, 90, 90],
    'Heart Attack': [0, 0, 1, 0, 0, 1, 1, 1, 0, 1, 1]
}
df = pd.DataFrame(data)

# Prepare the data
X = df[['Age', 'Heart Rate']]
y = df['Heart Attack']

```

Soft Computing

5

## نمونه رگرسیون لجستیک با بیش از یک ویژگی

```

# Train the logistic regression model
model = LogisticRegression()
model.fit(X, y)

# model's parameters
print("Coefficients:", model.coef_)
print("Intercept:", model.intercept_)
theta_0 = model.intercept_[0]
theta_1 = model.coef_[0][0]
theta_2 = model.coef_[0][1]
print("Intercept (θ₀):", theta_0)
print("Coefficient for Age (θ₁):", theta_1)
print("Coefficient for Heart Rate (θ₂):", theta_2)

```

```
Coefficients: [[0.07723627 0.00274301]]
Intercept: [-5.3543177]
Intercept (θ₀): -5.354317698549416
Coefficient for Age (θ₁): 0.07723627391026841
Coefficient for Heart Rate (θ₂): 0.002743013264610142
```

Soft Computing

6

### نمونه رگرسیون لجستیک با بیش از یک ویژگی

```
# Example prediction for a person with Age = 20 and Heart Rate = 80
example_data = np.array([[20, 80]])
probability_heart_attack = model.predict_proba(example_data)[0][1]
print("Probability of Heart Attack for Age=20 and Heart Rate=80:",
      probability_heart_attack)
```

Probability of Heart Attack for Age=20 and Heart Rate=80: 0.02685

