



DATA SCIENCE FOR PREDICTIVE MODELING

Tessy Badriyah, PhD.

Politeknik Elektronika Negeri Surabaya (PENS), INDONESIA


Data Mining and Data Science

webinar series #2

25 Agustus 2020

2nd International Conference on Electrical, Communication and Computer Engineering

OUTLINE



- Pendahuluan
- Data Science
- Predictive Modeling
- Workshop Predictive Modeling dengan Python

Courtesy: <https://docs.microsoft.com/en-us/azure/machine-learning/team-data-science-process/lifecycle>

PENDAHULUAN

- Berbagai aktivitas kegiatan dalam kehidupan secara langsung maupun tidak memerlukan pengelolaan data
- Contoh:
- Bank : menabung, transfer, deposit.
- Reservasi : hotel, pesawat, kereta api.
- Belanja : toko, mall, supermarket.
- Dan lain-lain.

DATA EVOLUTION

Data Mentah



Informasi




Pengetahuan/
Knowledge




Decision

DARI INFORMASI MENJADI PENGETAHUAN



- Adanya ledakan data dengan pertumbuhan data secara eksponensial

Tahapan Data Mining



BIG DATA

- Istilah Big Data muncul pertama kali pada sekitar tahun 2000-an, ketika definisi Big Data dijelaskan dalam 3V oleh seorang analist bernama Doug Laney
 - Volume, data yang disimpan oleh suatu organisasi dalam jumlah yang besar
 - Velocity, ada kebutuhan untuk dapat mengakses data besar tersebut dengan cepat
 - Variety, data berasal dari berbagi macam variasi format data.

FORMAT DATA


- Berikut ini 3 jenis Format data:
 - Structured, relational database (RDBMS)
 - Semi-Structured, XML, JSON
 - Unstructured, document, jurnal, metadata, gambar, video, file teks, audio, ebooks, email message, social media, dll.

BIG DATA AND DATA SCIENCE

- Bidang ilmu Data Science berkaitan dengan penyelesaian permasalahan kompleks menggunakan data, tidak hanya data terstruktur seperti SQL tapi juga data yang tidak terstruktur dan semi-terstruktur dari era kemunculan Big Data.
- Data science adalah aplikasi dari proses data mining dan menggunakan metode machine learning dalam domain yang spesifik.
- Menurut survey, saat ini data science merupakan pekerjaan yang paling banyak dicari, bisa disebut sebagai the sexiest job of the twenty-first century.

Data Science Is Multidisciplinary

By Brendan Tierney, 2012



DATA

PREDICTIVE MODELING / PREDICTIVE ANALYTICS


- Menggunakan data historical untuk memprediksi kejadian yang terjadi berikutnya.
- Data historical adalah data yang sudah diketahui atribut outputnya => disebut dengan data training => digunakan untuk men-generate model.
- Model yang dihasilkan kemudian diaplikasikan ke dalam data testing (data testing = data yang terjadi berikutnya yang tidak diketahui atribut output nya).

PYTHON PROGRAMMING

- Mengapa menggunakan Python?
- Karena kita perlu bekerja dengan pemrograman multipurpose, simple, dengan Bahasa yang efisien
 - Functional
 - Imperative
 - Object-oriented
 - Procedural

GOOGLE COLAB

- Dan untuk menjalankan pemrograman python kita gunakan google colab yang dapat diakses pada : colab.research.google.com
- Sebelumnya, anda harus login dulu dengan akun googlemail.




PEMBELAJARAN SEDERHANA

- Loading data
- Training sebuah data
- Menampilkan hasilnya

- `from sklearn.datasets import load_boston`
- `Boston=load_boston()`
- `X, y = Boston.data, Boston.target`
- `from sklearn.linear_model import LinearRegression`
- `hypothesis = LinearRegression(normalize=True_`
- `hypothesis.fit(X,y)`
- `print(hypothesis.coef_)`

PEMBELAJARAN SEDERHANA



The image shows a Google Colaboratory notebook interface. The browser address bar shows the URL `colab.research.google.com/drive/1OxudI9hGIBZsHr71U8SVItOodNV7...`. The notebook title is "Untitled1.ipynb - Colaboratory". The code cell contains the following Python code:

```
from sklearn.datasets import load_boston
Boston=load_boston()
X, y = Boston.data, Boston.target
from sklearn.linear_model import LinearRegression
hypothesis = LinearRegression(normalize=True)
hypothesis.fit(X,y)
print(hypothesis.coef_)
```

The output of the code is a 5x4 matrix of coefficients:

```
[ -1.08011358e-01  4.64204584e-02  2.05586264e-02  2.68673382e+00
 -1.77666112e+01  3.80986521e+00  6.92224640e-04 -1.47556685e+00
  3.06049479e-01 -1.23345939e-02 -9.52747232e-01  9.31168327e-03
 -5.24758378e-01]
```

At the bottom of the notebook, there is a file named "sepeda.jpg" and a "Show all" button.

