みんなのPython勉強会 #13　　2016.6.7

scikit-learnで知る機械学習の全体像

辻 真吾
@tsjshg

自己紹介

- 1975年生まれ
- 都内のとある大学で研究やってることになってます
  - 研究室のテーマは癌とゲノム
  - 私がやっているのはPythonでデータ解析
- 昔はJavaやC++も好きでしたが、最近はほぼPython
- http://www.tsjshg.info/

Udemy

2016/6/30までの30% OFF クーポンです。

https://www.udemy.com/python-jp/?couponCode=stapy13-35d

Hype Cycle

- 先端技術がたどる典型的な道筋
- 米国の調査会社Gartnerが提唱

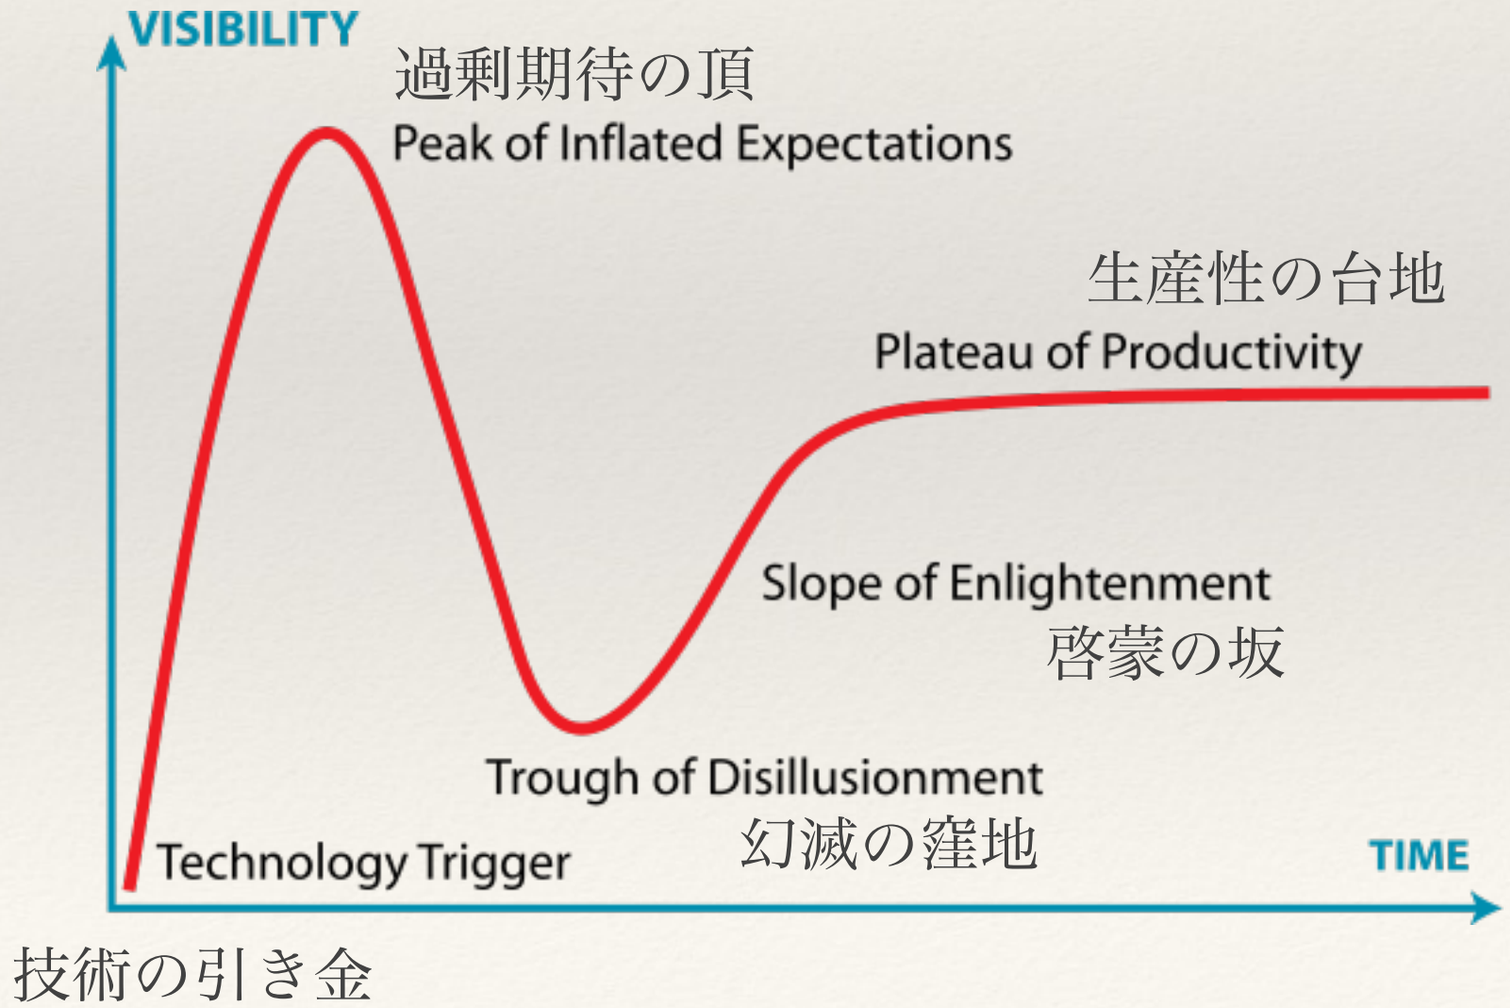

Gartner Hype Cycle 2015

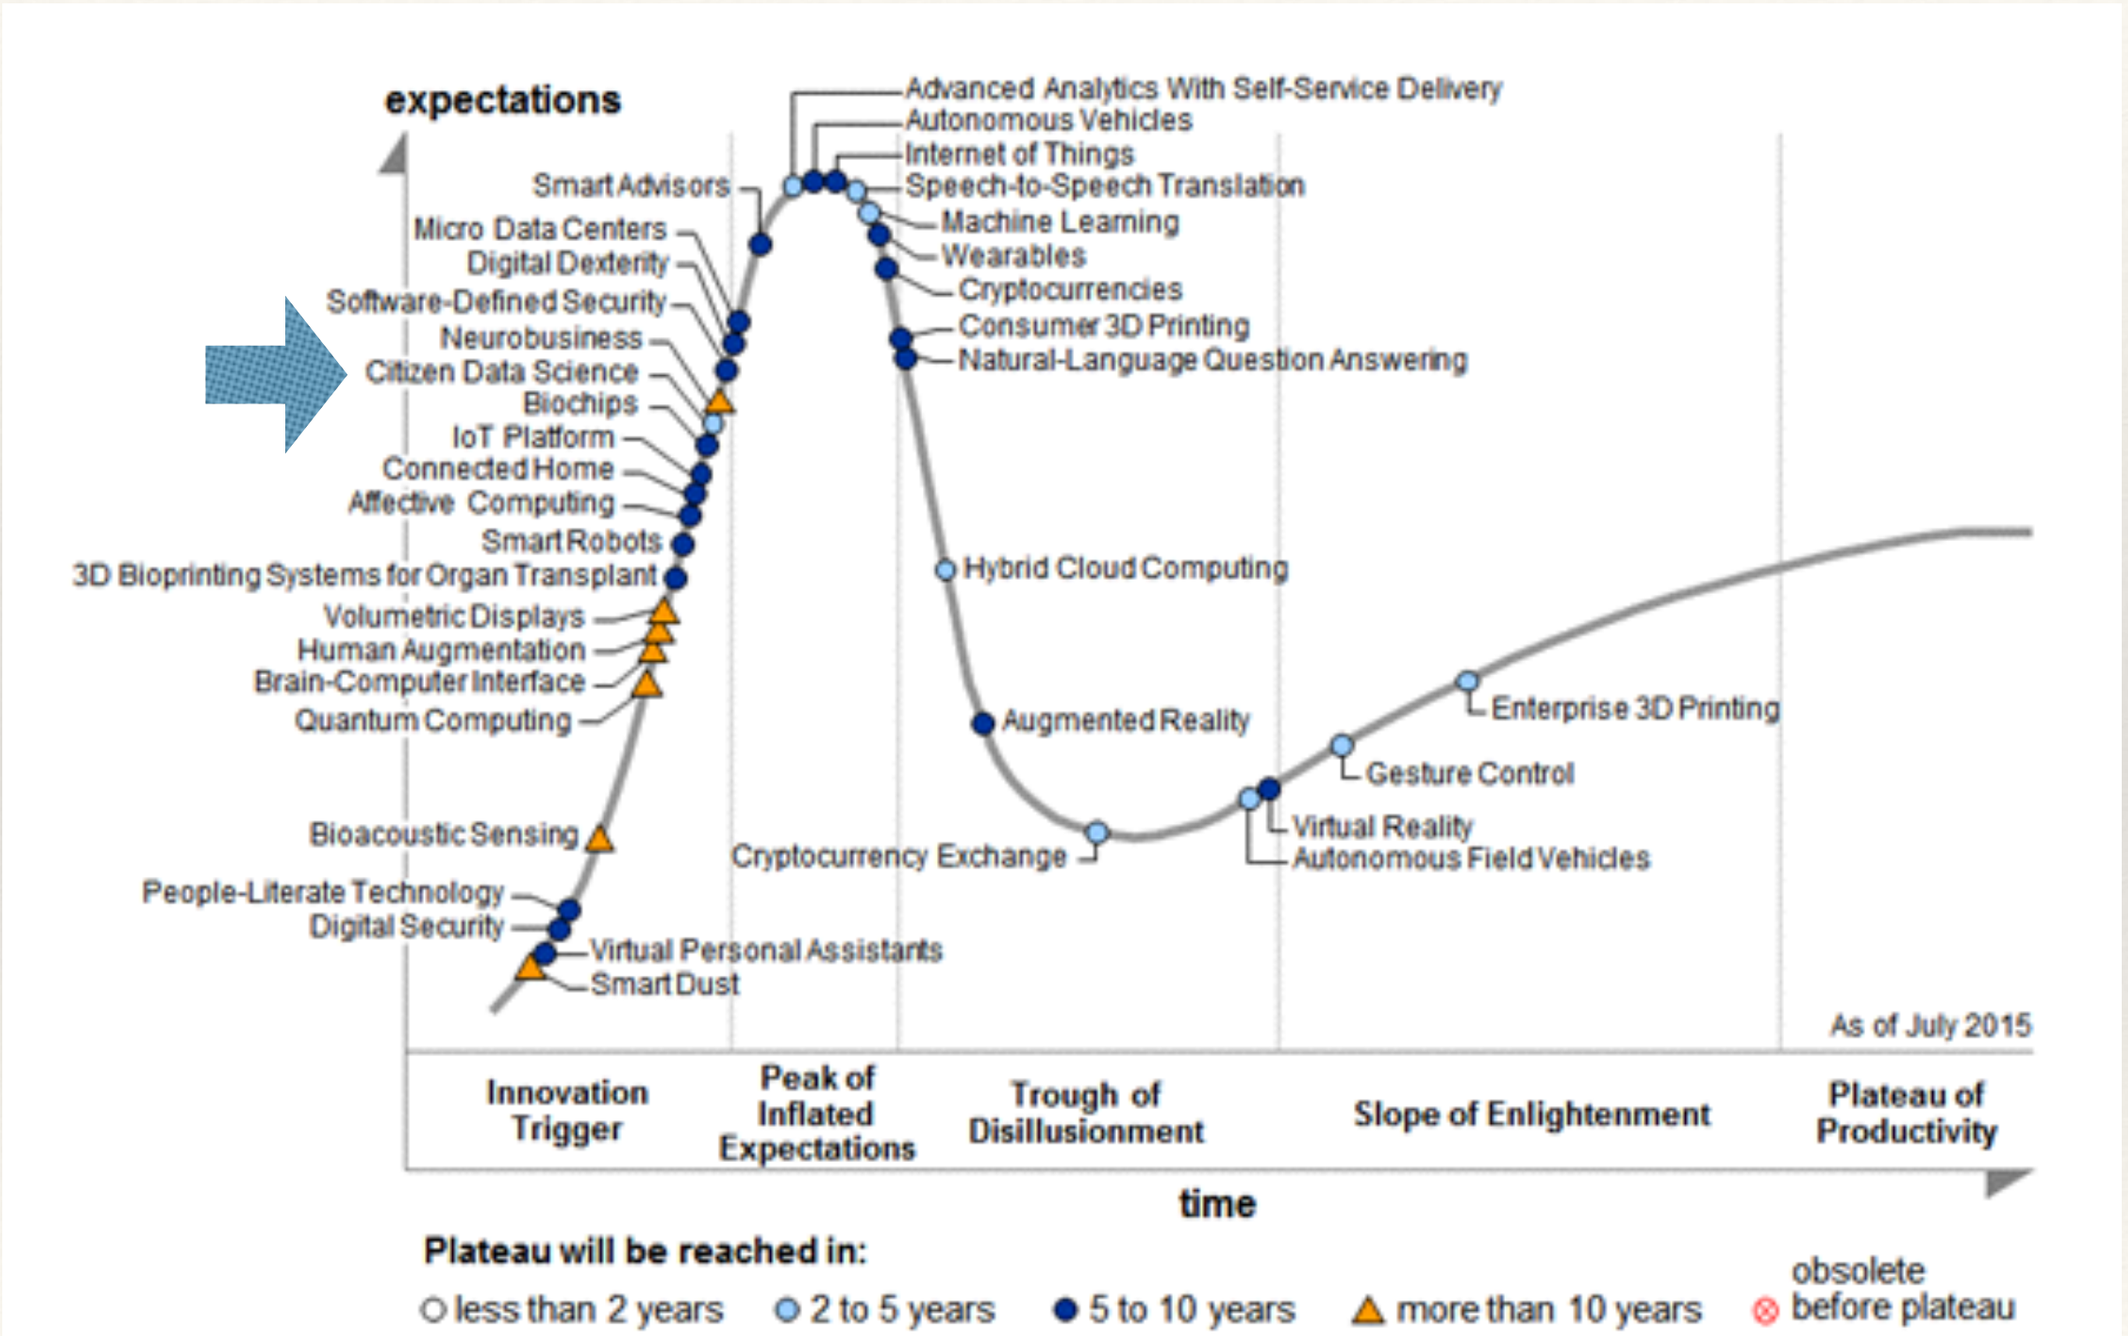

http://www.gartner.com/newsroom/id/3114217

Citizen Data Science

- （またも）Gartner社の提唱した概念
- 統計やプログラミングを専門にしないが、自分の分野のデータを解析する人
- データサイエンティストの不足を補う

データサイエンスやりたい？

Pythonが便利

- 最近、怒濤の勢い
- これから始めるな3系を
- 汎用言語なのでなんでもできますが、データ解析分野で大きな存在感

www.python.org

Pythonはglue（のり）言語

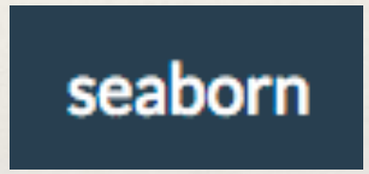

Anacondaがおすすめ！

- Continuum Analytics社が配布するPython
- 標準のPythonにcondaをはじめとして多くの外部ライブラリを同梱
- 無料です
- データ解析環境があっという間に整います

