

O'REILLY®  
オライリー・ジャパン



# Pythonではじめる 機械学習

scikit-learnで学ぶ特徴量エンジニアリングと機械学習の基礎

Andreas C. Müller  
Sarah Guido  
著  
中田 秀基 訳

# 目次

|            |   |
|------------|---|
| まえがき ..... | v |
|------------|---|

|                                   |          |
|-----------------------------------|----------|
| <b>1章 はじめに .....</b>              | <b>1</b> |
| 1.1 なぜ機械学習なのか? .....              | 1        |
| 1.1.1 機械学習で解決可能な問題 .....          | 2        |
| 1.1.2 タスクを知り、データを知る .....         | 4        |
| 1.2 なぜPythonなのか? .....            | 5        |
| 1.3 scikit-learn .....            | 5        |
| 1.3.1 scikit-learnのインストール .....   | 6        |
| 1.4 必要なライブラリとツール .....            | 7        |
| 1.4.1 Jupyter Notebook .....      | 7        |
| 1.4.2 NumPy .....                 | 7        |
| 1.4.3 SciPy .....                 | 8        |
| 1.4.4 matplotlib .....            | 9        |
| 1.4.5 pandas .....                | 10       |
| 1.4.6 mglearn .....               | 11       |
| 1.5 Python 2 vs. Python 3 .....   | 12       |
| 1.6 本書で用いているバージョン .....           | 12       |
| 1.7 最初のアプリケーション：アイリスのクラス分類 .....  | 13       |
| 1.7.1 データを読む .....                | 14       |
| 1.7.2 成功度合いの測定：訓練データとテストデータ ..... | 17       |
| 1.7.3 最初にすべきこと：データをよく観察する .....   | 19       |
| 1.7.4 最初のモデル：k-最近傍法 .....         | 20       |
| 1.7.5 予測を行う .....                 | 22       |

|                                      |            |
|--------------------------------------|------------|
| 1.7.6 モデルの評価 .....                   | 23         |
| 1.8 まとめと今後の展望 .....                  | 24         |
| <b>2章 教師あり学習 .....</b>               | <b>27</b>  |
| 2.1 クラス分類と回帰 .....                   | 27         |
| 2.2 汎化、過剰適合、適合不足 .....               | 28         |
| 2.2.1 モデルの複雑さとデータセットの大きさ .....       | 31         |
| 2.3 教師あり機械学習アルゴリズム .....             | 31         |
| 2.3.1 サンプルデータセット .....               | 31         |
| 2.3.2 k-最近傍法 .....                   | 36         |
| 2.3.3 線形モデル .....                    | 46         |
| 2.3.4 ナイーブベイズクラス分類器 .....            | 68         |
| 2.3.5 決定木 .....                      | 70         |
| 2.3.6 決定木のアンサンブル法 .....              | 82         |
| 2.3.7 カーネル法を用いたサポートベクタマシン .....      | 90         |
| 2.3.8 ニューラルネットワーク（ディープラーニング） .....   | 102        |
| 2.4 クラス分類器の不確実性推定 .....              | 115        |
| 2.4.1 決定関数 (Decision Function) ..... | 116        |
| 2.4.2 確率の予測 .....                    | 119        |
| 2.4.3 多クラス分類の不確実性 .....              | 122        |
| 2.5 まとめと展望 .....                     | 124        |
| <b>3章 教師なし学習と前処理 .....</b>           | <b>127</b> |
| 3.1 教師なし学習の種類 .....                  | 127        |
| 3.2 教師なし学習の難しさ .....                 | 128        |
| 3.3 前処理とスケール変換 .....                 | 128        |
| 3.3.1 さまざまな前処理 .....                 | 129        |
| 3.3.2 データ変換の適用 .....                 | 130        |
| 3.3.3 訓練データとテストデータを同じように変換する .....   | 132        |
| 3.3.4 教師あり学習における前処理の効果 .....         | 135        |
| 3.4 次元削減、特徴量抽出、多様体学習 .....           | 137        |
| 3.4.1 主成分分析 (PCA) .....              | 137        |
| 3.4.2 非負値行列因子分解 (NMF) .....          | 152        |
| 3.4.3 t-SNE を用いた多様体学習 .....          | 159        |
| 3.5 クラスタリング .....                    | 164        |
| 3.5.1 k-means クラスタリング .....          | 164        |
| 3.5.2 凝集型クラスタリング .....               | 177        |