WORKSHOP PREDICTIVE MODELING

- Berfokus pada sub bidang yang spesifik yaitu predictive modeling.
- Bidang ini paling banyak digunakan dalam industry dan merupakan bidang yang menggunakan banyak menggunakan scikit-learn library yang ada di Python.
- Predictive modeling berfokus pada pengembangan model yang membuat prediksi yang akurat

PREDICTIVE MODELING WORKFLOW

- Mendefinisikan masalah: melakukan investigasi dan mengkarakterisasi persoalan dalam rangka memahami tujuan project.
- Menganalisa Data: Menggunakan descriptive statistics dan visualisasi untuk bisa lebih memahami data yang digunakan.
- Mempersiapkan Data: Menggunakan transformasi data untuk mendapatkan struktur data yang lebih baik dari persoalan prediksi dari algoritma pemodelan.
- Mengevaluasi Algoritma: Mendesain pengujian yang dapat mengevaluasi jumlah algoritma standart pada data dan memilih beberapa yang paling baik untuk bisa diinvestigasi lebih lanjut.
- Meningkatkan hasil: Menggunakan algorithm tuning dan metode ensemble untuk mendapatkan performansi yang lebih baik.
- Mempresentasikan hasil: Menyelesaikan model, membuat prediksi dan mempresentasikan hasilnya.

LOAD CSV FILES DENGAN PANDAS

- `# Load CSV using Pandas`
- `from pandas import read_csv`
- `filename = 'diabetes.csv'`
- `names = ['preg', 'plas', 'pres', 'skin', 'test', 'mass', 'pedi', 'age', 'class']`
- `data = read_csv(filename, names=names)`
- `print(data.shape)`

MELIHAT ISI DATA

- `# Menampilkan 20 baris pertama`
- `from pandas import read_csv`
- `filename = "pima-indians-diabetes.data.csv"`
- `names = ['preg', 'plas', 'pres', 'skin', 'test', 'mass', 'pedi', 'age', 'class']`
- `data = read_csv(filename, names=names)`
- `peek = data.head(20)`
- `print(peek)`

DESCRIPTIVE STATISTICS

- `# Menampilkan 20 baris pertama`
- `from pandas import read_csv`
- `# Ringkasan Statistik`
- `from pandas import read_csv`
- `from pandas import set_option`
- `filename = "pima-indians-diabetes.data.csv"`
- `names = ['preg', 'plas', 'pres', 'skin', 'test', 'mass', 'pedi', 'age', 'class']`
- `data = read_csv(filename, names=names)`
- `set_option('display.width', 100)`
- `set_option('precision', 3)`
- `description = data.describe()`
- `print(description)`

DISTRIBUSI CLASS (HANYA UNTUK KLASIFIKASI)

- # Distribusi Class
- from pandas import read_csv
- filename = "pima-indians-diabetes.data.csv"
- names = ['preg', 'plas', 'pres', 'skin', 'test', 'mass', 'pedi', 'age', 'class']
- data = read_csv(filename, names=names)
- class_counts = data.groupby('class').size()
- print(class_counts)

```
Output :  
class  
0 500  
1 268
```

KORELASI DIANTARA ATRIBUT

- # Korelasi menggunakan Pairwise Pearson
- `from pandas import read_csv`
- `from pandas import set_option`
- `filename = "pima-indians-diabetes.data.csv"`
- `names = ['preg', 'plas', 'pres', 'skin', 'test', 'mass', 'pedi', 'age', 'class']`
- `data = read_csv(filename, names=names)`
- `set_option('display.width', 100)`
- `set_option('precision', 3)`
- `correlations = data.corr(method='pearson')`
- `print(correlations)`

```
      preg  plas  pres  skin  test  mass  pedi  age  class
preg  1.000  0.129  0.141 -0.082 -0.074  0.018 -0.034  0.544  0.222
plas  0.129  1.000  0.153  0.057  0.331  0.221  0.137  0.264  0.467
pres  0.141  0.153  1.000  0.207  0.089  0.282  0.041  0.240  0.065
skin -0.082  0.057  0.207  1.000  0.437  0.393  0.184 -0.114  0.075
test -0.074  0.331  0.089  0.437  1.000  0.198  0.185 -0.042  0.131
mass  0.018  0.221  0.282  0.393  0.198  1.000  0.141  0.036  0.293
pedi -0.034  0.137  0.041  0.184  0.185  0.141  1.000  0.034  0.174
age   0.544  0.264  0.240 -0.114 -0.042  0.036  0.034  1.000  0.238
class 0.222  0.467  0.065  0.075  0.131  0.293  0.174  0.238  1.000
```