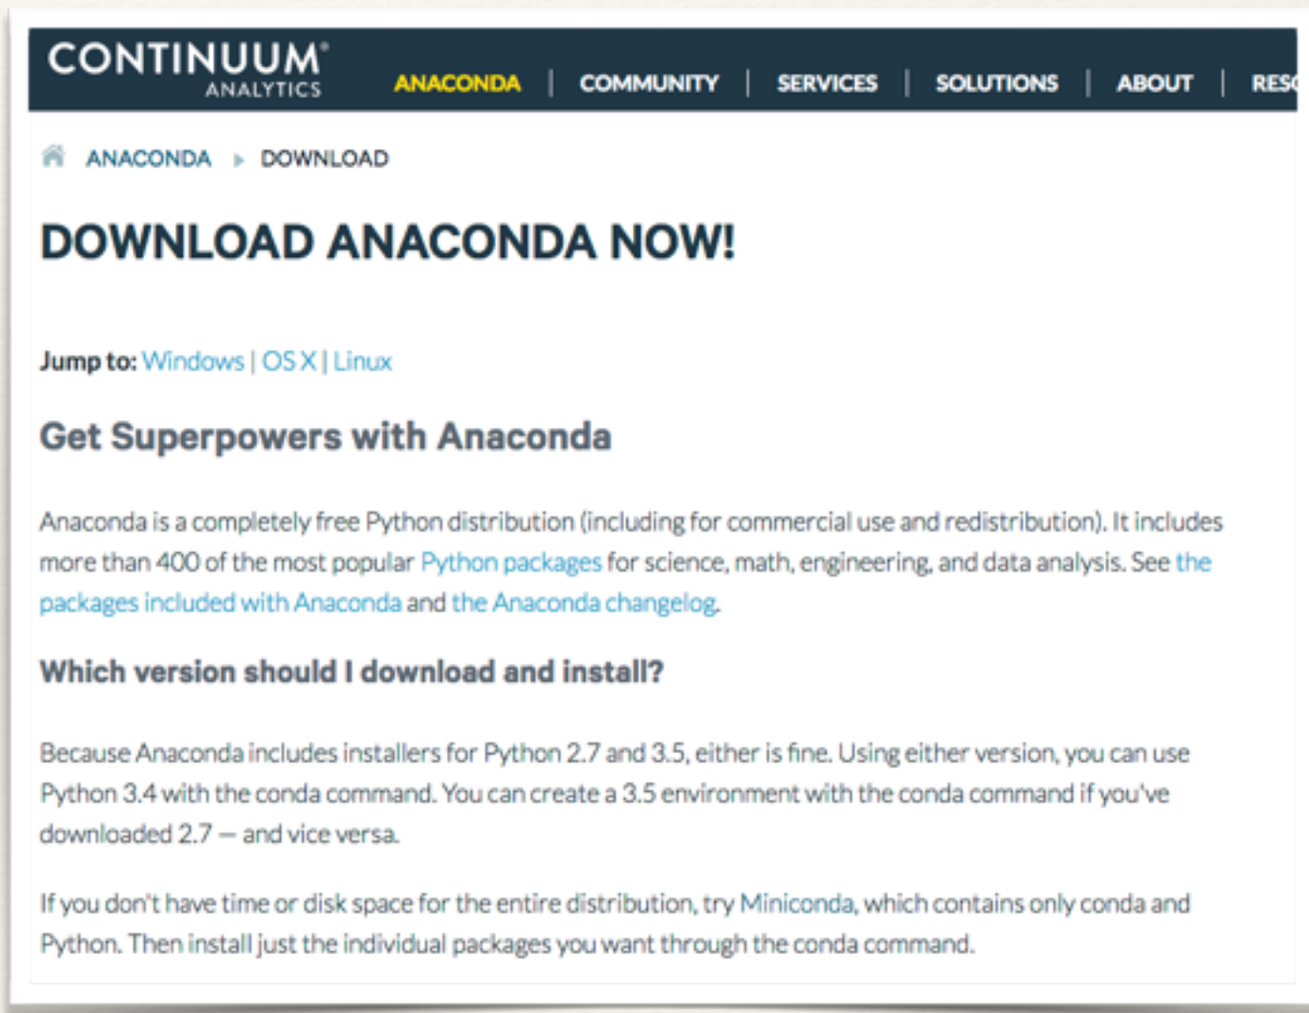

https://www.continuum.io

今日はscikit-learnの話を

（その前に）機械学習とは？

身長182cmで角刈りの人は男性か？女性か？

目的変数　　説明変数

性別	身長(cm)	髪型	眼鏡
男	182	角刈り	なし
男	170	七三分け	あり
女	160	ロング	あり
女	153	ショートヘア	なし

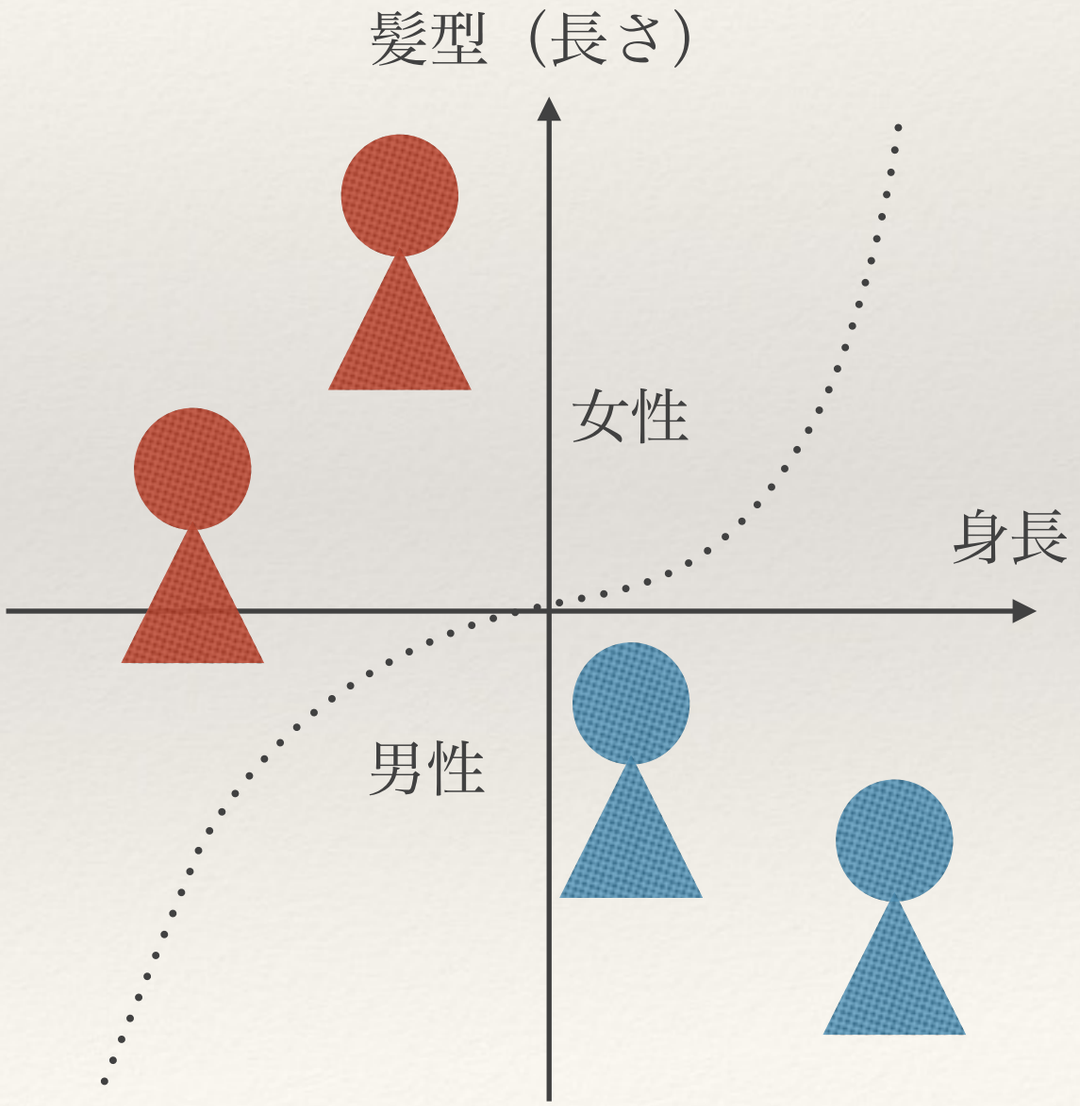

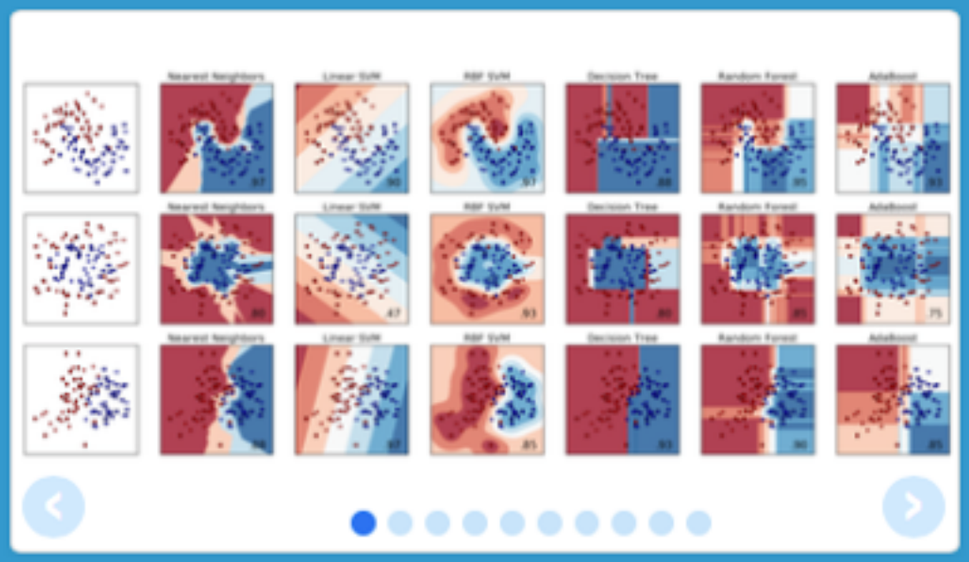

scikit-learn

Machine Learning in Python

- Simple and efficient tools for data mining and data analysis
- Accessible to everybody, and reusable in various contexts
- Built on NumPy, SciPy, and matplotlib
- Open source, commercially usable - BSD license

Classification

Identifying to which category an object belongs to.