|                                    |            |
|------------------------------------|------------|
| 3.5.3 DBSCAN.....                  | 182        |
| 3.5.4 クラスタリングアルゴリズムの比較と評価.....     | 186        |
| 3.5.5 クラスタリング手法のまとめ.....           | 202        |
| 3.6 まとめと展望.....                    | 203        |
| <b>4章 データの表現と特徴量エンジニアリング .....</b> | <b>205</b> |
| 4.1 カテゴリ変数.....                    | 206        |
| 4.1.1 ワンホットエンコーディング(ダミー変数).....    | 207        |
| 4.1.2 数値でエンコードされているカテゴリ.....       | 211        |
| 4.2 ビニング、離散化、線形モデル、決定木.....        | 213        |
| 4.3 交互作用と多項式.....                  | 217        |
| 4.4 単変量非線形変換.....                  | 225        |
| 4.5 自動特徴量選択.....                   | 229        |
| 4.5.1 単変量統計.....                   | 229        |
| 4.5.2 モデルベース特徴量選択.....             | 232        |
| 4.5.3 反復特徴量選択.....                 | 234        |
| 4.6 専門家知識の利用.....                  | 235        |
| 4.7 まとめと展望.....                    | 244        |
| <b>5章 モデルの評価と改良 .....</b>          | <b>245</b> |
| 5.1 交差検証.....                      | 246        |
| 5.1.1 scikit-learnでの交差検証.....      | 247        |
| 5.1.2 交差検証の利点.....                 | 248        |
| 5.1.3 層化k分割交差検証と他の戦略.....          | 248        |
| 5.2 グリッドサーチ.....                   | 254        |
| 5.2.1 単純なグリッドサーチ.....              | 255        |
| 5.2.2 パラメータの過剰適合の危険性と検証セット.....    | 256        |
| 5.2.3 交差検証を用いたグリッドサーチ.....         | 258        |
| 5.3 評価基準とスコア .....                 | 270        |
| 5.3.1 最終的な目標を見失わないこと .....         | 270        |
| 5.3.2 2クラス分類における基準 .....           | 271        |
| 5.3.3 多クラス分類の基準 .....              | 292        |
| 5.3.4 回帰の基準 .....                  | 295        |
| 5.3.5 評価基準を用いたモデル選択 .....          | 295        |
| 5.4 まとめと展望 .....                   | 298        |

---

|   |            |
|---|------------|
| <b>6章 アルゴリズムチェーンとパイプライン</b>                       | <b>299</b> |
| 6.1 前処理を行う際のパラメータ選択                               | 300        |
| 6.2 パイプラインの構築                                     | 302        |
| 6.3 パイプラインを用いたグリッドサーチ                             | 303        |
| 6.4 汎用パイプラインインターフェイス                              | 306        |
| 6.4.1 <code>make_pipeline</code> による簡便なパイプライン生成   | 308        |
| 6.4.2 ステップ属性へのアクセス                                | 309        |
| 6.4.3 <code>GridSearchCV</code> 内のパイプラインの属性へのアクセス | 309        |
| 6.5 前処理ステップとモデルパラメータに対するグリッドサーチ                   | 311        |
| 6.6 グリッドサーチによるモデルの選択                              | 314        |
| 6.7 まとめと展望  | 315        |
| <b>7章 テキストデータの処理</b>                              | <b>317</b> |
| 7.1 文字列として表現されているデータのタイプ                          | 317        |
| 7.2 例題アプリケーション：映画レビューのセンチメント分析                    | 319        |
| 7.3 Bag of Wordsによるテキスト表現                         | 322        |
| 7.3.1 トイデータセットに対するBoW                             | 323        |
| 7.3.2 映画レビューのBoW                                  | 324        |
| 7.4 ストップワード                                       | 329        |
| 7.5 tf-idfを用いたデータのスケール変換                          | 330        |
| 7.6 モデル係数の調査                                      | 333        |
| 7.7 1単語よりも大きい単位のBag-of-Words (n-グラム)              | 334        |
| 7.8 より進んだトーカン分割、語幹処理、見出し語化                        | 339        |
| 7.9 トピックモデリングと文書クラスタリング                           | 343        |
| 7.9.1 LDA (Latent Dirichlet Allocation)           | 343        |
| 7.10 まとめと展望                                       | 351        |
| <b>8章 おわりに</b>                                    | <b>353</b> |
| 8.1 機械学習問題へのアプローチ                                 | 353        |
| 8.1.1 人間をループに組み込む                                 | 354        |
| 8.2 プロトタイプから運用システムへ                               | 354        |
| 8.3 運用システムのテスト                                    | 355        |
| 8.4 独自Estimatorの構築                                | 356        |
| 8.5 ここからどこへ行くのか                                   | 357        |
| 8.5.1 理論  | 357        |
| 8.5.2 他の機械学習フレームワークとパッケージ                         | 357        |
| 8.5.3 ランキング、推薦システム、その他の学習                         | 358        |

---

|                                |     |
|--------------------------------|-----|
| 8.5.4 確率モデル、推論、確率プログラミング ..... | 359 |
| 8.5.5 ニューラルネットワーク .....        | 359 |
| 8.5.6 大規模データセットへのスケール .....    | 360 |
| 8.5.7 名誉を得る .....              | 361 |
| 8.6 結論 .....                   | 361 |
| 索引 .....                       | 363 |