```
Intercept (θ₀): -5.354317698549416
Coefficient for Age (θ₁): 0.07723627391026841
Coefficient for Heart Rate (θ₂): 0.002743013264610142
```

$$P(Heart\ Attack = 1 | X = Age, Heart\ rate) = \frac{1}{1 + e^{-(5.354 + 0.077Age + 0.003Heart\ rate)}}$$

Soft Computing

7

### ارزیابی الگوریتم

پس از مدلسازی و تحلیل داده ها نیاز به ارزیابی الگوریتم است

**اگر الگوریتم ارزیابی نشود نمی توان آنرا بهبود بخشد.**



Soft Computing

8

## ارزیابی الگوریتم

پس از مدلسازی و تحلیل داده های دودویی نتایج را به صورت زیر می توان دسته بندی نمود:

**مثبت صحیح (TP: True Positive)**:

تعداد حالت هایی که مقدار پیش بینی شده با مقدار واقعی برابر بوده و متغیر پاسخ برابر با یک است.  
(شناسایی درست - معیار مثبت).

**مثبت کاذب (FP: False Positive)**:

تعداد حالت هایی که مقدار پیش بینی شده برای متغیر پاسخ یک و مقدار واقعی برابر صفر است.  
(شناسایی غلط - معیار منفی).

**منفی صحیح (TN: True Negative)**:

تعداد حالت هایی که مقدار پیش بینی شده با مقدار واقعی برابر بوده و متغیر پاسخ برابر با صفر است.  
(مردودی درست - معیار مثبت).

**منفی کاذب (FN: False Negative)**:

تعداد حالت هایی که مقدار پیش بینی شده برای متغیر پاسخ صفر و مقدار واقعی برابر یک است.  
(مردودی غلط - معیار منفی).

Soft Computing

9

## ارزیابی الگوریتم

مثال: الگوریتمی بیمارهای دارای سرطان را شناسایی می کند و نتایج زیر را داده است.

Individual Number	1	2	3	4	5	6	7	8	9	10	11	12
Actual Classification	1	1	1	1	1	1	1	1	0	0	0	0
Predicted Classification	0	0	1	1	1	1	1	1	1	0	0	0
Result	FN	FN	TP	TP	TP	TP	TP	TP	FP	TN	TN	TN

( FP: False Positive )  
منفی کاذب ( FN: False Negative )

مثبت صحیح ( TP: True Positive )  
منفی صحیح ( TN: True Negative )

چگونه از این شاخص ها استفاده کنیم؟

Soft Computing

10

## ارزیابی الگوریتم

### ماتریس اختلاط یا ماتریس درهم ریختگی (Confusion Matrix or Error Matrix)

به منظور سنجش مدل از یک ماتریس دو در دو به نام ماتریس درهم ریختگی استفاده می شود

مثبت کاذب (FP)	مثبت صحیح (TP)
منفی کاذب (FN)	منفی صحیح (TN)

		Predicted condition	
		Positive (PP) $PP = TP + FP$	Negative (PN) $PN = FN + TN$
Actual condition	Total population $= P + N$		
	Positive (P) $P = TP + FN$	True positive (TP)	False negative (FN)
در واقعیت صحیح (P)	Negative (N) $N = FP + TN$	False positive (FP)	True negative (TN)

ماتریس درهم ریختگی

Soft Computing

11

## ارزیابی الگوریتم

### ماتریس درهم ریختگی برای مثال بیماران سرطانی

Individual Number	1	2	3	4	5	6	7	8	9	10	11	12
Actual Classification	1	1	1	1	1	1	1	1	0	0	0	0
Predicted Classification	0	0	1	1	1	1	1	1	1	0	0	0
Result	FN	FN	TP	TP	TP	TP	TP	TP	FP	TN	TN	TN

		Predicted condition				Predicted condition		
		Positive (PP)	Negative (PN)			Total $8 + 4 = 12$	Cancer	Non-cancer
Actual condition	Positive (P)	True positive (TP)	False negative (FN)	Actual condition	Cancer 8	6	2	
	Negative (N)	False positive (FP)	True negative (TN)		Non-cancer 4	1	3	

Soft Computing

12

## ارزیابی الگوریتم

### معیارها در ماتریس اختلاط یا ماتریس درهم ریختگی

به منظور اندازه‌گیری کارایی مدل از معیارهای زیر برای حالت مثبت (مقدار یک) استفاده می‌شود

#### صحت یا حساسیت (Sensitivity, Recall)

$$TPR \text{ (Recall)} = \frac{TP}{P} = \frac{TP}{TP+FN}$$

#### Hit rate, True Positive Rate (TPR)

صحت برابر است با تعداد مثبت صحیح به تعداد صحیح در واقعیت

این معیار نسبت پیش‌بینی مثبت درست مدل به کل مقادیر مثبت درست واقعی را نشان می‌دهد

#### دقت (Precision)

$$PPV \text{ (Precision)} = \frac{TP}{PP} = \frac{TP}{TP+FP}$$

#### Positive Predictive Value (PPV)

دقت برابر است با تعداد مثبت صحیح به تعداد صحیح در مدل (پیش‌بینی)

این معیار نسبت پیش‌بینی مثبت درست مدل به کل مقادیر مثبت درست مدل را نشان می‌دهد

Soft Computing

13

## ارزیابی الگوریتم

### معیارها در ماتریس اختلاط یا ماتریس درهم ریختگی

مشابه حالت قبل از معیارهای زیر برای حالت منفی (مقدار صفر) استفاده می‌شود

#### Specificity

$$TNR = \frac{TN}{N} = \frac{TN}{TN+FP}$$

#### True Negative Rate(TNR) ,Selectivity

برابر است با تعداد منفی صحیح به تعداد منفی در واقعیت

این معیار در برابر حساسیت است