Applications: Spam detection, Image recognition.
Algorithms: SVM, nearest neighbors, random forest, ... — Examples

Regression

Predicting a continuous-valued attribute associated with an object.

Applications: Drug response, Stock prices.
Algorithms: SVR, ridge regression, Lasso, ... — Examples

Clustering

Automatic grouping of similar objects into sets.

Applications: Customer segmentation, Grouping experiment outcomes
Algorithms: k-Means, spectral clustering, mean-shift, ... — Examples

Dimensionality reduction

Reducing the number of random variables to consider.

Applications: Visualization, Increased efficiency
Algorithms: PCA, feature selection, non-negative matrix factorization. — Examples

Model selection

Comparing, validating and choosing parameters and models.

Goal: Improved accuracy via parameter tuning
Modules: grid search, cross validation, metrics. — Examples

Preprocessing

Feature extraction and normalization.

Application: Transforming input data such as text for use with machine learning algorithms.
Modules: preprocessing, feature extraction. — Examples

http://scikit-learn.org/stable/

膨大すぎる・・・

- Examplesのページが秀逸
- 目的別にサンプルコードとその出力が並んでいる
- 入門するならここからを選んでみました

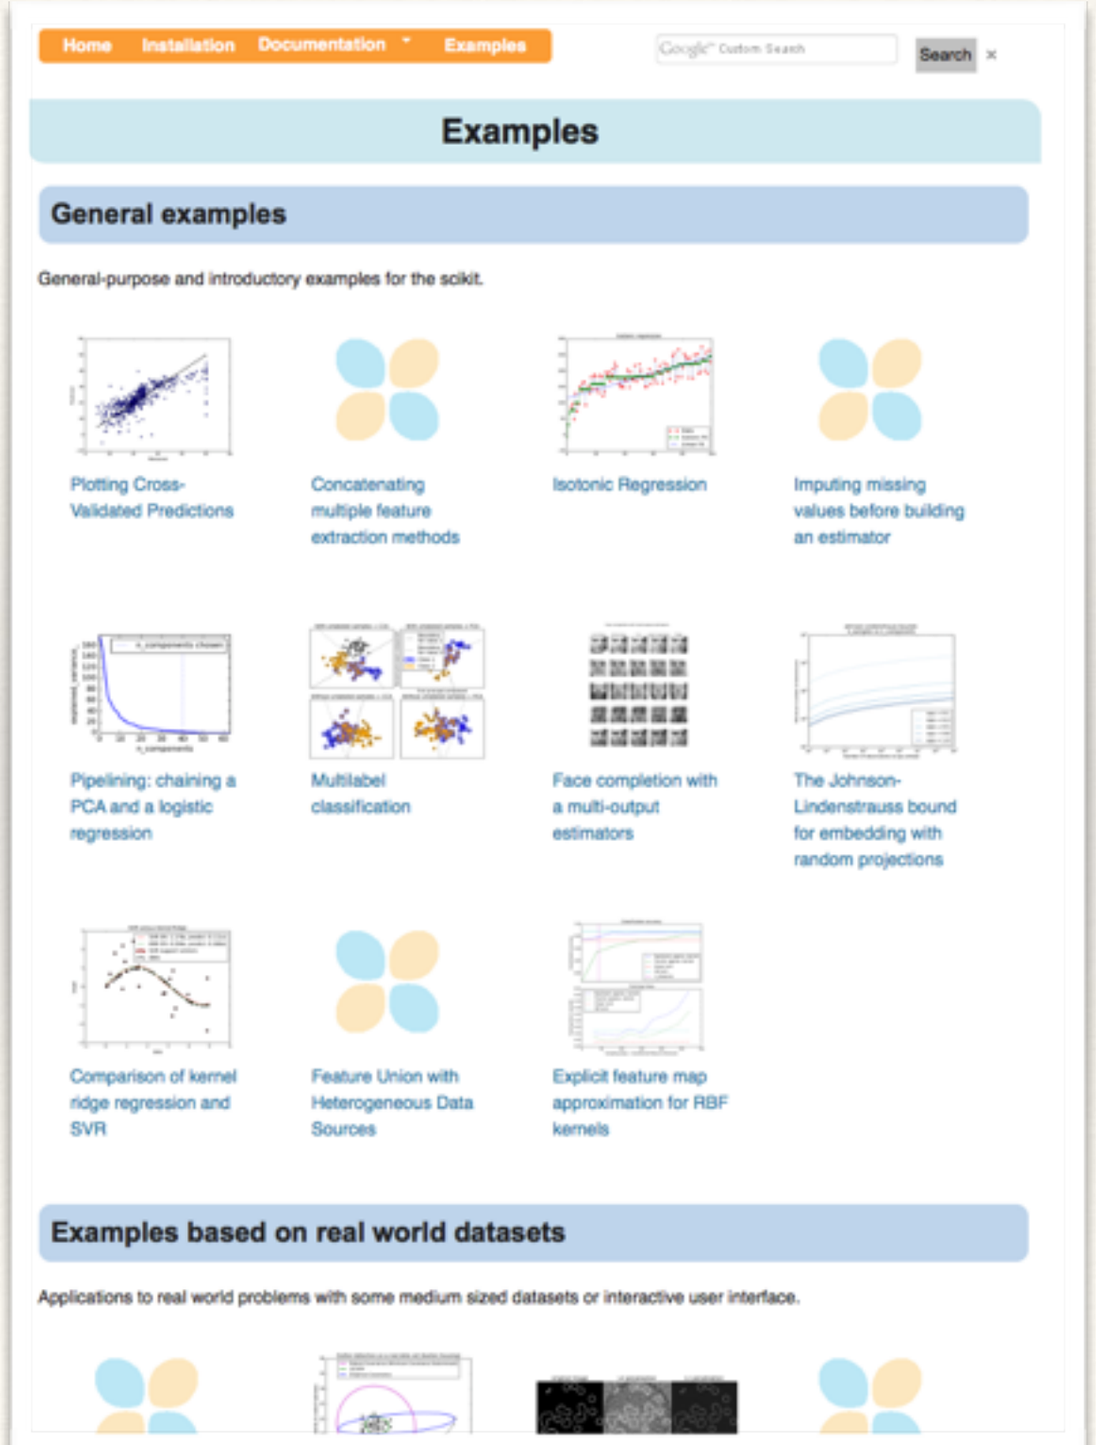

よく使われるデータセット

The Digit Dataset

- 手書きの数字データ
- 扱いやすいように8x8のグレースケールになっている
- http://scikit-learn.org/stable/auto_examples/datasets/plot_digits_last_image.html

