1-4　データ・AI利活用のための技術

東京大学 数理・情報教育研究センター

2020年5月11日

概要

- データサイエンスやAI利活用の現場ではどういう技術が用いられるのでしょうか？

- ここでは基本的なものを見ていくことで、データ・AIを活用するために使われている技術の概要を知ることを目標とします

本教材の目次

1-4-1　データの1次分析と可視化

データの1次分析

- 基礎統計量（平均値、最小値、最大値、分散など）、欠損値、偏りがないかなどを調べます
- データ可視化も1次分析に含まれます

データの確認

```
# show first 5 records -> seems ok
df.head()
```

	id	type	region	code	prefecture	city	town	nearest_station	nearest_station_min	price	...	future_usage	orientation	road_type	road_are
0	1	宅地(土地)	住宅地	1101	北海道	札幌市中央区	旭ケ丘	円山公園	28	86000000	...	その他	南	市道	10.2
1	2	宅地(土地)	住宅地	1101	北海道	札幌市中央区	旭ケ丘	円山公園	26	5000000	...	NaN	西	私道	4.0

欠損値の確認

```
In [5]: # ratio of null records
        df.isnull().sum() / len(df)

Out[5]: id                    0.000000
        type                  0.000000
        region                0.285000
        code                  0.000000
        prefecture            0.000000
        city                  0.000000
        town                  0.002065
        nearest_station       0.143826
        nearest_station_min   0.150569
        price                 0.000000
        unit_price            0.644265
        floor_plan            0.846775
        square_meters         0.000000
        unit_price_square     0.644265
        shape                 0.287836
        frontage              0.349677
        total_floor           0.663158
        year_built            0.521600
        structure             0.509749
        purpose               0.514253
        future_usage          0.722026
        orientation           0.288267
        road_type             0.304437
        road_area             0.311708
        city_plan             0.134972
        coverage              0.182164
        volume                0.182164
        transaction_date      0.000000
        renovation            0.855279
        circumstances         0.939687
        dtype: float64
```

基礎統計量

```
In [68]: # summary statistics
         df["price"].describe()

Out[68]: count    3.664002e+06
         mean     2.761324e+07
         std      1.432475e+08
         min      1.000000e+02
         25%      5.000000e+06
         50%      1.400000e+07
         75%      2.900000e+07
         max      6.100000e+10
         Name: price, dtype: float64
```

データ可視化

- 可視化の例を見ていきましょう

棒グラフ
(各国の人口)

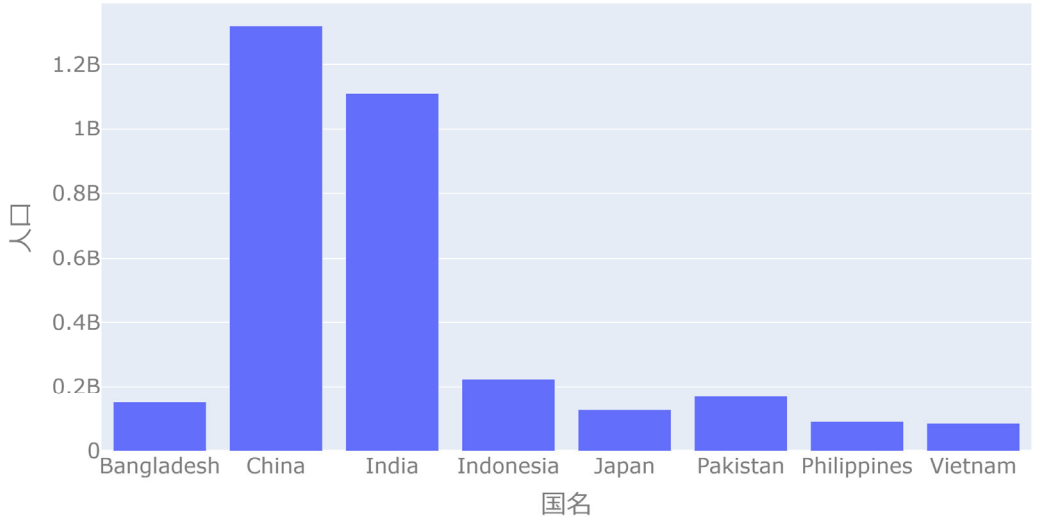

ヒストグラム
(米国のチップ)

