総務省統計局

# 1日で学べる！ はじめてのPython

## データサイエンス・オンライン講座《特別編》

2023年12月9日(土)、 23日(土)

主催：総務省統計局
運営委託：株式会社ネットラーニング

1

## 自己紹介

### 佐久間　貴士

- 千葉県立保健医療大学
  健康科学部歯科衛生学科講師
- 立正大学データサイエンス学部 非常勤講師
- 日本大学法学部 非常勤講師

2

# 本日の講義資料

## 次の２点をお手元にご用意ください

①20231223_1日で学べる！はじめてのPython.pdf（投影しているPDF資料）

②演習資料.zip


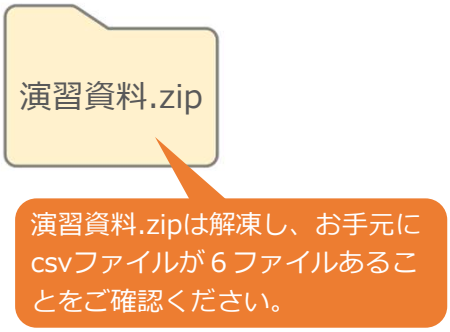


3

# 講義資料の格納先について（ダウンロード方法）

① カリキュラム一覧で ＋ ボタンをクリックしてください。

② 事前接続テストや講座当日のZoom参加のためのページならびに講義資料等のページが表示されますので、 ボタンの横にあるタイトルをクリックしてください。

③ 下記2点の資料をクリックいただきダウンロードしてください。
- 20231223_1日で学べる！はじめてのPython_講義資料.pdf
- 演習資料.zip




4

# 講義のまえに

## 推奨環境：パソコン（Windows/Mac 問いません）

※ タブレットやスマートフォンでの操作については
ご質問に回答できない場合があります。

5

# 講義のまえに

## Google Colaboratory の起動

https://colab.research.google.com/ にアクセス


6

# 講義のまえに

## Google Colaboratory の起動


7

# 講義のまえに

## Google Colaboratory の起動


8

# 講義のまえに

## プログラムの保存について

Colaboratoryで作成したノートブックは Google Drive※（https://drive.google.com/）内の「Colab Notebooks」に自動で保存されます。

※ Googleが提供しているクラウドストレージで、Googleアカウントでログインします


**名前の変更について**

Google Drive もしくは Google Colaboratory 、どちらからでも変更することができます。

9

# 講義のまえに

## さまざまなプログラミング言語

- Python
- R
- C言語
- C++
- Java
- PHP

10

## 講義のまえに

### ExcelとPythonのちがい

- Excelの限界
- 少ないコードで実装でき，標準ライブラリやコミュニティから提供されたモジュールが豊富，導入が容易
  - データ量が膨大でも重たくない
  - 再現性の高さ
  - オープンライセンス
  - ライブラリによる効率的なデータ分析
  - 機械学習と深層学習

11

## 講義のまえに

- **実際に手を動かして、コードを入力してみよう！**
  本日作成するコードは、講義終了後にみなさまにお配りします。
  講義時間中は、コピー&ペーストではなく、ご自身でコードを打ち込んでみましょう。

12

## 今日の内容

1. データ分析に必要な統計学の基礎を学ぶ
2. 比較して2変数の関係を考える
3. データに基づいて判断を下すための手法を学ぶ
4. ビジネスにおける予想と分析結果の報告

13

## 今日の内容

1. データ分析に必要な統計学の基礎を学ぶ
2. 比較して2変数の関係を考える
3. データに基づいて判断を下すための手法を学ぶ
4. ビジネスにおける予想と分析結果の報告

14

## 第1章の内容

1. データの種類とは
2. 1変数の状況と把握
   - （1）可視化の活用
   - （2）代表値の活用
3. ビジネスにおける比較
   - （1）概要
   - （2）活用