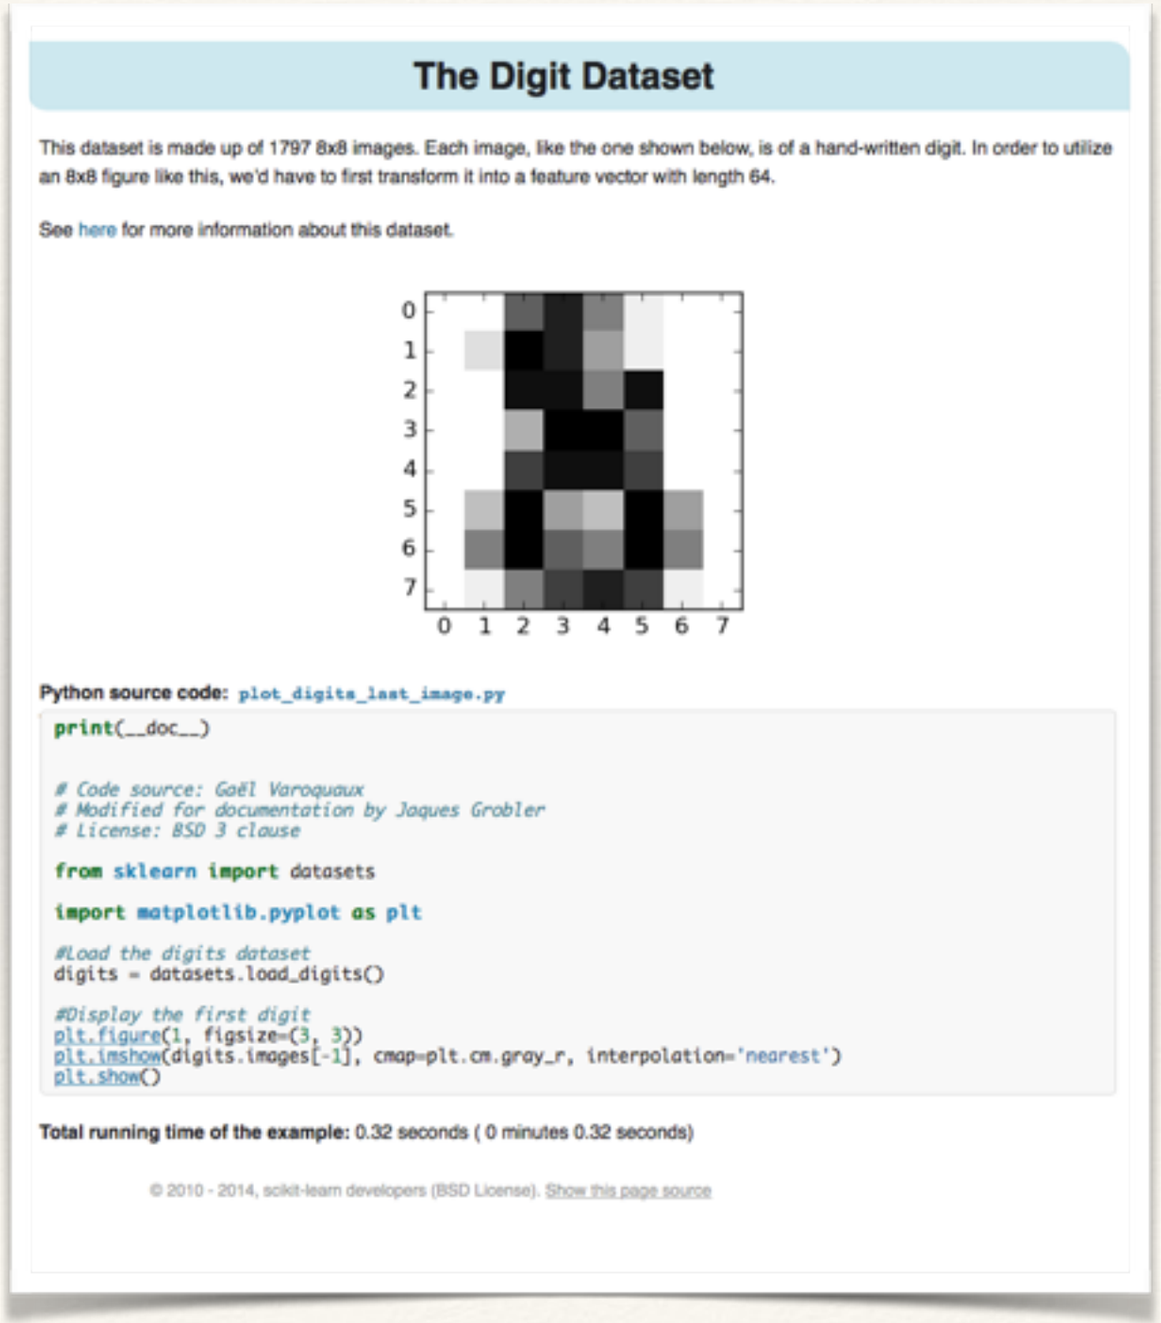

The Digit Dataset

This dataset is made up of 1797 8x8 images. Each image, like the one shown below, is of a hand-written digit. In order to utilize an 8x8 figure like this, we'd have to first transform it into a feature vector with length 64.

See here for more information about this dataset.

Python source code: plot_digits_last_image.py

```
print(__doc__)


# Code source: Gaël Varoquaux
# Modified for documentation by Jaques Grobler
# License: BSD 3 clause

from sklearn import datasets

import matplotlib.pyplot as plt

#Load the digits dataset
digits = datasets.load_digits()

#Display the first digit
plt.figure(1, figsize=(3, 3))
plt.imshow(digits.images[-1], cmap=plt.cm.gray_r, interpolation='nearest')
plt.show()
```

Total running time of the example: 0.32 seconds (0 minutes 0.32 seconds)

The Iris Dataset

- アヤメの花に関するデータ
- 3種類x50サンプル
  - 説明変数は4つ
- wikipedia（英語）の記事が詳しいです
- http://scikit-learn.org/stable/auto_examples/datasets/plot_iris_dataset.html#example-datasets-plot-iris-dataset-py