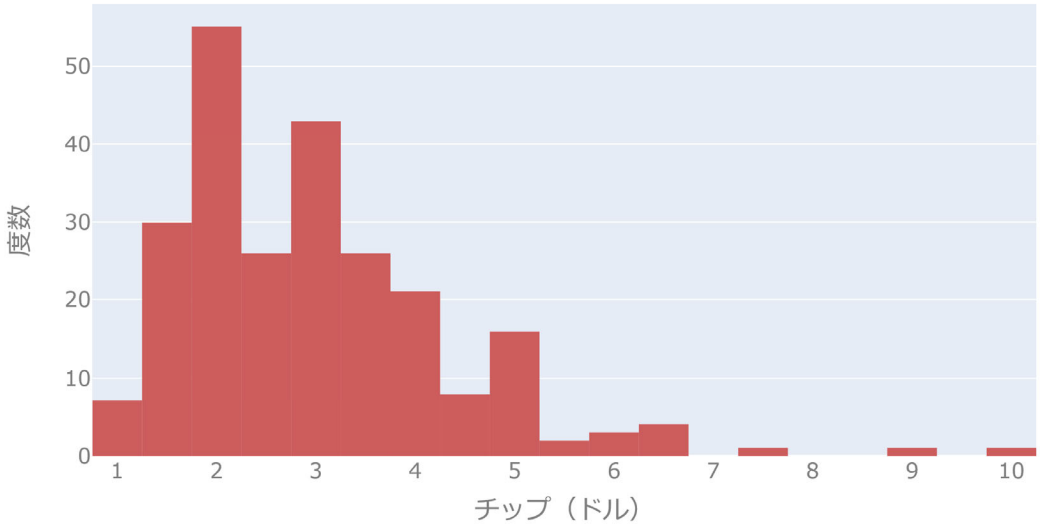

時系列

- 時間発展していくデータでは横軸を時間軸として扱います

アップル株の時系列

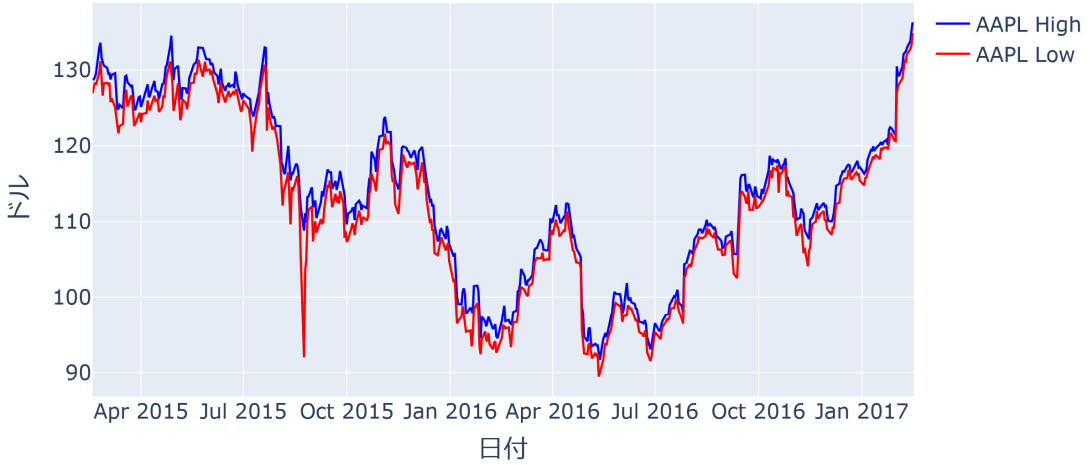

ビットコイン価格の時系列
➔右図のように複合チャートとして描画することもあります

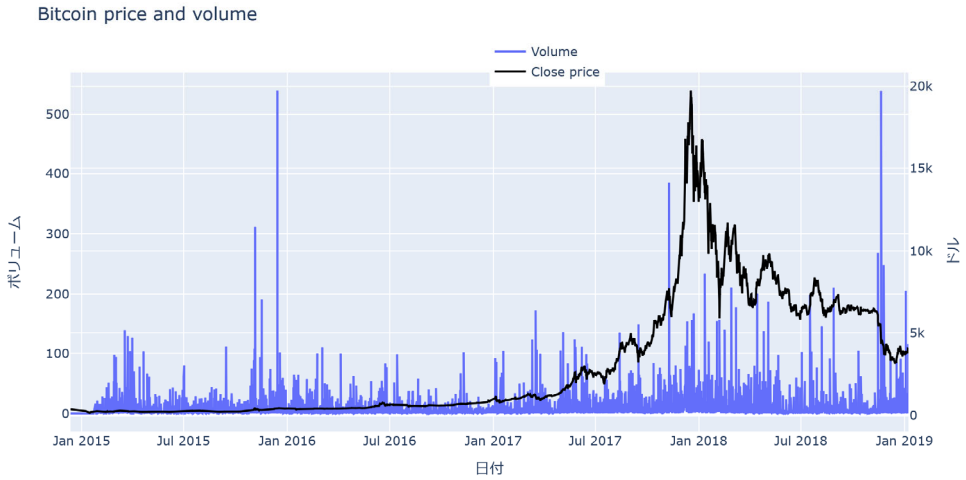

散布図と回帰

- 散布図は2つの変数の関係を確認するためによく使われます

- 散布図に沿うように直線や曲線を入れることもあります

