# データサイエンスのための リーダブルコードのススメ


**20th February 2021, Python Charity Talks in Japan 2021.02**
**Yuta Kanzawa @yutakanzawa**

**Data Scientist at Janssen Pharmaceutical K.K., Tokyo**
**A Family Company of Johnson & Johnson**

# 神沢雄大 Yuta Kanzawa

- データサイエンティスト@ヤンセンファーマ
  - 製薬部門**@ジョンソン・エンド・ジョンソン**
- Twitter: @yutakanzawa
- 好きなもの：オペラとワイン
  - ワーグナー
  - ブルゴーニュ (WSET Lv 2→3)
- 使用可能言語：7
  - 人間：日本語、英語、ドイツ語
  - コンピューター：R, Python, SAS, SQL

# 謝辞

本トークは、本日に先立ち、以下のイベントにて発表する機会を戴きました。

採択、お声掛け戴いた運営の方々並びに各イベントにご参加戴いた皆様、ありがとうございました。

- **PyCon mini Hiroshima 2020**
  - 2020年10月10日
- **みんなのPython勉強会**
  - 2021年1月13日

# アジェンダ

- 今日話すこと
  - エンジニアにとってはベタな話（でも一部はショッキングかも）
  - ポエム

- 今日話さないこと
  - エンジニアにとっては目から鱗な話
  - コードそのもの

# おことわり

- 「データサイエンス」、「データサイエンティスト」という主語の大きな話をしますが、原則としてスピーカーの実体験に基づいたものです。

- 事例を一般化するように努めていますが、全てのデータサイエンティストが当てはまる訳ではありません。コードを書くという点で、模範となるデータサイエンティストも数多く存在します。

- 開発環境やエディタ、IDEについては割愛します（個人的なベストプラクティスがまだない）。

# TL;DR

- 読みにくいor保守性が低いコード ＝ 自分やチームの足枷

- しかし、データサイエンティストにとってコードは手段。
  - 「動けばOK」という文化はなくならない。

- データサイエンティストがエンジニアを見習うべきポイント：
  - 処理の内容や機能に応じて、フォルダやコードを分割。
  - コメント付け、リファクタリングの実施、フォーマッターの使用。
  - チームと協力して習慣づける。
    - レヴューし合う。

# なぜデータサイエンティストも読みやすくて保守性が高いコードを書く必要があるのか。

## Why readable codes also for data science?

# いきなりですが、質問！

- 今日の朝食のメニューは？
- 今の服の色は？
- 今夜の懇親会の飲み物は？

# 落とし穴ワーストスリー

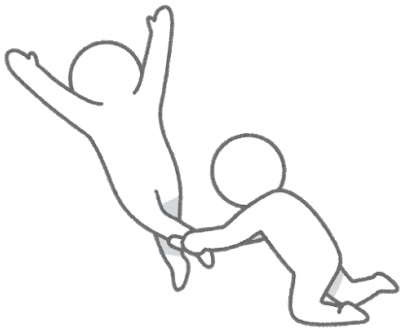

- **未来の自分は他人**（だと思った方がいい）。
  - コードやドキュメントに書いていないことは覚えていない。
  - 過去（今）の自分が足を引っ張る可能性大。
- 来年も**自分が作業するとは限らない。**
  - 異動、昇進→後任からの質問対応→結果的に属人化

- **他人の書いたコードを「解読」**しないといけないこともある。
  - 不十分な引き継ぎ
  - **秘伝のタレ**
  - もういない→本人に聞けない。

# コーディングにおける エンジニアとの違い

## Differences in coding from engineers

# おことわり（再掲）

- 「データサイエンス」、「データサイエンティスト」という主語の大きな話をしますが、原則としてスピーカーの実体験に基づいたものです。

- 事例を一般化するように努めていますが、全てのデータサイエンティストが当てはまる訳ではありません。コードを書くという点で、模範となるデータサイエンティストも数多く存在します。