I. setosa

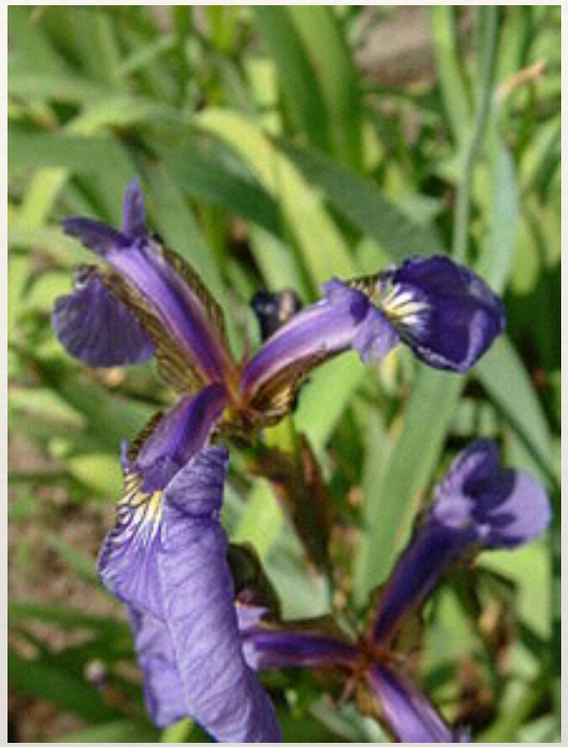

versicolor

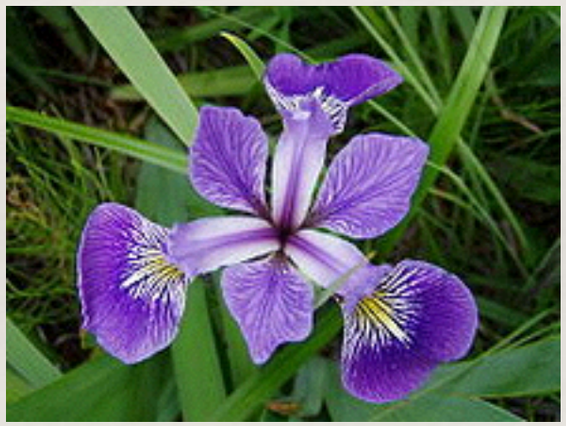

virginica

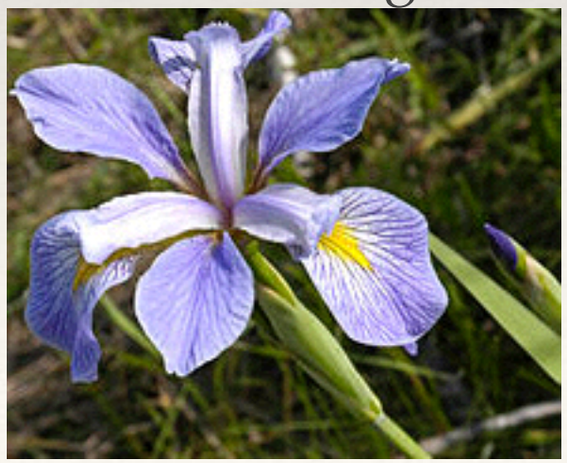

サンプルの全体像を把握する

PCA example with Iris Data-set

- Principal Component Analysis(PCA、主成分分析)
- 多数の説明変数を縮約し、データセットの全体像を把握するのに便利

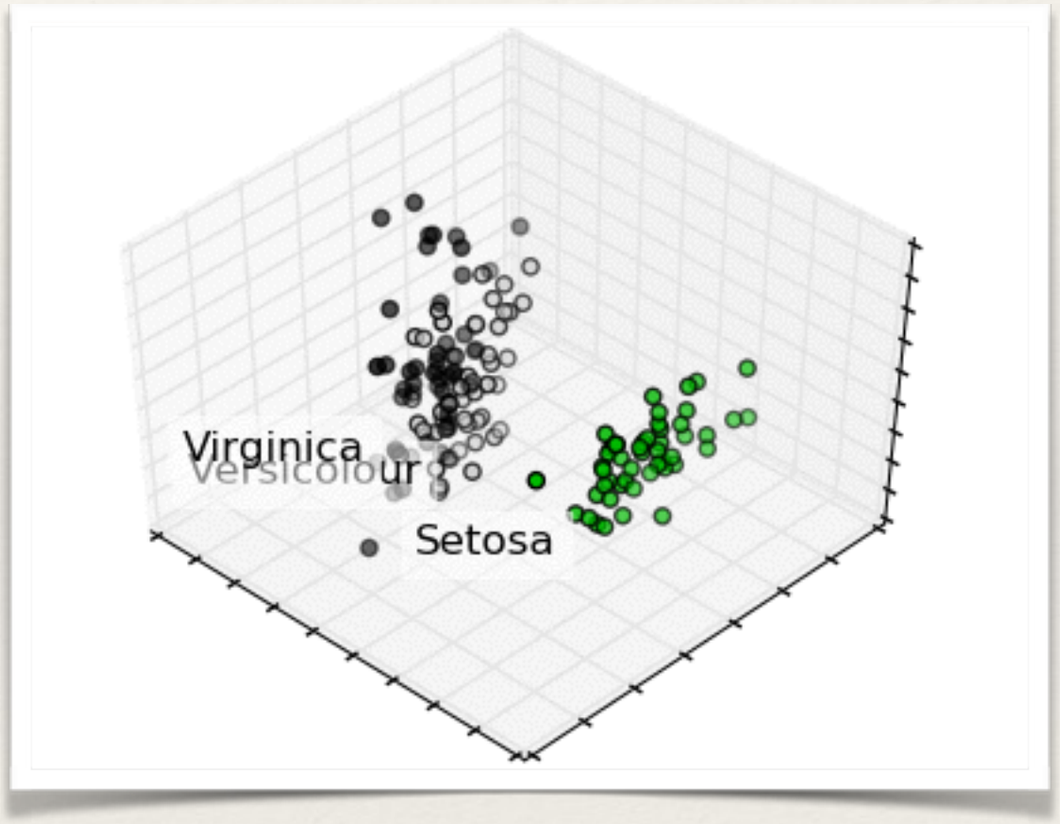

- http://scikit-learn.org/stable/auto_examples/decomposition/plot_pca_iris.html

教師無しでクラスタリング

K-means clustering

- 単純なアルゴリズムながら、
  よく使われている方法の1つ
- アルゴリズムのパラメータについて学習できる

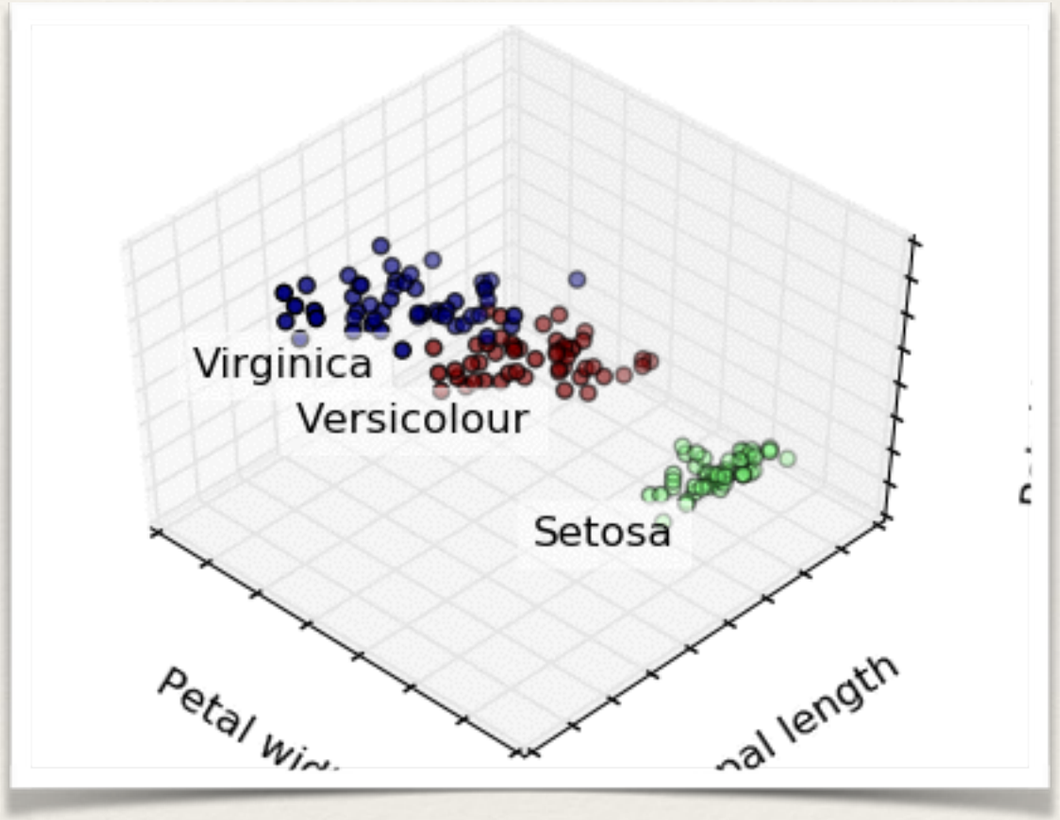

- http://scikit-learn.org/stable/auto_examples/cluster/plot_cluster_iris.html#example-cluster-plot-cluster-iris-py