  ➔左は線形回帰（直線で二変数の関係を表現）で右はスプライン回帰（滑らかな曲線で二変数の関係を表現）の例

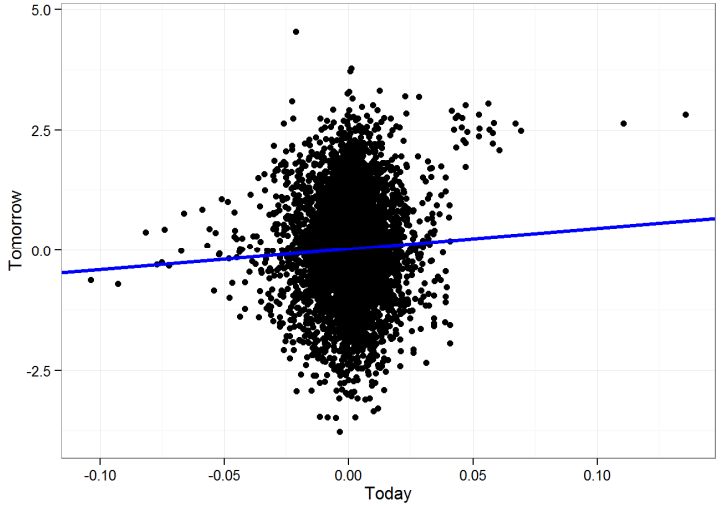

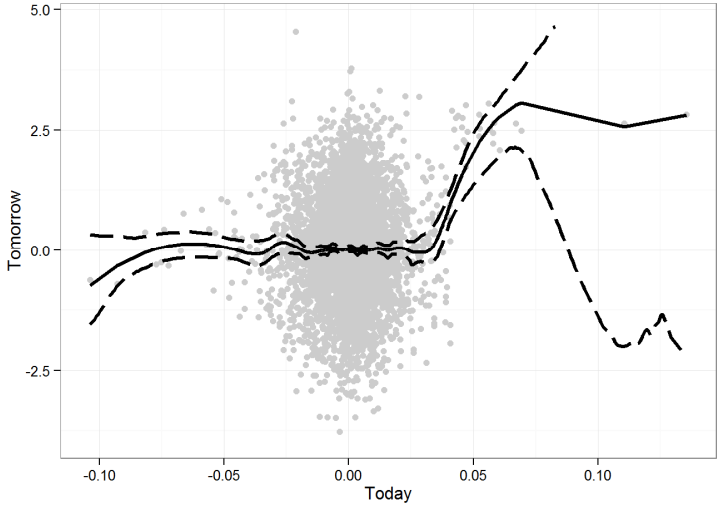

地図上の可視化・ダイナミック可視化

- 地図上に表示したり動的に可視化したりすることで初めて見えるものも多いです
- 左下の図によるとカリフォルニア州では海外沿いになるほど住宅価格が高いことがわかります
- もっと手の込んだ図やダイナミック可視化については右下のリンクを参照してください