Pemodelan dengan Logistic Regression

Teknik sampling: train_test_split

- ❖ Evaluasi menggunakan data training dan data testing
- ❖ `from pandas import read_csv`
- ❖ `from sklearn.model_selection import train_test_split`
- ❖ `from sklearn.linear_model import LogisticRegression`
- ❖ `filename = 'pima-indians-diabetes.data.csv'`
- ❖ `names = ['preg', 'plas', 'pres', 'skin', 'test', 'mass', 'pedi', 'age', 'class']`
- ❖ `dataframe = read_csv(filename, names=names)`
- ❖ `array = dataframe.values`
- ❖ `X = array[:,0:8]`
- ❖ `Y = array[:,8]`
- ❖ `test_size = 0.33`
- ❖ `seed = 7`
- ❖ `X_train, X_test, Y_train, Y_test = train_test_split(X, Y, test_size=test_size,`
- ❖ `random_state=seed)`
- ❖ `model = LogisticRegression()`
- ❖ `model.fit(X_train, Y_train)`
- ❖ `result = model.score(X_test, Y_test)`
- ❖ `print("Accuracy: %.3f%%") % (result*100.0)`

Output :
Accuracy: 75.591%

Teknik sampling : k-fold Cross Validation

- ❖ # Evaluasi menggunakan Cross Validation
- ❖ from pandas import read_csv
- ❖ from sklearn.model_selection import KFold
- ❖ from sklearn.model_selection import cross_val_score
- ❖ from sklearn.linear_model import LogisticRegression
- ❖ filename = 'pima-indians-diabetes.data.csv'
- ❖ names = ['preg', 'plas', 'pres', 'skin', 'test', 'mass', 'pedi', 'age', 'class']
- ❖ dataframe = read_csv(filename, names=names)
- ❖ array = dataframe.values
- ❖ X = array[:,0:8]
- ❖ Y = array[:,8]
- ❖ num_folds = 10
- ❖ seed = 7
- ❖ kfold = KFold(n_splits=num_folds, random_state=seed)
- ❖ model = LogisticRegression()
- ❖ results = cross_val_score(model, X, Y, cv=kfold)
- ❖ print("Accuracy: %.3f%% (%.3f%%)" % (results.mean()*100.0, results.std()*100.0))

Output :
Accuracy: 76.951% (4.841%)

Tuning Parameter pada Algoritma Support Vector Machine (SVM)

```
In [1]: from pandas import read_csv  
import numpy as np
```

```
In [2]: from sklearn.datasets import make_blobs  
from sklearn.model_selection import RepeatedStratifiedKFold  
from sklearn.model_selection import GridSearchCV
```

```
In [3]: filename = 'pima-indians-diabetes.csv'  
names = ['preg', 'plas', 'pres', 'skin', 'test', 'mass', 'pedi', 'age', 'class']  
dataframe = read_csv(filename, names=names)
```

```
In [4]: array = dataframe.values  
X = array[:,0:8]  
Y = array[:,8]
```

Tuning Parameter pada Algoritma Support Vector Machine (SVM)

```
In [20]: from sklearn.svm import SVC
```

```
In [21]: model = SVC()
```

```
In [22]: kernel = ['poly', 'rbf', 'sigmoid']  
C = [50, 10, 1.0, 0.1, 0.01]  
gamma = ['scale']
```

```
In [23]: param = dict(kernel=kernel,C=C,gamma=gamma)  
cv = RepeatedStratifiedKFold(n_splits=10, n_repeats=3, random_state=1)  
search = GridSearchCV(estimator=model, param_grid=param, n_jobs=-1, cv=cv, scoring='accuracy',error_score=0)  
result = search.fit(X, Y)
```

```
In [24]: print("Best: %f using %s" % (result.best_score_, result.best_params_))  
means = result.cv_results_['mean_test_score']  
stds = result.cv_results_['std_test_score']  
params = result.cv_results_['params']  
for mean, stdev, param in zip(means, stds, params):  
    print("%f (%f) with: %r" % (mean, stdev, param))
```

```
Best: 0.759125 using {'C': 10, 'gamma': 'scale', 'kernel': 'poly'}
```

PENUTUP

Telah diselesaikan, pembelajaran webinar series #2 dengan topik Data Science for Predictive Modeling, dengan pembahasan topik sebagai berikut:

- Pendahuluan
- Data Science
- Predictive Modeling
- Workshop Predictive Modeling dengan Python

Semoga ilmu yang dipelajari dapat bermanfaat, aamiin ...
Mohon maaf atas segala kekurangan dan terima kasih.

**Thank
You**