Comparing different clustering algorithms on toy datasets

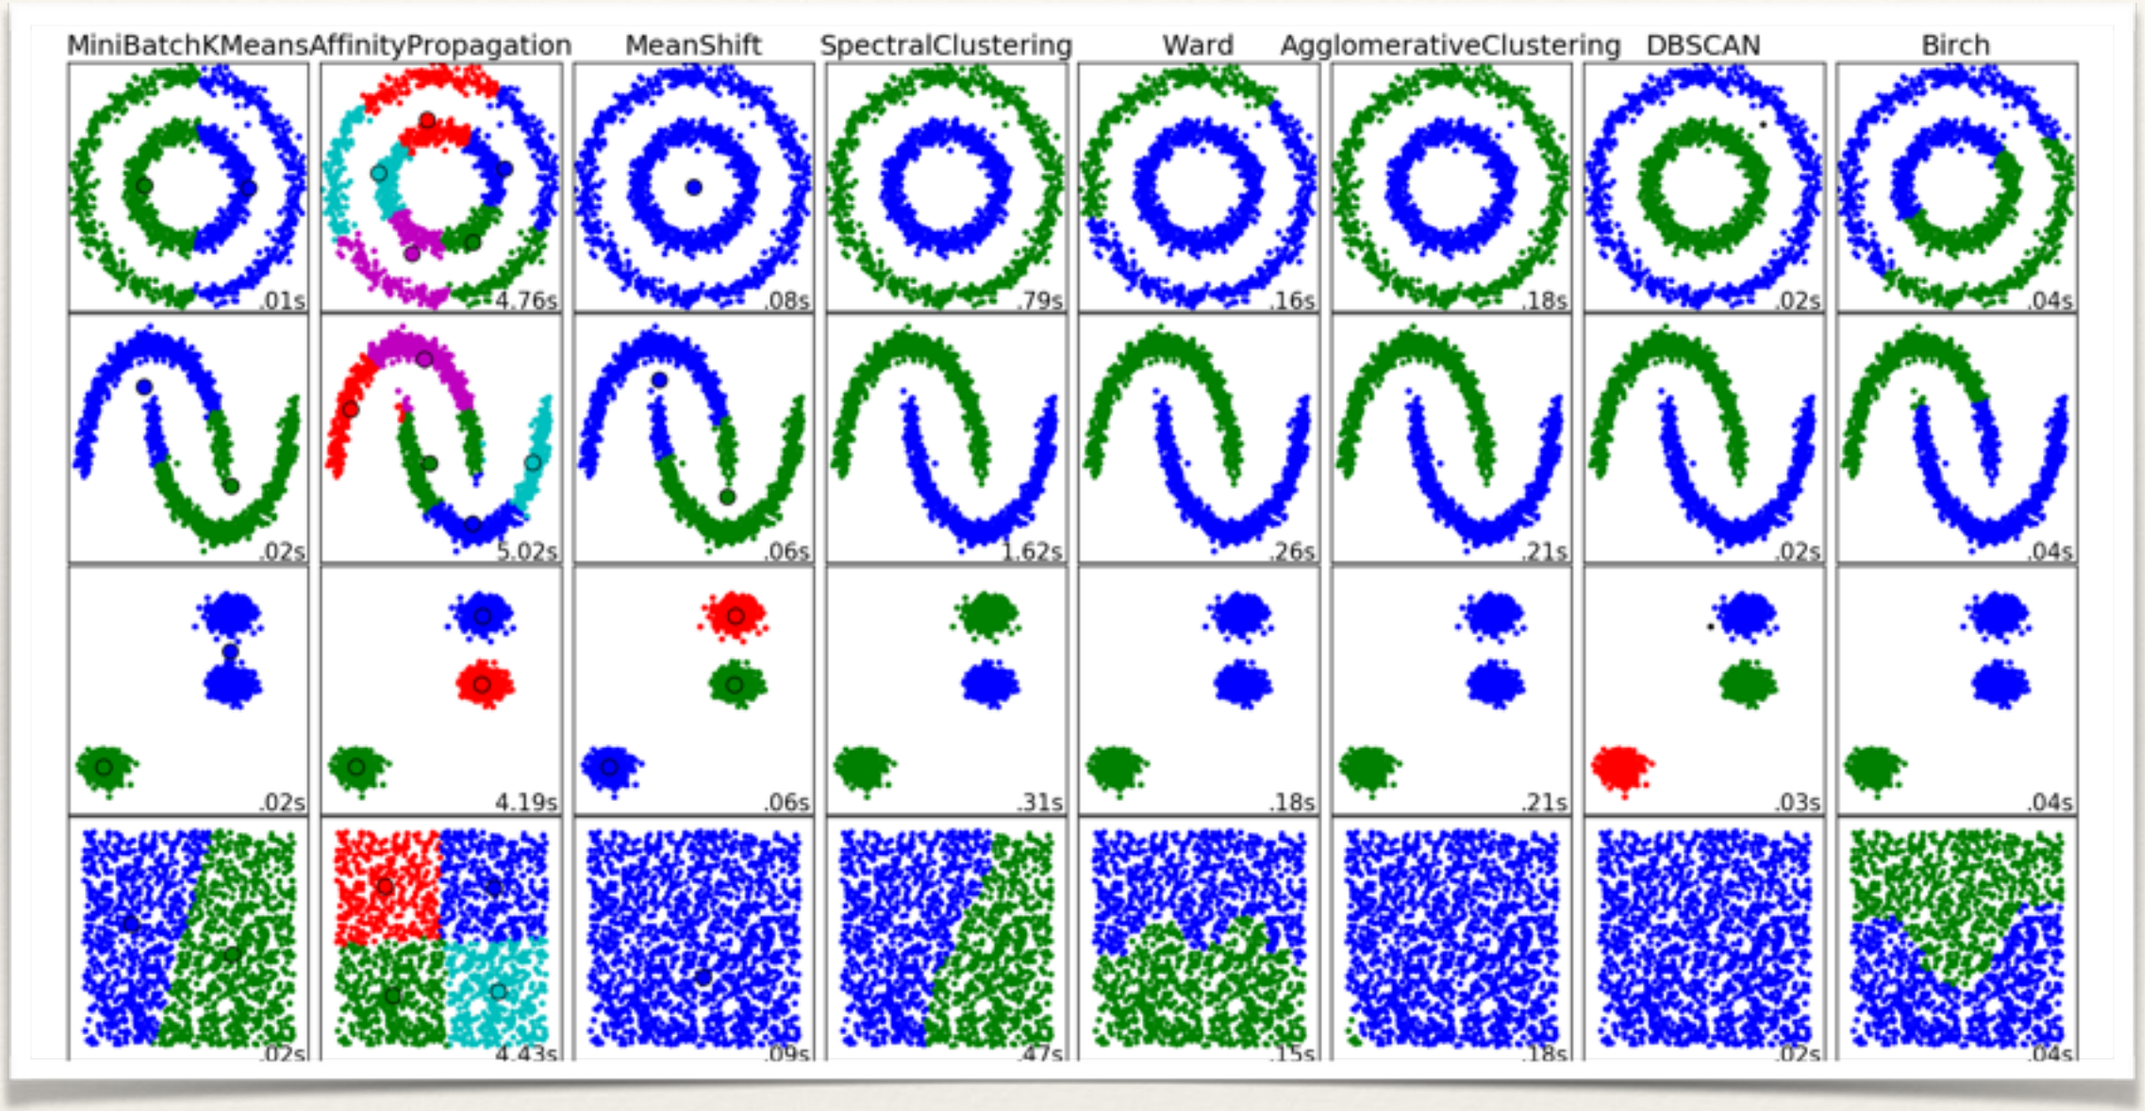

クラスタリングのアルゴリズムって沢山あるなーというのが分かる

http://scikit-learn.org/stable/auto_examples/cluster/plot_cluster_comparison.html

教師有り学習

予測モデルを作りたい

Digits Classification Exercise

- k-近傍法とロジスティック回帰を使ったモデルの作成と予測
- 珍しくシンプルなコードなので、理解しやすい

- http://scikit-learn.org/stable/auto_examples/exercises/digits_classification_exercise.html#example-exercises-digits-classification-exercise-py