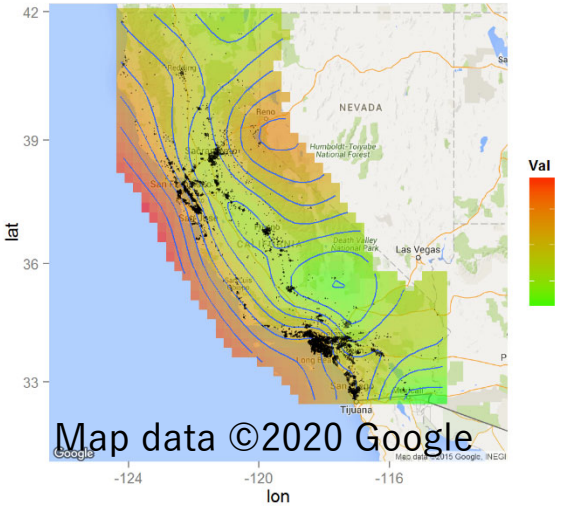

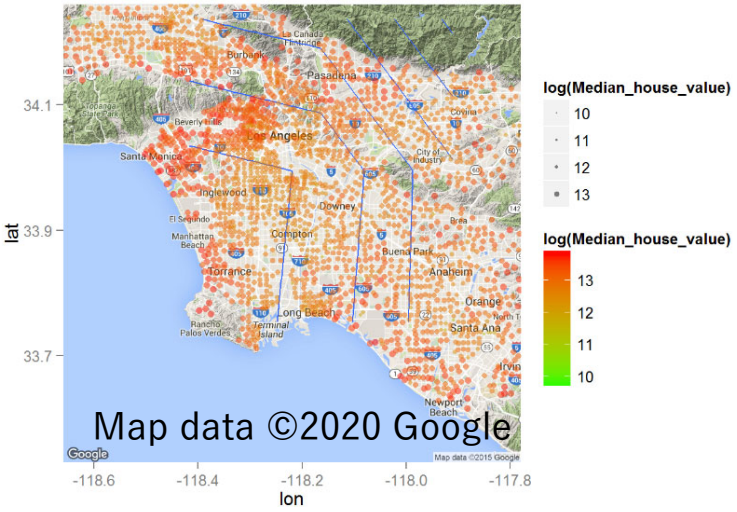

挙動・軌跡の可視化、ダイナミックな可視化、リアルタイム可視化の手の込んだ例については次を参照してください
https://eng.uber.com/keplergl/