15

## 1.データの種類とは

**分析とは何か**

収集した情報の整理，加工，取捨選択を経て分析するプロセスのこと

適切なデータ分析により，数値にもとづく合理的な意思決定が可能となるほか，今まで気づけなかった課題やチャンスに気づきやすくなる

16

## 1.データの種類とは

**データ分析のメリット**

- データドリブン（Data Driven）が可能になる
- 迅速な意思決定が可能になる
- 新たなビジネスチャンスを発見できる

17

## 1.データの種類とは

**データ分析に用いられる主な10の手法**

- バスケット分析
- アソシエーション分析
- クロス集計
- 因子分析
- クラスター分析
- 決定木分析
- ABC分析
- ロジスティック回帰分析
- 主成分分析
- グレイモデル

18

# 1.データの種類とは

## 統計的処理の方針

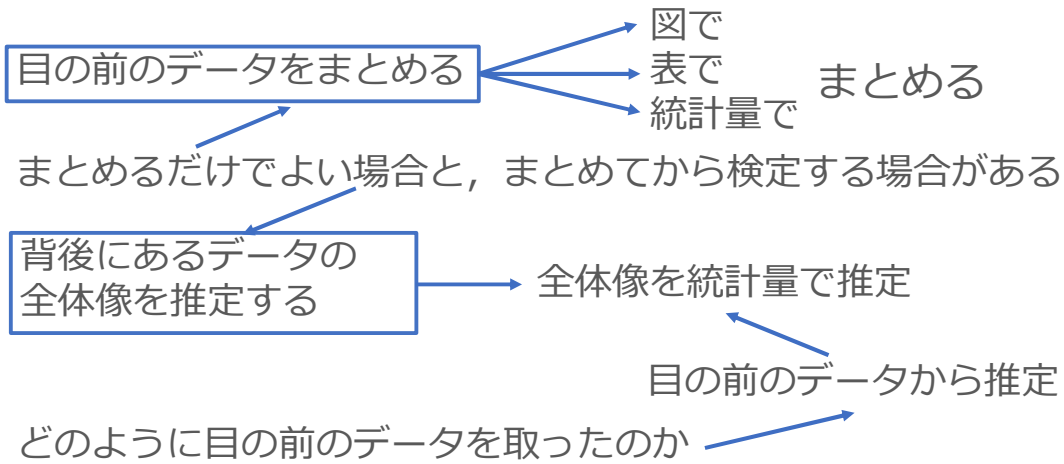


19

# 2. 1変数の状況と把握　（1）可視化の活用

## 1次元データを扱う

- 体位のデータ（体重，身長，その他）
- 医学データ（血圧，血糖値，○○値）
- 国民の所得
- 試験の点数
- 工業製品，農業生産物の質量など
- その他，数値の集合が統計の中心

**押さえるポイント**

全体のようすをつかむ　データの可視化 → 分布のかたち
統計量を知る　代表値：平均，分散，四分位数

20

## 2. 1変数の状況と把握　（1）可視化の活用

### データの整理

- 性質に注目すると以下の３種類に分けられる
  1. カテゴリカルデータ（名義データ）
  2. 順位データ（順序データ）
  3. 計算データ（数量データ）

ｱ．体重　ｲ．身長　ｳ．性別　Ⅰ．A・B・C・Dの成績
ｵ．100点満点のテストの得点　ｶ．あなたは走るのは速いですかという質問に対して，速い・ふつう・遅いの回答選択肢が用意されている場合　ｷ．100m走のタイム　ｸ．給料　ｹ．ある道路を自動車が通った台数　ｺ．年齢
ｻ．体重を重い・普通・軽いに分けた場合　ｼ．好きな食べ物を聞いた場合

21

## 2. 1変数の状況と把握　（1）可視化の活用

### データの整理

- データの性質を基礎にした分類以外の分類でよく使われるもの
  1. 時系列データ：時間の流れとともに観測して得られるデータ
  2. 横断面データ：一時点のみにおけるデータ