#### Negative Predictive Value (NPV)

$$NPV = \frac{TN}{TN+FN}$$

Soft Computing

14

## ارزیابی الگوریتم

معیارها در ماتریس اختلاط یا ماتریس درهم ریختگی

به منظور اندازه‌گیری کارایی مدل از معیارهای زیر نیز استفاده می‌شود

$$\text{Support} = P$$

**(Support)**

تکیه‌گاه تعداد مشاهده مقادیر ۱ (هر کلاسی از داده‌ها) در مشاهدات است.

$$F_1 = \frac{1}{\frac{1}{2\text{Precision}} + \frac{1}{2\text{Recall}}} = 2 \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}}$$

**اندازه  $F_1$**

میانگین همساز دو معیار دقت و صحت است.  
مقدار صفر بدترین حالت و مقدار یک بهترین  
حالت است و تعادل دقت و صحت را دربردارد

$$\text{ACC} = \frac{\text{TP} + \text{TN}}{\text{P} + \text{N}} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{TN} + \text{FP} + \text{FN}}$$

**(Accuracy)**

Soft Computing

15

## صحت سنجی دو کلاسی

ماتریس درهم ریختگی (Confusion Matrix)


Predicted Class

		Positive	Negative	<b>Sensitivity</b> $\frac{TP}{(TP + FN)}$
<b>Actual Class</b>	<b>Positive</b>	True Positive (TP)	False Negative (FN) <b>Type II Error</b>	
	<b>Negative</b>	False Positive (FP) <b>Type I Error</b>	True Negative (TN)	<b>Specificity</b> $\frac{TN}{(TN + FP)}$
	<b>Precision</b> $\frac{TP}{(TP + FP)}$	<b>Negative Predictive Value</b> $\frac{TN}{(TN + FN)}$	<b>Accuracy</b> $\frac{TP + TN}{(TP + TN + FP + FN)}$	

ماتریس درهم ریختگی می‌تواند برای کلاسهای بیشتر نیز توسعه یابد

Soft Computing

16



صحت سنجی چند کلاسی

ماتریس درهم ریختگی چند طبقه

<b>Recall</b> is the fraction of samples in class $i$ that the model correctly classified as class $i$	$\text{Recall} = \frac{C_{ii}}{\sum_j C_{ij}}$
$C_{ii}$ : The count of samples correctly classified as class $i$ (True Positives for class $i$ ).	
$\sum_j C_{ij}$ : The total number of samples that actually belong to class $i$ , regardless of how they were classified (True Positives + False Negatives for class $i$ ).	
<b>Precision</b> is the fraction of samples that the model assigned to class $i$ that actually belong to class $i$ .	$\text{Precision} = \frac{C_{ii}}{\sum_j C_{ji}}$
$C_{ii}$ : The count of samples correctly classified as class $i$ (True Positives for class $i$ ).	
$\sum_j C_{ji}$ : The total number of samples predicted as class $i$ , regardless of their actual class (True Positives + False Positives for class $i$ ).	
<b>Accuracy</b> is the overall fraction of correctly classified samples across all classes	$\text{Accuracy} = \frac{\sum_i C_{ii}}{\sum_i \sum_j C_{ij}}$
$\sum_i C_{ii}$ : The sum of True Positives across all classes (correctly classified samples for each class).	
$\sum_i \sum_j C_{ij}$ : The total number of samples across all classes (including both correct and incorrect classifications).	18

## صحت سنجی چند کلاسی

### میانگین گیری بدون وزن بین چند کلاس

- **Macroaveraging:** treats each class equally by computing the performance measure (like F1 score) for each class independently and then averaging them.
- **Implication:** Macroaveraging gives equal weight to all classes, regardless of the number of samples in each class. This is useful when you want each class to have an **equal impact on the overall metric**, even if some classes have fewer samples.

### میانگین گیری وزن دار بین چند کلاس

- **Microaveraging:** Microaveraging aggregates all true positives (TP), false positives (FP), and false negatives (FN) across all classes and then computes a single performance measure.
- **Implication:** Microaveraging takes into account the imbalance of class distributions by weighing each sample equally. It is especially useful in cases where **class imbalance is significant**, as it doesn't prioritize one class over another.

## صحت سنجی رگرسیون لجستیک

### ماتریس درهم ریختگی (Confusion Matrix)



به منظور اندازه گیری کارایی مدل ابتدا داده های مساله را به دو قسمت آموزش و تست تقسیم می کنیم.  
در دستور زیر داده های تست ۳۰ درصد داده های مساله در نظر گرفته شده اند