関係性の可視化

- 関係性の可視化にはネットワークや行列が使用されます
  - 行列は4-1-5で詳しく説明します

- 下記はネットワーク図として上場企業同士の関係を描画したものです

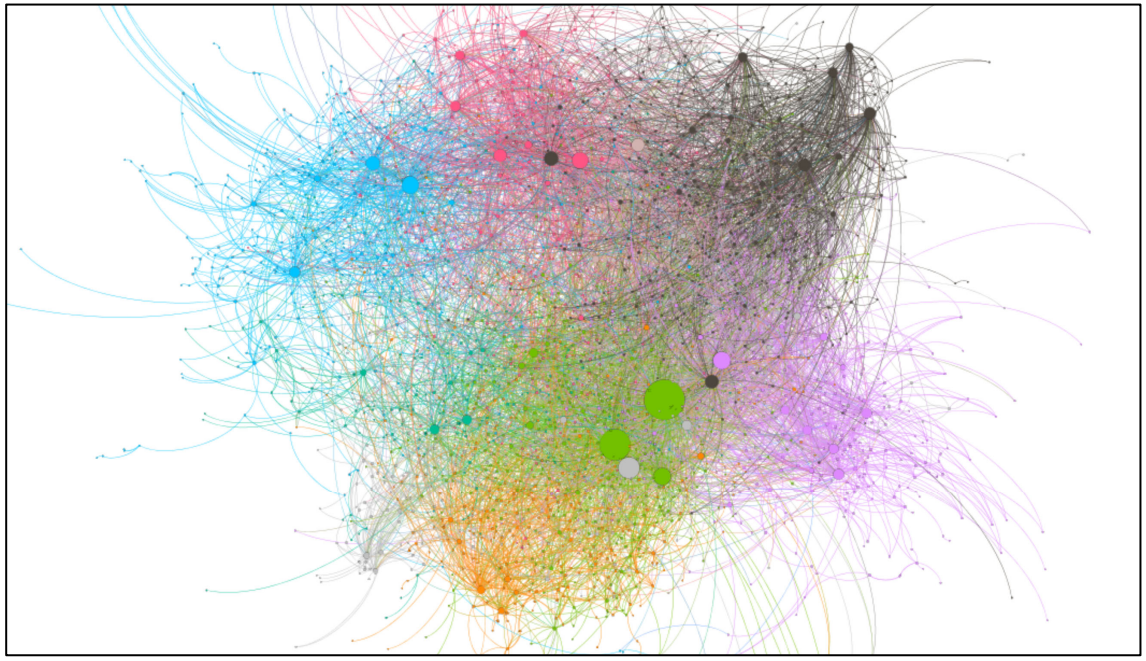

上場企業同士の関係

多次元の可視化

- 3次元の散布図を描くこともあります
  - 下記はアヤメの品種のデータでがく片の長さ、がく片の幅、花びらの幅の関係を可視化しています

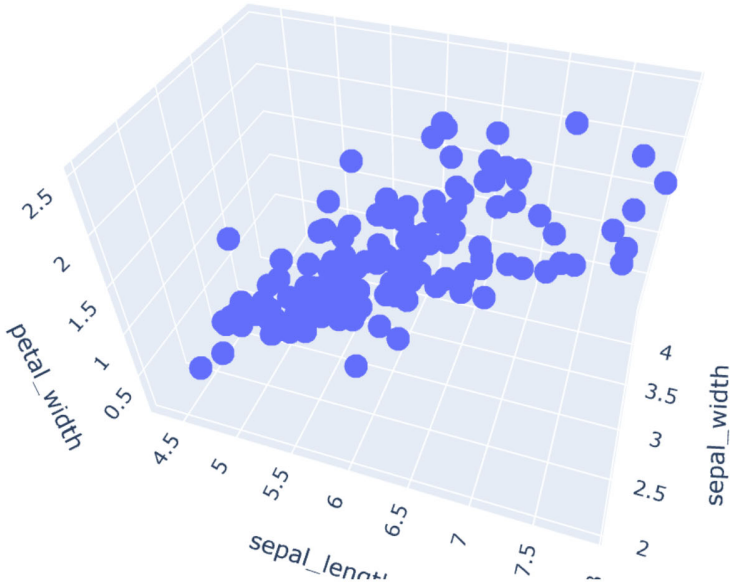

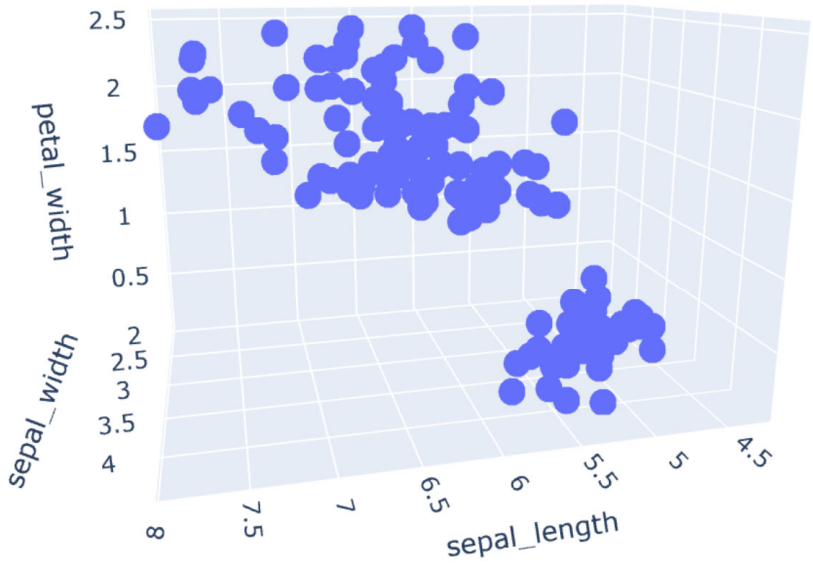

言語処理

- テキストの分析では文書を単語の出現頻度行列としてまとめたり単語ごとにベクトルを与えたりすることで分析しやすい形に変換します
  - 文書を単語の出現頻度行列としてまとめたものをバッグオブワーズと呼びます

	the	is	of	finance	bank	tributuary	river
文書1	34	12	23	7	3	0	0
文書2	8	4	12	0	2	3	5
文書3	2	3	3	3	9	0	0
…							
文書N	12	43	12	0	5	0	5