  縦断的研究，横断的研究

ｱ．あるクラスで一斉に行ったテストの結果　ｲ．A君の前期，後期の成績
ｳ．A君の前期の統計学，環境学，論理学の成績　Ⅰ．東京における1年間365日の気温　ｵ．平成28年4月1日の全国各地の気温
ｶ．4月に行った学生健康診断の結果　ｷ．ある人の過去10年間の健康診断の結果

22

## 2. 1変数の状況と把握　（1）可視化の活用

### 重要な統計量

- 平均（mean）：$\mu = \frac{1}{n}\sum_{i=1}^{n} x_i$
- 分散（variance）：$\sigma^2 = \frac{1}{n}\sum_{i=1}^{n}(x_i-\mu)^2$
- 標準偏差（standard deviation，sd）：$\sigma = \sqrt{\sigma^2}$
- 四分位数（Quantile）：$Q_1$，$Q_2$，$Q_3$
- メジアン，中央値（median）：$Q_2$

Averageも平均を表す概念だが、意味がやや広く、メジアン等の「真ん中」をも指す

23

## 2. 1変数の状況と把握　（1）可視化の活用

### データの種類

- 質的変量（質的変数）　性別，学年，出身地など
- 量的変量（量的変数）
  - 離散変量（離散変数）　家族の人数，テストの点数など
  - 連続変量（連続変数）　身長，体重など

**質的変量と量的変量**

- 数値が量的な変量を持つ変量を量的変量，意味を持たないものを質的変量という。
- 質的変量か量的変量かを見分けるには，「算術平均をとって意味があるか」を考えてみる方法がある。

24

# 2. 1変数の状況と把握　（1）可視化の活用

## 離散変量と連続変量

- **離散変量**は家族の人数やテストの点数など，とびとびの値しかとらない変数である。
- 一方，身長と体重などは正確に測ろうとする場合，無限に細かい数値になる。（身長171.2865...cm）このような変量は**連続変量**である。

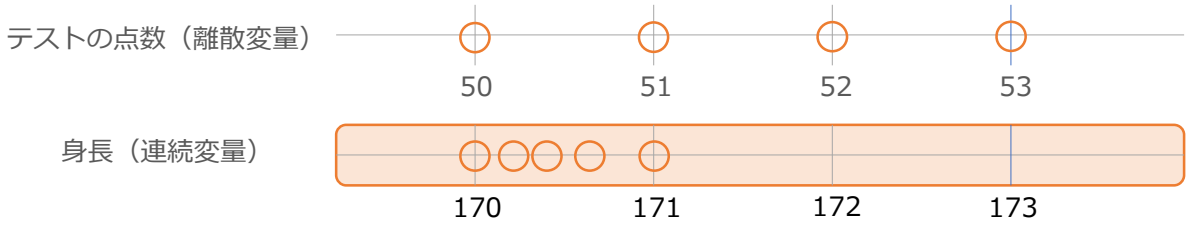


**データの種類によって，まとめ方が異なる**

25

# 2. 1変数の状況と把握　（1）可視化の活用

## データの尺度

- データの分類方法としては，**尺度**による分類方法もある。

- 質的変量
  - 名義尺度
  - 順序尺度
- 量的変量
  - 間隔尺度
  - 比例尺度

※離散変量と連続変量のそれぞれに，間隔尺度と比例尺度のものがある

尺度による分類

| | |
|---|---|
| 質的変量 | 名義尺度 |
| | 順序尺度 |
| 離散変量<br>量的変量<br>連続変量 | 間隔尺度<br>比例尺度 |