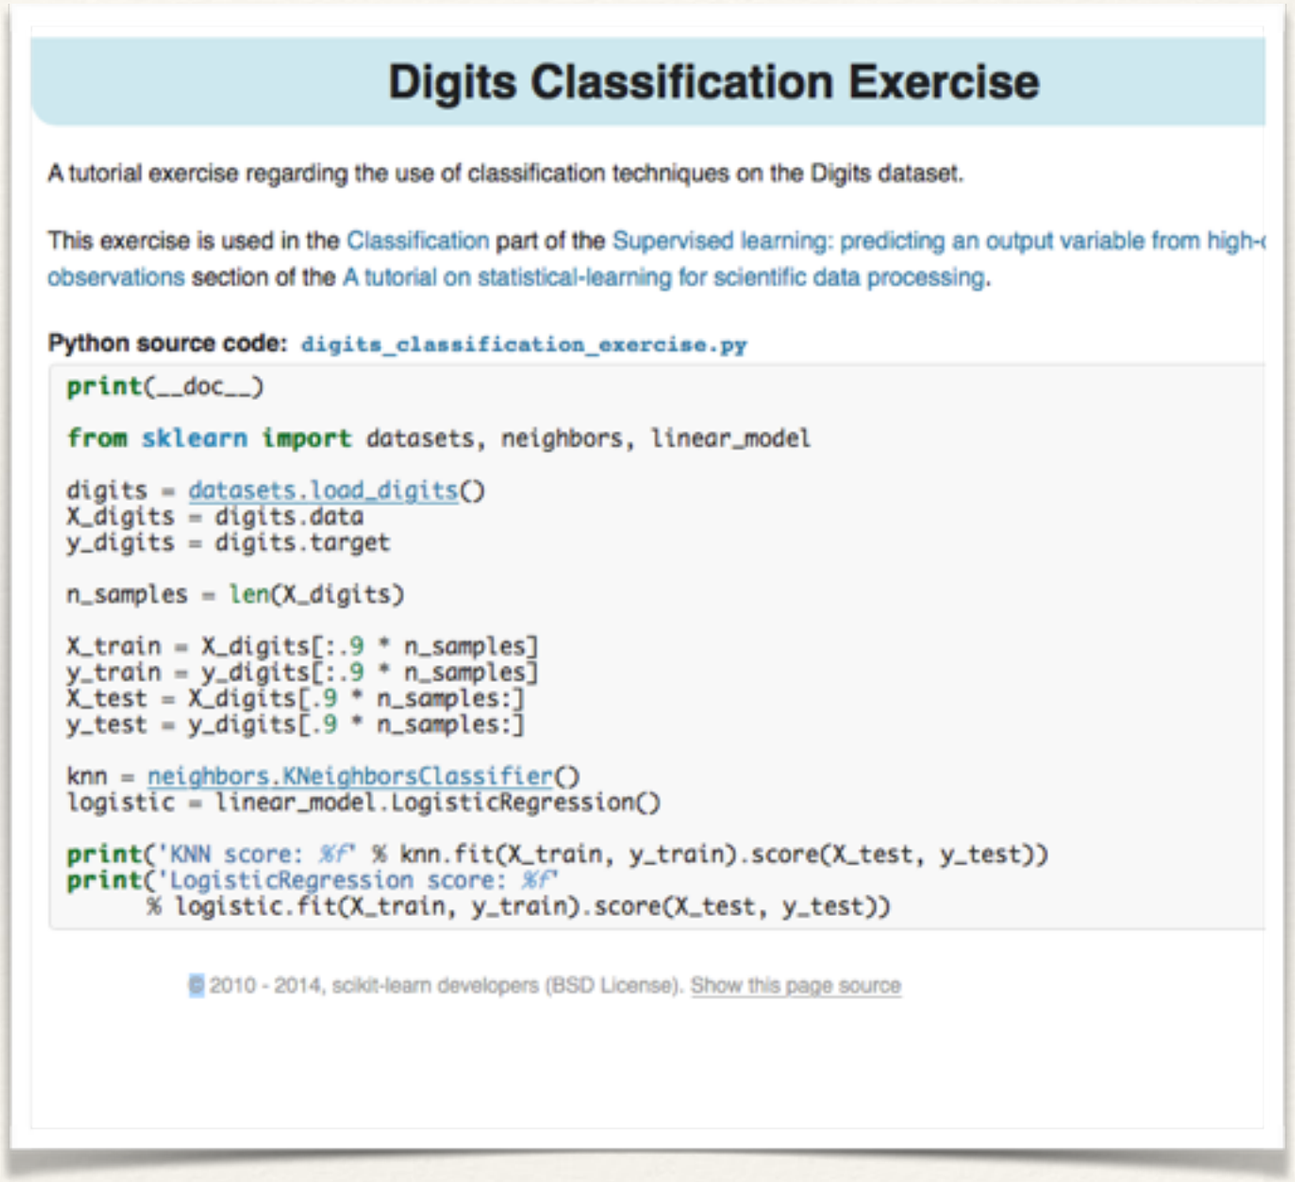

Digits Classification Exercise

A tutorial exercise regarding the use of classification techniques on the Digits dataset.

This exercise is used in the Classification part of the Supervised learning: predicting an output variable from high-d observations section of the A tutorial on statistical-learning for scientific data processing.

Python source code: `digits_classification_exercise.py`

```
print(__doc__)

from sklearn import datasets, neighbors, linear_model

digits = datasets.load_digits()
X_digits = digits.data
y_digits = digits.target

n_samples = len(X_digits)

X_train = X_digits[:.9 * n_samples]
y_train = y_digits[:.9 * n_samples]
X_test = X_digits[.9 * n_samples:]
y_test = y_digits[.9 * n_samples:]

knn = neighbors.KNeighborsClassifier()
logistic = linear_model.LogisticRegression()

print('KNN score: %f' % knn.fit(X_train, y_train).score(X_test, y_test))
print('LogisticRegression score: %f'
      % logistic.fit(X_train, y_train).score(X_test, y_test))
```

SVM exercise

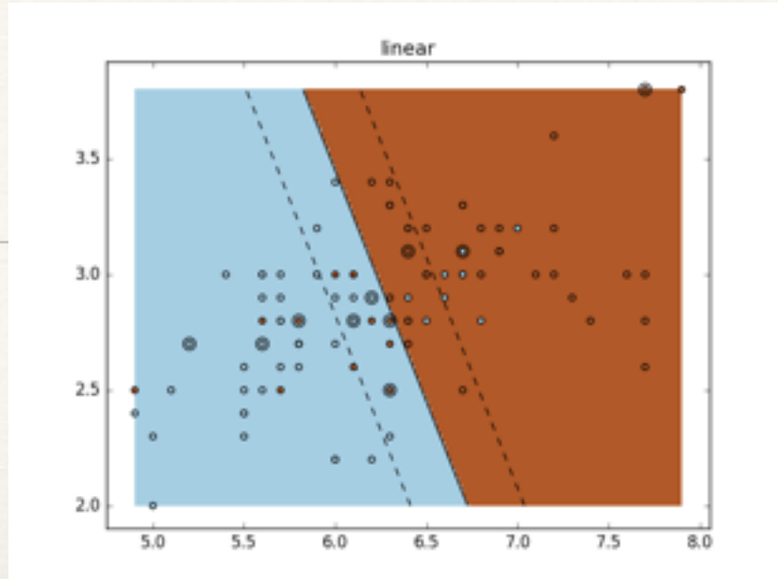

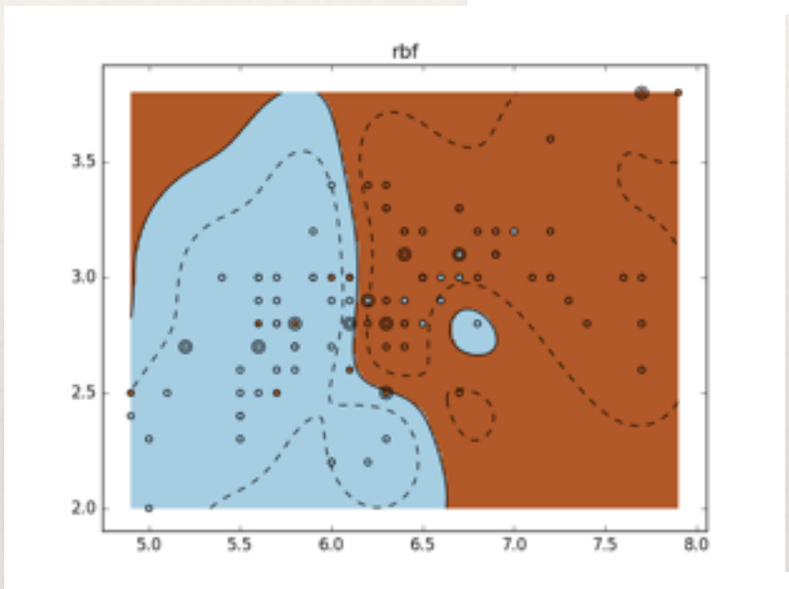

- Support Vector Machine(SVM)
- カーネルによる分離面の違いがわかるプロット付き

- http://scikit-learn.org/stable/auto_examples/exercises/plot_iris_exercise.html

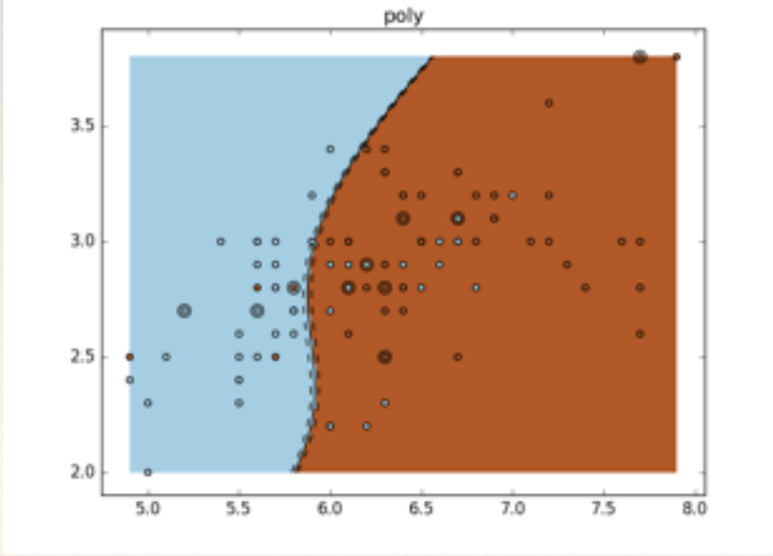

まとめ

- scikit-learnのExampleから入門によさそうなものを紹介
- その他、さまざまなアルゴリズムが揃っている
- ドキュメントも豊富
  - 加藤先生が読み方伝授してくれるはず
- アルゴリズムの数学的な背景は別
- 使うだけなら、慣れれば結構簡単