バッグオブワーズの例

- 単語をベクトルに変換する手法もあります（word2vec[Milkoc et al.2013]など

画像処理と認識技術

- 画像は画素（ピクセル）ごとにベクトルが記録されています
- そのままだと分析しづらいのでイメージを分割しタグ付けするなど前処理を加えることがあります
  - オブジェクト認識と呼ばれる認識技術の一種です
- 車載カメラで使用されるオブジェクト認識の具体例はCityscape(https://www.cityscapes-dataset.com）で見ることができます

認識技術の一例です

出典: Cityscape https://www.cityscapes-dataset.com/examples/#fine-annotations

音声処理

- オーディオ信号は分析しやすい形式に変換し分析することが多いです

- 変換の例としては短時間フーリエ変換、メル周波数係数、定数Q変換、クロマグラムなど様々な方法があります
  - 詳細は[Choit et al.2018]
  (https://arxiv.org/pdf/1709.04396.pdf)を参照してください

1-4-2　データ利活用のための技術

予測

- 訓練データからパターンを学習し、同様のパターンをもっていると考えらえる未知のデータの分類や予測に役立てます
  - 下記以外にも時系列予測やネットワークのリンク予測など応用は豊富です

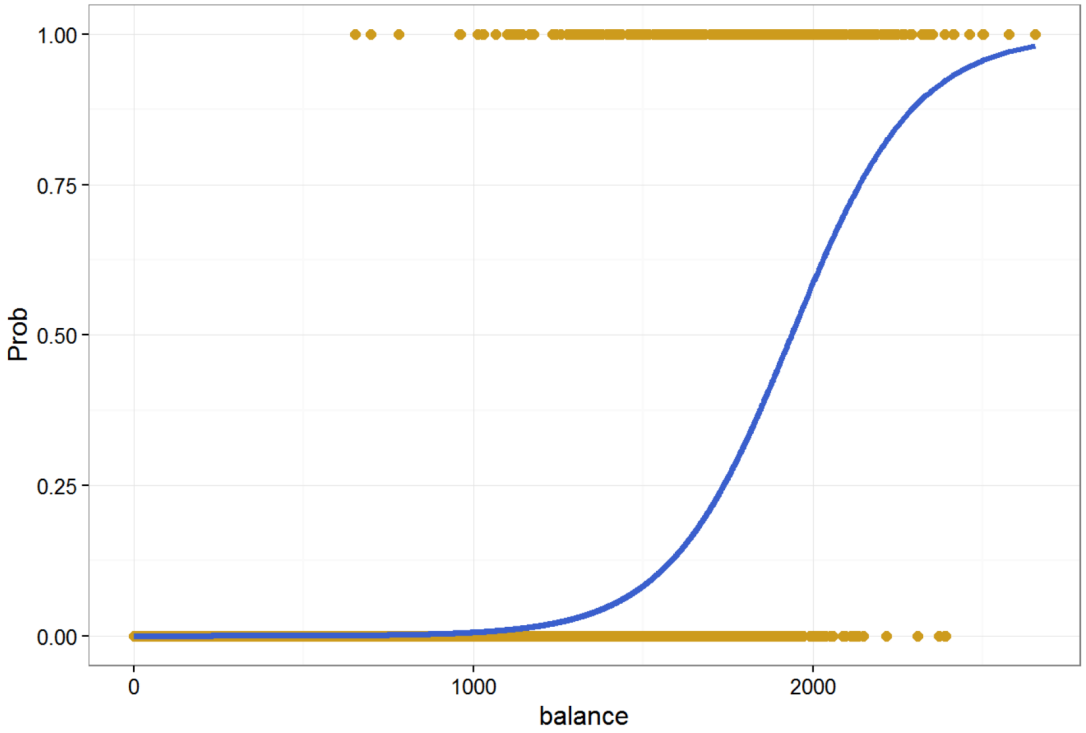

ロジスティック回帰によるデフォルト確率の予想
（この例についての詳細は[James et al.2013]を参照してください）

グルーピング

- グルーピング（クラスタリング）とはデータをいくつかのまとまりに分割することです

- 下は二次元で表現されたデータを3つのクラスタに分割した例です
  - （参考）下記はK-meansの例です

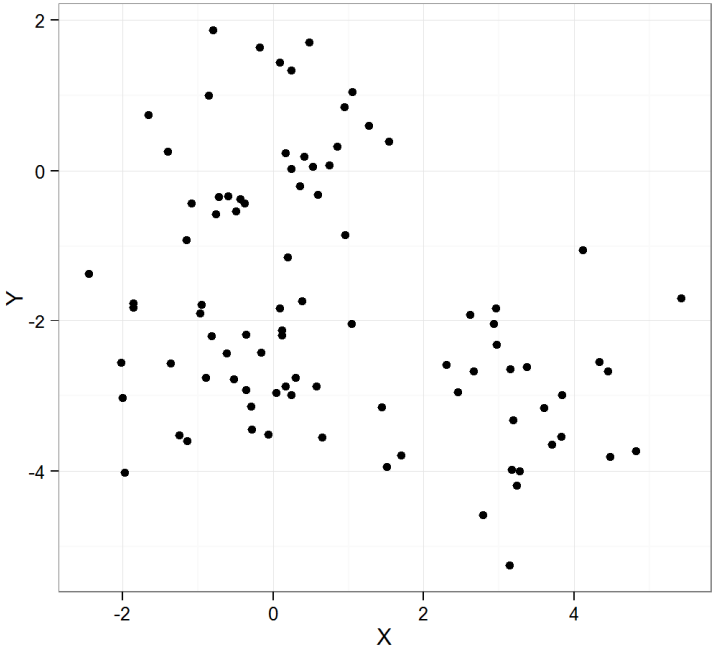