26

## 2. 1変数の状況と把握　（1）可視化の活用

### データの尺度

i. 名義尺度（性別，出身地など）
データ同士を区別するためにつけたもの。性別で，男ー1,女ー2などとしているが，男女を入れ替えても問題ない。

ii. 順序尺度（テストの順位，成績評価など）
テストの順位や成績評価など，順番に意味があるものである。これは，入れ替えることはできない。

iii. 間隔尺度（テストの点数，日付など）
テストの点数のように，順番に意味があり，さらにそれが等間隔に並んでいるもの。比例尺度との違いは，ゼロが絶対的な意味を持つかどうか。

iv. 比例尺度（身長，体重，家族の人数など）
比例尺度ともいう。体重40kgは20kgの2倍というように，比にも意味がある。

27

## 2. 1変数の状況と把握　（2）代表値の活用

### ライブラリのインポート

**ライブラリ（モジュール）**
プログラムファイルで、複数の関数が定義されている。

- numpy
  高度な数値計算と科学技術計算を支援するために設計された強力なライブラリ
  （多次元配列，ブロードキャスト，数学関数，など）
- pandas
  データ操作と分析のための効果的なデータ構造を提供するライブラリ
  （データフレーム，データ操作，時系列データ処理，など）

28

## 2. 1変数の状況と把握　（2）代表値の活用

### ライブラリのインポート

```
# pandas を pd という名前でインポート
import pandas as pd

# numpy を np という名前でインポート
import numpy as np
```

**＃（ハッシュ記号）**をつけることで、プログラムの内容を説明する「コメント」を記述できます

以降は ”pd.関数名”, ”np.関数名” と入力すればそれぞれの機能が使える

基本的に「import ライブラリ名」のように読み込む
「from ライブラリ名 import モジュール名.関数名」でもOK

29

## 2. 1変数の状況と把握　（2）代表値の活用

### ライブラリのインポート

```
import numpy as np
import pandas as pd

# google.colabからファイルをインポート
from google.colab import files

# uploadするファイルを選択できるインタフェースを表示させる
uploaded = files.upload()
```


演習資料.zipの中のsample_cross.csvを選択してください

30

# 2. 1変数の状況と把握　（2）代表値の活用

## ライブラリとデータのインポート

```
import io

# Pandasのread_csv関数を使って、csvファイルを読み込み、
  変数ad df に格納
ad_df =
pd.read_csv(io.BytesIO(uploaded['sample_cross.csv']))

# ad_dfをprint関数で表示させる
# print関数は()内を表示させる関数
print(ad_df)
```

```
    広告   購入 性別 年齢
0    B しなかった 男性 31
1    B しなかった 女性 28
2    A しなかった 女性 25
3    A しなかった 男性 31
4    B しなかった 男性 33
..  ..   ... .. ..
988  B しなかった 女性 27
989  B しなかった 男性 25
990  B しなかった 男性 32
991  B しなかった 女性 32
992  B しなかった 女性 28

[993 rows x 4 columns]
```

31

# 2. 1変数の状況と把握　（2）代表値の活用

## ライブラリとデータのインポート

```
# ageという変数を用意
# numpyの中にあるarray関数（配列）を使って、先ほど定義した
  ad_dfの中の[年齢]というカラムから100件データを並べる

age = np.array(ad_df['年齢'])[:100]
age
```

```
array([31, 28, 25, 31, 33, 31, 30, 30, 24, 30, 22, 23, 31, 25, 22, 23, 27
       27, 27, 27, 29, 32, 32, 32, 26, 26, 29, 26, 25, 25, 28, 30, 24, 30,
       28, 30, 27, 25, 32, 32, 28, 29, 30, 30, 32, 23, 31, 25, 32, 25, 31,
       31, 30, 26, 31, 28, 28, 27, 28, 29, 28, 23, 24, 23, 27, 23, 28, 32,
       30, 24, 23, 29, 24, 31, 28, 25, 31, 33, 31, 30, 30, 24, 30, 22, 23,
       31, 25, 22, 23, 27, 27, 27, 27, 29, 32, 32, 32, 26, 26, 29])
```

32

# 2. 1変数の状況と把握　（2）代表値の活用

## ライブラリとデータのインポート

```
# 変数age_df にPandasのDataFrameというデータ構造で格納
age_df = pd.DataFrame({'年齢':age})

# age_df を表示
age_df
```