- 開発環境やエディタ、IDEについては割愛します（個人的なベストプラクティスがまだない）。

# データサイエンティストのアウトプット（最終成果物）

- データセット、数値
- グラフ
- モデル
- 考察

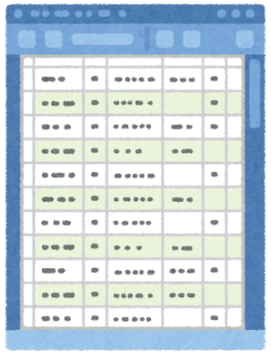
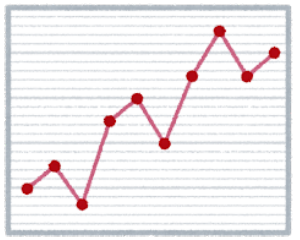
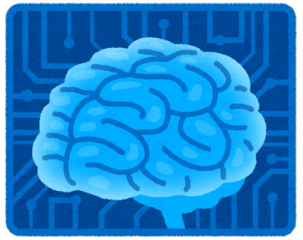


→ コードはアウトプットを作成する手段。

一度きりのコードを書く割合が高い。

（でも、一度きりのはずがそうでなくなることも…）

# データサイエンティストにとってのコードの位置付け

- **動くコード**が正義。
  - よく分からないけど期待通りの結果が出ている。
  - 動かすのが面倒だけど期待通りの結果が出ている。
  - キレイな書き方ではないけど期待通りの結果が出ている。

- 動くコードが完成したら、Mission completed!
  - テスト、なにそれ、おいしいの？
  - フォーマッター、なにそれ、おいしいの？
  - リファクタリング、なにそれ、おいしいの？

# データサイエンティストの作業形態

- 分析の恥は**書き捨て**。
  - 動くコードを目指して多数の試行錯誤。

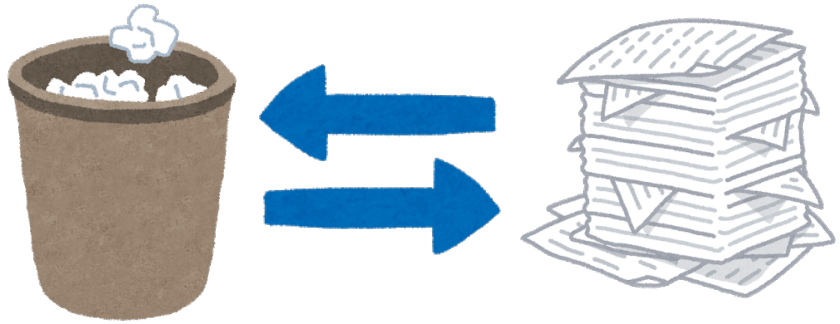

- 目的のためには**手段を選ばない**。
  - ネットからコピペしたコードのつぎはぎ
  - 複数のツールを経由する処理フロー
    - 例：
      Excelで加工してから、Pythonに投入、グラフを出力し、
      グラフの軸ラベルはPowerPointでテキストボックスを貼って調整。

# データサイエンティストが エンジニアを見習うべきポイント

## What data scientists should learn from engineers

# ファイルとフォルダの構成

- 一言でいうと「役割分担」
- Jupyter Notebookあるある
  - データ読込から結果出力まで1つのファイル。
  - コードと入力データ、出力データが同じフォルダ。
  - プロトタイプを試行錯誤して作るのには向いているけど…


- 入力と出力、コードとデータは別々に保管！ *1
- 処理の内容や大まかな機能に応じて、コードを分割！ *2,3

*1 https://socinuit.hatenablog.com/entry/2020/09/16/123811
*2 https://socinuit.hatenablog.com/entry/2020/10/03/173920
*3『リーダブルコード』第II、III部

# コメント

- 一言でいうと「メモ書き」
- 読みやすさの向上
  - ただし、自分では分かりやすいと思いがち。

- 例：
  - 変数、処理、関数の説明*1
  - 補足事項
  - 今後の課題の記述
    - 「TODO」

*1『リーダブルコード』5、6章参照

# リファクタリング

- 一言でいうと「コードの整理整頓」
- 保守性の向上
- 特に：
  - 変数名、関数名の見直し
    - 機能、内容に即したもの*1にする。
  - 処理の分割（既出）
  - 関数化
  - for文、リスト内包表記
  - 知識の継続的アップデートが役立つ。
    - e.g. f文字列、セイウチ演算子*2