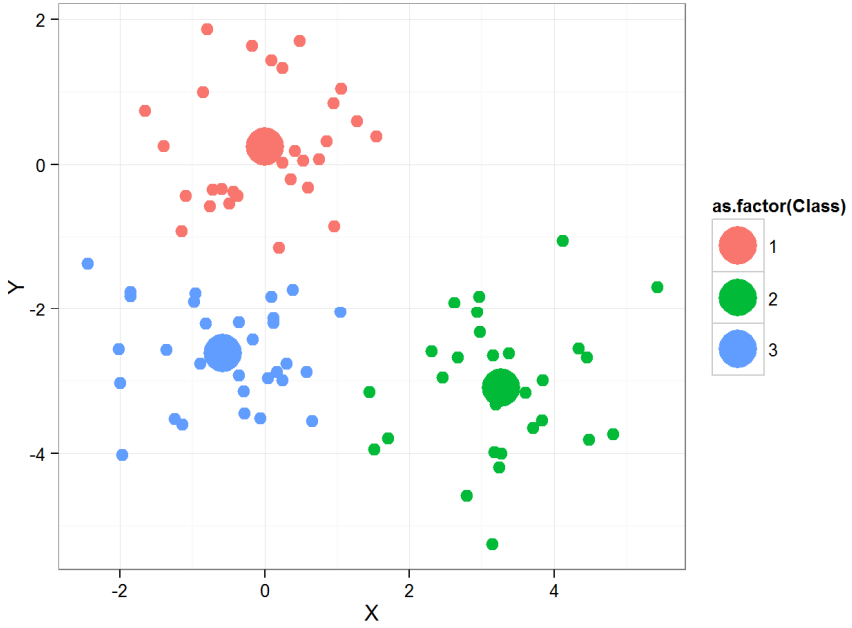

パターン発見とルールベース

- データ内のパターンを発見する手法も多くあります

マーケットバスケット分析はデータの中からよく出現するパターンを見つける手法のことです。例えば[Hastie et al.2009]のpg494では米国のアンケートのデータを用い

「結婚しており、家を所有している」なら「住居はアパートではない」など

データからルールを見つけることに成功しています。こうしたものをルールベースによるアプローチと言います。

トピックモデルは文書からトピックと呼ばれる潜在構造を推論する手法です

<<Gozo Stadium>>

…The main mission of the new board of the GFA is to improve the facilities of the Gozo Stadium in order to reach UEFA and FIFA standards so in the future the stadium could host international matches of the Maltese National Team.

…The main mission of the new board of the GFA is to improve the facilities of the Gozo Stadium in order to reach UEFA and FIFA standards so in the future the stadium could host international matches of the Maltese National Team.

<<bet365 Stadium>>

The bet365 Stadium is an all-seater football stadium in Stoke-on-Trent England and the home of Premier League club Stoke City.