DataFrameは二次元配列でデータを表示させる記述です
各レコードには「インデックス」という番号が表示されます

| | 年齢 |
|---|---|
| 0 | 31 |
| 1 | 28 |
| 2 | 25 |
| 3 | 31 |
| 4 | 33 |
| ... | ... |
| 95 | 32 |
| 96 | 32 |
| 97 | 26 |
| 98 | 26 |
| 99 | 29 |

100 rows × 1 columns

33

# 2. 1変数の状況と把握　（2）代表値の活用

## データの中心の指標（平均値：mean）

```
# sum関数で求めた（合計）をlen関数で求めた配列数で割る＝算術平均の計算
sum(age) / len(age)
# 上記と同じ作業をNumpyのmean関数でも求めることができる
np.mean(age)
# 先ほどデータフレームage_dfに入れた関数を平均するというコード
age_df.mean()
```

```
27.8

27.8

年齢    27.8
dtype: float64
```

34

## 2. 1変数の状況と把握　（2）代表値の活用

### データの中心の指標（中央値：median）

データを大きさの順に並べた時にちょうど中央に位置する値

```
# Numpyのsort関数（小さい順に並ぶ）でageを読み込み、変数sorted_ageに格納
sorted_age = np.sort(age)
# print()関数と同じ sorted_ageを表示させる
sorted_age
```

```
array([22, 22, 22, 22, 23, 23, 23, 23, 23, 23, 23, 23, 23, 24, 24, 24, 24,
       24, 24, 25, 25, 25, 25, 25, 25, 25, 25, 25, 25, 26, 26, 26, 26, 26, 26,
       27, 27, 27, 27, 27, 27, 27, 27, 27, 27, 27, 28, 28, 28, 28, 28, 28,
       28, 28, 28, 28, 29, 29, 29, 29, 29, 29, 29, 30, 30, 30, 30, 30, 30,
       30, 30, 30, 30, 30, 30, 30, 31, 31, 31, 31, 31, 31, 31, 31, 31, 31,
       31, 31, 32, 32, 32, 32, 32, 32, 32, 32, 32, 32, 32, 33, 33])
```

35

## 2. 1変数の状況と把握　（2）代表値の活用

### データの中心の指標（中央値：median）

```
n = len(sorted_age)                # 変数nにsorted_ageの個数を入れる
# ifはexcelのifと同義で、論理式を分岐させる指示
# == 2つの値を比較して等しいかどうかを調べる
if n % 2 == 0:                     # %は余りを表示させる数式
   m0 = sorted_age[n//2 -1]        # //は切り捨ての除算
   m1 = sorted_age[n//2]           # 偶数、奇数の判定
   median = (m0 + m1) / 2
else:
    median = sorted_age[(n+1)//2 - 1]
median
```

```
28.0
```

36

# 2. 1変数の状況と把握　（2）代表値の活用

## データのばらつきの指標（分散と標準偏差）

平均が40歳でも,全員が40歳の場合のデータと,0歳が半分、80歳が半分のデータでは全く異なる。ばらつきを求めるために**偏差(deviation)**を計算する。

```
# Numpyのmean（平均）を求める
mean = np.mean(age)
# ageから平均を引き、平均との差＝ばらつき（偏差）を求める
deviation = age - mean
deviation
```

```
array([ 3.2,  0.2, -2.8,  3.2,  5.2,  3.2,  2.2,  2.2, -3.8,  2.2, -5.8,
       -4.8,  3.2, -2.8, -5.8, -4.8, -0.8, -0.8, -0.8, -0.8,  1.2,  4.2,
        4.2,  4.2, -1.8, -1.8,  1.2, -1.8, -2.8, -2.8,  0.2,  2.2, -3.8,
        2.2,  0.2,  2.2, -0.8, -2.8,  4.2,  4.2,  0.2,  1.2,  2.2,  2.2,
        4.2, -4.8,  3.2, -2.8,  4.2, -2.8,  3.2,  3.2,  2.2, -1.8,  3.2,
        0.2,  0.2, -0.8,  0.2,  1.2,  0.2, -4.8, -3.8, -4.8, -0.8, -4.8,
        0.2,  4.2,  2.2, -3.8, -4.8,  1.2, -3.8,  3.2,  0.2, -2.8,  3.2,
        5.2,  3.2,  2.2,  2.2, -3.8,  2.2, -5.8, -4.8,  3.2, -2.8, -5.8,
       -4.8, -0.8, -0.8, -0.8, -0.8,  1.2,  4.2,  4.2,  4.2, -1.8, -1.8,
        1.2])
```