```
# Split the data into training and testing sets
X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=0.3, random_state=42)
```


محاسبه معیارها

```
from sklearn import metrics
print(metrics.classification_report(y_test, y_pred))
```

	precision	recall	f1-score	support
0	0.91	0.97	0.94	10981
1	0.52	0.25	0.34	1376







## ابعاد کاسبرگ و گلبرگ زنبق مختلف

فایل دیتای ایریس دارای طول و عرض کاسبرگ و گلبرگ است برچسب نام گل است که دارای سه نوع زنبق است

	sepal_length	sepal_width	petal_length	petal_width	species
0	5.1	3.5	1.4	0.2	Iris-setosa
1	4.9	3.0	1.4	0.2	Iris-setosa
2	4.7	3.2	1.3	0.2	Iris-setosa
3	4.6	3.1	1.5	0.2	Iris-setosa
4	5.0	3.6	1.4	0.2	Iris-setosa

طول و عرض کاسبرگ و گلبرگ است چهار ویژگی گلها است ترسیم ویژگیها در چهار بعد میسر نیست و از روش‌های دیگری باید بهره گرفت

Soft Computing

27

## طبقه‌بندی چند کلاسی

مثال: طبقه‌بندی چند کلاسی فایل دیتای ایریس  
فایل: 8 multiclass regression iris petal.py:

```
import seaborn as sns
import pandas as pd
import matplotlib.pyplot as plt
from sklearn.datasets import load_iris
from sklearn.linear_model import LogisticRegression
from sklearn.model_selection import train_test_split
from sklearn.metrics import accuracy_score, classification_report
# Load dataset
data = load_iris()
X = data.data[:, 2:4] # Select only petal length and petal width
y = data.target
# Map target numbers to iris species names
species_mapping = {0: 'Setosa', 1: 'Versicolor', 2: 'Virginica'}
species_names = [species_mapping[label] for label in y]
# Convert to DataFrame for easier plotting and visualization
df = pd.DataFrame(X, columns=['petal length (cm)', 'petal width (cm)'])
df['species'] = species_names # Use species names instead of numbers
# Split the data into training and test sets
X_train, X_test, y_train, y_test = train_test_split(X, y,
test_size=0.3, random_state=0)
```

Soft Computing

28

## طبقه بندی چند کلاسی

مثال: طبقه بندی چند کلاسی فایل دیناتی ایریس

```
# Initialize and train logistic regression model for multiclass classification
logreg = LogisticRegression(multi_class='multinomial', solver='lbfgs',
max_iter=200)
logreg.fit(X_train, y_train)

# Predict and evaluate
y_pred = logreg.predict(X_test)
print("Accuracy:", accuracy_score(y_test, y_pred))
print(classification_report(y_test, y_pred,
target_names=species_mapping.values()))

# Convert test labels and predictions to species names for plotting
y_test_names = [species_mapping[label] for label in y_test]
y_pred_names = [species_mapping[label] for label in y_pred]
# Plotting classification results for petal length and petal width
plt.figure(figsize=(8, 6))
sns.scatterplot(x=X_test[:, 0], y=X_test[:, 1], hue=y_test_names,
style=y_pred_names, palette='viridis', s=100, edgecolor="k")
plt.xlabel('Petal Length (cm)')
plt.ylabel('Petal Width (cm)')
plt.title('Logistic Regression Classification: Petal Length vs Petal Width')
plt.legend(title="True Species")
plt.show()
```

29

Soft Computing


## طبقه بندی چند کلاسی

مثال: طبقه بندی چند کلاسی فایل دیناتی ایریس

	precision	recall	f1-score	support
Setosa	1.00	1.00	1.00	16
Versicolor	1.00	0.94	0.97	18
Virginica	0.92	1.00	0.96	11
accuracy			0.98	45
macro avg	0.97	0.98	0.98	45
weighted avg	0.98	0.98	0.98	45

30

Soft Computing



طبقه بندی چند کلاسی

مثال: طبقه بندي چند کلاسی فایل دیتای ایریس با چهار ویژگی طول و عرض گلبرگ و کاسبرگ