The bet365 Stadium is an all-seater football stadium in Stoke-on-Trent England and the home of Premier League club Stoke City.

<<University of Colorado Law School>>

The University of Colorado Law School is one of the professional graduate schools within the University of Colorado System.…United States Supreme Court Justice Wiley Blount Rutledge graduated from the University of Colorado Law School in 1922.

The University of Colorado Law School is one of the professional graduate schools within the University of Colorado System.…United States Supreme Court Justice Wiley Blount Rutledge graduated from the University of Colorado Law School in 1922.

トピック1	トピック2	トピック3	トピック4
stadium	he	bank	state
world	football	war	university
cup	club	financial	mathematical
de	first	banks	school
international	league	banking	theory

最適化

- 大きくは連続最適化、離散（組み合わせ）最適化に分かれます
  - 連続最適化：微分可能な関数が対象
  - 離散最適化：組み合わせなど微分不可能な関数が対象

- 数理・計算機の発達と共に従来では「解く」ことが難しかった問題も近似的に解けるようになりました
  - 深層学習の発展とも関連します

シミュレーション・データ同化

- 実機の使用が困難な時や想定シナリオを作る際にはシミュレーションが用いられます
- シミュレーションをより現実的なものにするために実データから得られた観測値を統合することをデータ同化と呼びます

アンリアルエンジンを用いた自動運転シミュレーター

https://unrealengine.com/ja/spotlights/carla-democratizes-autonomous-vehicle-r-d-with-free-open-source-simulator

上のリンクの例はまるでゲームのようですが、リアルなシミュレーションを構成することで実機を使用せず自動運転のプログラムをテストできるため注目を集めています

NASAによるハリケーンのシミュレーションの例は
https://www.youtube.com/watch?v=p-3aB9hJ8Hc
で見ることができます

1-4-3　ビッグデータとAI

AIとビッグデータ

- 「1-1 社会で起きている変化」で多くの例を紹介しましたが、本節で紹介した分析技術を適用できるデータは数多くあります
  - 物理学、生物学、化学、政治学、法律文書、文学、音楽、テキスト、動画、経済学、ファイナンス、ビジネス、アプリ開発、農業、機械制御など

- こうしたデータを活用することでAIはパターンを学習し社会における様々な分野で役立てられます

特化型AIと汎用AI

- 「1-1 社会で起きている変化」でも紹介しましたが、特化型AIとはあるタスクの処理に特化したAIのことです。それに対して汎用AIとは様々なタスクの処理に対応できるAIのことです。

- 本節で紹介した技術を突き詰めることで多くの特化型AIは作成されています

- 複数の技術を組み合わせることで汎用AIっぽいものもできるかもしれませんが、現代ではまだ模索段階です
  - データの処理性能などでAIは人間をすでに上回っていますが、理解を与えたり、未知の状況に対応したりするなど様々な面でまだ課題を抱えています
  - 今のAIでできないことは研究開発のフロンティアになっています

自動機械学習

- 「1-1 社会で起きている変化」でも紹介しましたが、本節で見た機械学習モデルの開発ステップを自動化する試みもあります
  - GoogleのAutoML(https://cloud.google.com/automl)
  - MicrosoftAutoML(https://docs.microsoft.com/ja-jp/azure/machine-learning/concept-automated-ml)

- そうした自動化技術の進化した先にもしかしたら未来のAIがあるのかもしれません

1-4-4　参考文献

参考文献

[Choi et al.2018] Keunwoo Choi et al., "A Tutorial on Deep Learning for Music Information Retrieval“, https://arxiv.org/pdf/1709.04396.pdf

[Hastie et al.2009] Trevor Hastie, Robert Tibshirani, Jerome Friedman, "The Elements of Statistical Learning: Data Mining, Inference, and Prediction", Second Edition, February 2009

[James et al. 2013] James, G., Witten, D., Hastie, T., Tibshirani, R.,"An Introduction to Statistical Learning with Applications in R", Sprinter, 2013.

[Mikolov et al.2013] Tomas Mikolov, Ilya Sutskever, Kai Chen, Greg S. Corrado, Jeff Dean, "Distributed Representations of Words and Phrases and their Compositionality", Part of: Advances in Neural Information Processing Systems 26 (NIPS 2013)