37

# 2. 1変数の状況と把握　（2）代表値の活用

## データのばらつきの指標（分散と標準偏差）

```
# ageのdfのコピーを作る
summary_df = age_df.copy()
# int型とタイプを指定
summary_df['偏差'] = deviation.astype(int)
summary_df
```

シングルクォーテーションを記載することで日本語で記述できる！

| | 年齢 | 偏差 |
|---|---|---|
| 0 | 31 | 3 |
| 1 | 28 | 0 |
| 2 | 25 | -2 |
| 3 | 31 | 3 |
| 4 | 33 | 5 |
| ... | ... | ... |
| 95 | 32 | 4 |
| 96 | 32 | 4 |
| 97 | 26 | -1 |
| 98 | 26 | -1 |
| 99 | 29 | 1 |

100 rows × 2 columns

38

## 2. 1変数の状況と把握　（2）代表値の活用

### データのばらつきの指標（分散と標準偏差）

```
summary_df.mean()
np.mean(deviation **2)
```

```
9.7
```

```
# Numpyのvar関数でも同様に分散を求めることができる。
np.var(age)
```

```
9.7
```

39

## 2. 1変数の状況と把握　（2）代表値の活用

### データのばらつきの指標（分散と標準偏差）

```
# Pandasのvarを使って分散を計算してみると…
age_df.var()
```

```
年齢      9.79798
dtype: float64
```

40

# 2. 1変数の状況と把握　（2）代表値の活用

## データのばらつきの指標（分散と標準偏差）

```
summary_df['偏差二乗'] = np.square(deviation)
summary_df

summary_df.mean()
```

```
年齢     27.80
偏差      0.25
偏差二乗    9.70
dtype: float64
```

| | 年齢 | 偏差 | 偏差二乗 |
|---|---|---|---|
| 0 | 31 | 3 | 10.24 |
| 1 | 28 | 0 | 0.04 |
| 2 | 25 | -2 | 7.84 |
| 3 | 31 | 3 | 10.24 |
| 4 | 33 | 5 | 27.04 |
| ... | ... | ... | ... |
| 95 | 32 | 4 | 17.64 |
| 96 | 32 | 4 | 17.64 |
| 97 | 26 | -1 | 3.24 |
| 98 | 26 | -1 | 3.24 |
| 99 | 29 | 1 | 1.44 |

100 rows × 3 columns

41

# 2. 1変数の状況と把握　（2）代表値の活用

## データのばらつきの指標（分散と標準偏差）

```
import statistics
import math

print(statistics.mean(age))
print(sum(age) / len(age))
print(statistics.median(age))
print(statistics.mode(age))
print(statistics.variance(age))
print(statistics.pstdev(age))
```

```
27
27.8
28.0
30
9
3.0
```

42

## 3. ビジネスにおける比較　（1）概要

**ABテスト**

- AパターンとBパターンでどちらが効果があるのかをテストする
  ＝**複数のものを比較するテスト**
- Webマーケティングの領域で非常に頻繁に使われている

例）Webサイトのデザイン，インターネット広告，
ランディングページ最適化，メール配信のセグメント

43

## 3. ビジネスにおける比較　（1）概要

**カイ二乗検定（独立性の検定：test for independence）**

- 2つの変数XとYについて，関係があるのか，それとも独立であるのか
  - 帰無仮説$H_0$：属性間には関係がない「XとYは独立である」
  - 対立仮説$H_1$：属性間には関係がある「XとYは独立ではない」

