

Лабораторное занятие 8. Решение задач на L2 регулирование.

8-зертханалық сабақ. L2 реттеу ге есептер шығару.

```
import sklearn.model_selection as GridSearchCV

# отключим всякие предупреждения Anaconda
import warnings
warnings.filterwarnings('ignore')

%matplotlib inline

from matplotlib import pyplot as plt
import seaborn as sns


import numpy as np
import pandas as pd

from sklearn.preprocessing import PolynomialFeatures
from sklearn.linear_model import LogisticRegression, LogisticRegressionCV
from sklearn.model_selection import cross_val_score, StratifiedKFold
from sklearn.model_selection import GridSearchCV

data=pd.read_csv("dataregression2.csv")
data.head(10) X = data.ix[:,3].values
y = data.ix[:,3].values

plt.scatter(X[y == 1, 0], X[y == 1, 1], c='green', label='Выпущен')
plt.scatter(X[y == 0, 0], X[y == 0, 1], c='red', label='Бракован')

plt.xlabel("Тест 1")
plt.ylabel("Тест 2")

plt.title('2 теста микрочипов')

plt.legend();
```

Определяем функцию для отображения разделяющей кривой классификатора

```
import sklearn.linear_model
```

```
import sklearn.svm
```

```
from sklearn.linear_model import LinearRegression
```

```
clf=LogisticRegression()
```

```
from future import print_function, division
```

```
#Создадим объект sklearn, который добавит в матрицу X полиномиальные
```

```
#признаки вплоть до степени 7 и обучим логистическую регрессию с
```

```
#параметром регуляризации  $C=10^{-2}$ . Изобразим разделяющую границу.
```

```
poly = PolynomialFeatures(degree=7)
```

```
X_poly = poly.fit_transform(X)
```

```
C = 1
```

```
logit = LogisticRegression(C=C, n_jobs=-1, random_state=17)
```

```
logit.fit(X_poly, y)
```

```
plot_boundary(logit, X, y, grid_step=.005, poly_featurizer=poly)
```

```
plt.scatter(X[y == 1, 0], X[y == 1, 1], c='green', label='Выпущен')
```

```
plt.scatter(X[y == 0, 0], X[y == 0, 1], c='red', label='Бракован')
```

```
plt.xlabel("Тест 1")
```

```
plt.ylabel("Тест 2")
```

```
plt.title('2 теста микрочипов. Логит с  $C=1$ ')  
plt.legend();
```

```
print("Доля правильных ответов классификатора на обучающей выборке:",
```

```
round(logit.score(X_poly, y), 3))
```

```
C = 1e4
```

```
logit = LogisticRegression(C=C, n_jobs=-1, random_state=17)
```

```
logit.fit(X_poly, y)
```

```
plot_boundary(logit, X, y, grid_step=.005, poly_featurizer=poly)
```

```
plt.scatter(X[y == 1, 0], X[y == 1, 1], c='green', label='Выпущен')
```

```
plt.scatter(X[y == 0, 0], X[y == 0, 1], c='red', label='Бракован')
```

```
plt.xlabel("Тест 1")
```

```
plt.ylabel("Тест 2")
```

```
plt.title('2 теста микрочипов. Логит с C=10k')
```

```
plt.legend();
```

```
print("Доля правильных ответов классификатора на обучающей выборке:",
```

```
round(logit.score(X_poly, y), 3))
```

```
#
```

Настройка параметра регуляризации

Теперь найдем оптимальное (в данном примере) значение параметра регуляризации C . Сделать это можно с помощью `LogisticRegressionCV` – перебора параметров по сетке с последующей кросс-валидацией. Этот класс создан специально для логистической регрессии (для нее известны эффективные алгоритмы перебора параметров), для произвольной модели мы бы использовали `GridSearchCV`, `RandomizedSearchCV` или, например, специальные алгоритмы оптимизации гиперпараметров, реализованные в `hyperopt`.

```
skf = StratifiedKFold(n_splits=5, shuffle=True, random_state=17)
```

```
c_values = np.logspace(-2, 3, 500)
```

```
logit_searcher = LogisticRegressionCV(Cs=c_values, cv=skf, verbose=1, n_jobs=-1)
```

```
logit_searcher.fit(X_poly, y)
```