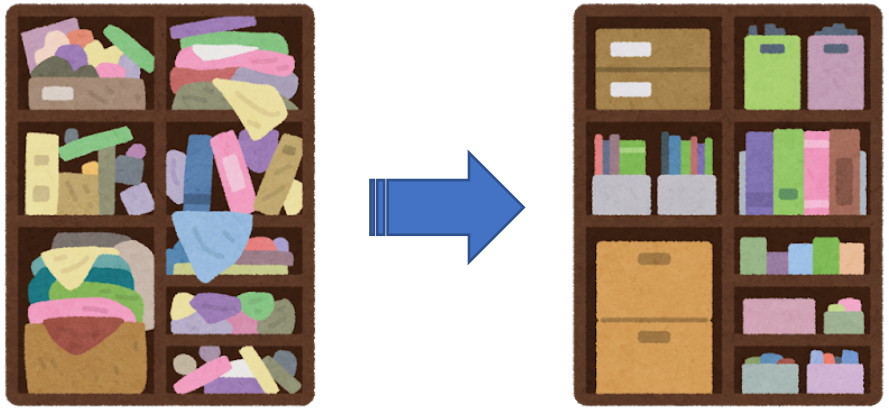

*1『リーダブルコード』2、3章参照
*2 https://atsuoishimoto.hatenablog.com/entry/2019/09/03/110508

# フォーマッターやリンターの使用*1

- フォーマッター
  - Black: PEP8*2準拠
    - 書式が整ったコードは読みやすい。→ デバッグや保守をしやすい。
    - Jupyter Notebookのエクステンション：Jupyter Black*3
      - Jupyter Notebook上でボタンorショートカットキー1つで実行可能。すごく便利！


- リンター（静的解析ツール）
  - flake8: 静的チェック（バグにつながりやすいコードをチェック）
  - mypy: 型ヒントチェック


*1 ここに挙げたツールの詳しくて分かりやすい説明 → PyCon JP 2019 ビギナーセッション『Pythonでの開発を効率的に進めるためのツール設定』https://www.slideshare.net/aodag/python-172432039
*2 Pythonのコーディング規約 https://www.python.org/dev/peps/pep-0008/
*3 https://github.com/drillan/jupyter-black

# 以上を身に付けるには。

- 漸進
  - 時間の取れる趣味のプロジェクトから始めてみる。
  - チームに提案して、コードの改善にかける時間を確保。
- 習慣付け
  - コメント付けは付箋を貼る感じで、最初は頻繁に。
  - 命名規則の導入（個人またはチームで）
  - コードを書いたら
    - Blackを実行。
    - リファクタリングしてみる。
- レヴューまたは鑑賞
  - 人に見てもらい、人のコードを見る。
    - チーム内、ブログ記事やGitHubのコード

# Next Steps: MLOpsを見据えて（模索中）

- データサイエンスチームのコード → プロダクション環境での運用
  - 直接の利害関係者が急拡大。
    - ユーザー、エンジニア（IT部門）、マネジメント層
  - →ちょっとしたバグが一大事に。

- 対策：再現性の確保*
  - コードのバージョン管理
  - ライブラリーのバージョン管理
  - 乱数のシード固定
  - テストの積極的導入 (CI/CD)

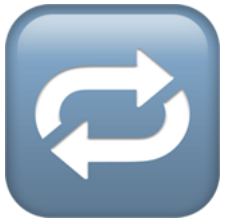

* Valliappa Lakshmanan, Sara Robinson, and Michael Munn. Machine Learning Design Patterns. Sebastopol: O'Reilly, 2020.

# まとめ

## Long story short

# Long story short

- 読みにくいor保守性が低いコード ＝ 自分やチームの足枷

- しかし、データサイエンティストにとってコードは手段。
  - 「動けばOK」という文化はなくならない。

- データサイエンティストがエンジニアを見習うべきポイント：
  - 処理の内容や機能に応じて、フォルダやコードを分割。
  - コメント付け、リファクタリングの実施、フォーマッターの使用。
  - チームと協力して習慣づける。
    - レヴューし合う。