- 独立性の検定にはカイ二乗分布が使われるのでカイ二乗検定（chi-square test）と呼ばれる

  大前提：カテゴリカルデータ（名義データへの適用）

44

## 3. ビジネスにおける比較　（1）概要

**帰無仮説と対立仮説**

- 帰無仮説（null hypothesis）$H_0$：
  「有意差がない」という仮説
  「無に帰すことも予定している」仮説であり，通常は否定したい仮説を設定する

- 対立仮説（alternative hypothesis）$H_1$：
  「有意差がある」という仮説
  帰無仮説が間違っていると確信されたとき（棄却された）に採用される

45

## 3. ビジネスにおける比較　（2）活用

**ABテスト（仮説を立てる）**

例 1

ある商品の広告プランとしてAとBがあり，どちらがより購買意欲につながっているのか

- もし広告の種類と購入の有無が独立なら購入の割合に変化はない
- そうでないなら，購入の割合に差が出るはず

➡ 独立性の検定が使える

46

# 3. ビジネスにおける比較　（2）活用

## ABテスト

例１

ある商品の広告プランとしてAとBがあり，どちらがより購買意欲につながっているのか

| | 購入した | 購入しなかった | 合計 |
|---|---|---|---|
| 広告A | 60 | 1,000 | 1,060 |
| 広告B | 40 | 400 | 440 |
| 合計 | 100 | 1,400 | 1,500 |

47

# 3. ビジネスにおける比較　（2）活用

## ABテスト（クロス集計表を作成する）

```
# pandas を pd という名前でインポート
import pandas as pd
# scipy から 一部分（stats）のみインポート

from scipy import stats
#カラム（columns。縦列）のタイトルを付与。
df = pd.DataFrame([[60, 1000], [40, 400]],
                  index=['A', 'B'], columns=['購入した', '購入していない'])
df
```

| | 購入した | 購入していない |
|---|---|---|
| A | 60 | 1000 |
| B | 40 | 400 |

48

# 3. ビジネスにおける比較　（2）活用

## ABテスト（検定を行う）

```
#カイ二乗検定で検定していくため、以下のとおり変数を指定
chi2, p, dof, exp = stats.chi2_contingency(df, correction=False)

print("期待度数", "¥n", exp)
print("自由度", "¥n", dof)
print("カイ二乗値", "¥n", chi2)
print("p値", "¥n", p)
```

**＼マークには注意！**
Windowsでは円記号「￥」で、
Macは「＼」記号で表示されます

```
期待度数
 [[ 70.66666667 989.33333333]
 [ 29.33333333 410.66666667]]
自由度
 1
カイ二乗値
 5.880911541288903
p値
 0.015305895674955605
```

結果はカイ二乗値(chi2)，p値(p)，自由度(dof)，期待度数(exp)で出力される

標準だとイェイツの修正が入るので，correction=Falseにして，補正が入らないように設定

49

# 3. ビジネスにおける比較　（2）活用

## ABテスト（期待度数について）

例１

ある商品の広告プランとしてAとBがあり，どちらがより購買意欲につながっているのか

来客数の合計が1,500名
100名が商品を購入している
広告AもBも1/15の割合で購買意欲につながっている

期待値

A:1060*(1/15)=70.7
B:440*(1/15)=29.3

$$\frac{(\text{観測データ} - \text{期待度数})^2}{\text{期待度数}}$$

$$\chi^2 = \sum \frac{(O-E)^2}{E}$$

50

# 3. ビジネスにおける比較　（2）活用

## ABテスト（実行結果の確認）

例１

ある商品の広告プランとしてAとBがあり，どちらがより購買意欲につながっているのか

```
chi2, p, dof, exp = stats.chi2_contingency(df, corre

print("期待度数", "\n", exp)
print("自由度", "\n", dof)
print("カイ二乗値", "\n", chi2)
print("p値", "\n", p)
```

```
期待度数
 [[ 70.66666667 989.33333333]
 [ 29.33333333 410.66666667]]
自由度
 1
カイ二乗値
 5.880911541288903
p値
 0.015305895674955605
```