```
import seaborn as sns 8 multiclass regression iris pairplot.py: جلسه
import pandas as pd
import matplotlib.pyplot as plt
from sklearn.datasets import load_iris
from sklearn.linear_model import LogisticRegression
from sklearn.model_selection import train_test_split
from sklearn.metrics import accuracy_score, classification_report

# Load dataset
data = load_iris()
X = data.data
y = data.target
# Map target numbers to iris species names
species_mapping = {0: 'Setosa', 1: 'Versicolor', 2: 'Virginica'}
species_names = [species_mapping[label] for label in y]

# Convert to DataFrame for easier plotting with species names
df = pd.DataFrame(X, columns=data.feature_names)
df['species'] = species_names # Use species names instead of numbers
```

## طبقه بندی چند کلاسی


مثال: طبقه بندی چند کلاسی فایل دیناتی ایریس با چهار ویژگی طول و عرض گلبرگ و کاسپرگ

```
# Split the data into training and test sets
X_train, X_test, y_train, y_test = train_test_split(X, y,
test_size=0.3, random_state=0)
# Initialize and train logistic regression model for multiclass
classification
logreg = LogisticRegression(multi_class='multinomial',
solver='lbfgs', max_iter=200)
logreg.fit(X_train, y_train)
# Predict and evaluate
y_pred = logreg.predict(X_test)
print("Accuracy:", accuracy_score(y_test, y_pred))
print(classification_report(y_test, y_pred,
target_names=species_mapping.values()))

# Pairplot for 4D visualization using seaborn with species names
plt.figure(figsize=(8, 5))
sns.pairplot(df, hue='species', palette='viridis')
plt.suptitle("Pairwise 2D Scatter Plots with Iris Species", y=0.99)
plt.show()
```

Soft Computing

33



Soft Computing

34

## تمرین برنامه نویسی

تمرین هشتم :

یک برنامه به زبان پایتون بنویسید که یک فایل داده را خوانده و رگرسیون لجستیک برای سه ویژگی و دو کلاس را حساب نماید.

۱- داده ها را طبقه بندی کنید

۲- طبقه بندی انجام شده را سه بعدی رسم کنید

۳- دقت طبقه بندی را بدست آورید

۴- برای یک حالت با ویژگیهای مشخص، کلاس را مشخص کنید

## Non-Linear Regression

- Note that linear regression is to regression what the perceptron is to classification
  - Simple, useful models which will often underfit
- The more powerful classification models which we will be discussing going forward in class can usually also be used for non-linear regression
  - MLP with Backpropagation, Decision Trees, Nearest Neighbor, etc.
- They can learn functions with arbitrarily complex high dimensional shapes

# Summary


- Linear Regression and Logistic Regression are nice tools for many simple situations
  - But both force us to fit the data with one shape (line or sigmoid) which will often underfit
- Intelligible results
- When problem includes more arbitrary non-linearity then we need more powerful models which we will introduce
  - Yet non-linear data transformations (e.g. Quadric perceptron) can help in these cases while still using a linear model for learning
- These models are commonly used in data mining applications and also as a "first attempt" at understanding data trends, indicators, etc.

Soft Computing

39

# رگرسیون

## 5 types of regression



© 2023 TECHTARGET. ALL RIGHTS RESERVED. TechTarget

Soft Computing

40

## یادگیری ناظرت شده - رگرسیون

الگوریتم های معروف رگرسیون:

رگرسیون خطی

رگرسیون چندجمله ای

رگرسیون ریج

رگرسیون درخت تصمیم

رگرسیون جنگل تصادفی

رگرسیون ماشین بردار پشتیبان