# 参考

- 『Pythonでの開発を効率的に進めるためのツール設定』
  - Atsushi Odagiri, PyCon JP 2019 ビギナーセッション
    - https://www.slideshare.net/aodag/python-172432039
- 『データ分析をちゃんと管理しよう with R【フォルダ構成編】』
  - kinuit
    - https://socinuit.hatenablog.com/entry/2020/09/16/123811
- 『データ分析をちゃんと管理しよう【コーディング編】』
  - kinuit
    - https://socinuit.hatenablog.com/entry/2020/10/03/173920

# 参考（続き）

- 『リーダブルコード―より良いコードを書くためのシンプルで実践的なテクニック』
  - Dustin Boswell, Trevor Foucher, 角征典（訳）(2012)
    - https://www.oreilly.co.jp/books/9784873115658/

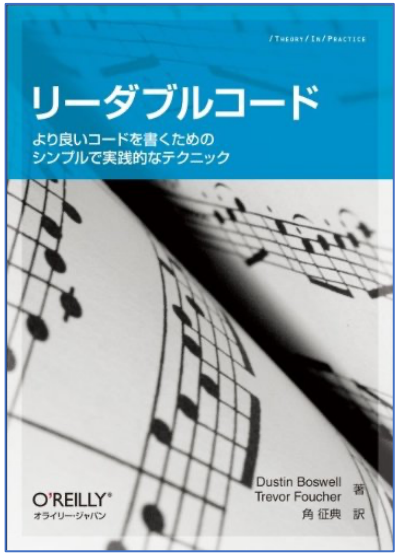


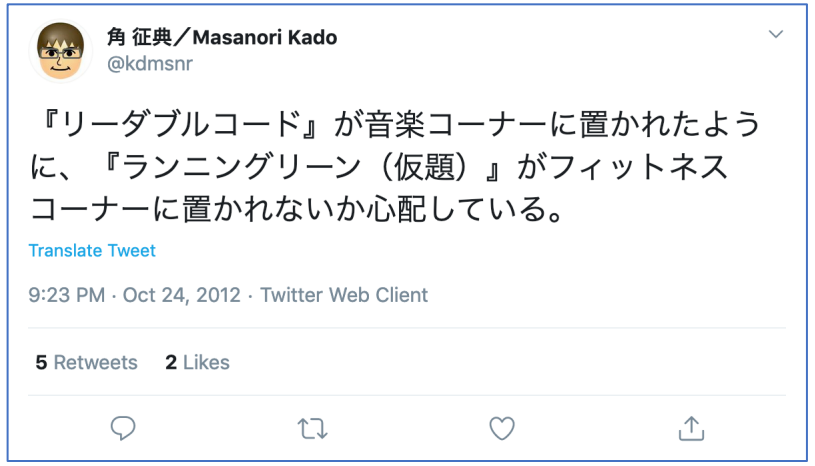


* https://twitter.com/kdmsnr/status/261080519792553984

# 参考（さらに）

- 『忙しい研究者のためのテストコードとドキュメントの書き方』
  - hmkz (2020)
    - https://qiita.com/hmkz/items/0689cd85fb3e1adcda1a

# 参考（さらにさらに）

- 'Machine Learning Design Patterns'
  - V. Lakshmanan, S. Robinson & M. Munn (2020)
    - https://www.oreilly.com/library/view/machine-learning-design/9781098115777/

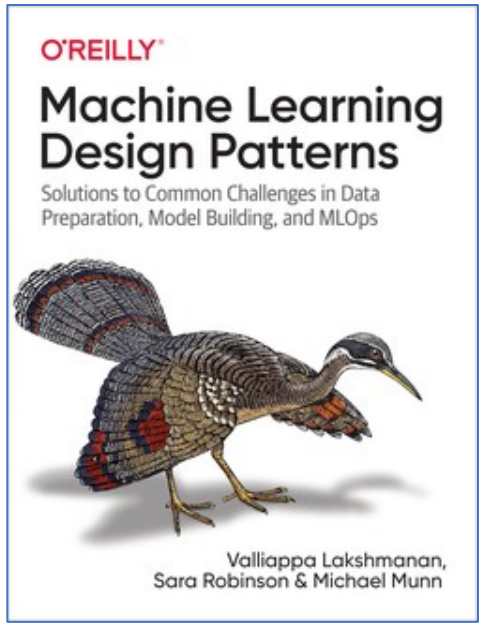

# Enjoy!