自由度＝（行数-1）＊（列数-1）

自由度1の時のカイ二乗分布の値
5%で3.84，1%で6.63，0.5%で7.88

5.88は3.84を上回っているが6.63を下回っている

AとBが同じ前提の時
この事象は5%以下の確率でしか起きない

51

# 3. ビジネスにおける比較　（2）活用

## ABテスト（実行結果の確認）

例１

ある商品の広告プランとしてAとBがあり，どちらがより購買意欲につながっているのか

```
chi2, p, dof, exp = stats.chi2_contingency(df, correction=False)

print("期待度数", "\n", exp)
print("自由度", "\n", dof)
print("カイ二乗値", "\n", chi2)
print("p値", "\n", p)
```

```
期待度数
 [[ 70.66666667 989.33333333]
 [ 29.33333333 410.66666667]]
自由度
 1
カイ二乗値
 5.880911541288903
p値
 0.015305895674955605
```

**p値（p-value）**
帰無仮説を考えた時にその結果が出る確率
（有意水準と照らし合わせるための数値）

有意水準 ＞ p値 ＝有意差がある

52

# 3. ビジネスにおける比較　（2）活用

## ABテスト

例２

Webサイトから商品購入を促すバナー（画像）を
２種類用意し，どちらが良いかテストすることにした

| | バナーA | バナーB |
|---|---|---|
| クリック数 | 10,000 | 10,000 |
| コンバージョン数 | 400 | 340 |
| コンバージョン率 | ??? | ??? |

※コンバージョン率：アクセスしてきたユーザーのうち、どのくらいがコンバージョンに至ったかを示す数値
コンバージョン：（訪問者がWebサイトの）目標としているアクションを起こしてくれた状態のこと

53

# 3. ビジネスにおける比較　（2）活用

## ABテスト（仮説を立てる）

例２

Webサイトから商品購入を促すバナー（画像）を
２種類用意し，どちらが良いかテストすることにした

- $H_0$:バナーAとバナーBにはコンバージョン数の差異を決定づける明らかな差が「ない」（独立である：関連がない）
- $H_1$:バナーAとバナーBにはコンバージョン数の差異を決定づける明らかな差が「ある」（独立ではない：関連がある）

仮説：両バナーにおいてコンバージョン数の差異を決定づける明らかな差が「ある」に違いない

54

## 3. ビジネスにおける比較　（2）活用

### ABテスト（ABテストができるようクロス集計を行う）

例２

Webサイトから商品購入を促すバナー（画像）を
２種類用意し，どちらが良いかテストすることにした

| | good click | no good click | total |
|---|---|---|---|
| バナーA | ? | ? | ? |
| バナーB | ? | ? | ? |
| 合計 | ? | ? | ? |

※コンバージョンがあったクリックとなかったクリックに分ける必要がある

55

## 3. ビジネスにおける比較　（2）活用

### ABテスト

例２

Webサイトから商品購入を促すバナー（画像）を
２種類用意し，どちらが良いかテストすることにした

| | good click | no good click | total |
|---|---|---|---|
| バナーA | 400 | 9,600 | 10,000 |
| バナーB | 340 | 9,660 | 10,000 |
| 合計 | 740 | 19,260 | 20,000 |

56

# 3. ビジネスにおける比較　（2）活用

## ABテスト（クロス集計表を作成する）

```
import pandas as pd
from scipy import stats

df = pd.DataFrame([[400, 9600], [340, 9660]],
                  index=['バナーA', 'バナーB'], columns=['goog click', 'no
good click'])
df
```

| | goog click | no good click |
|---|---|---|
| バナーA | 400 | 9600 |
| バナーB | 340 | 9660 |

57

# 3. ビジネスにおける比較　（2）活用

## ABテスト（検定を実施し実行結果を確認する）

```
chi2, p, dof, exp = stats.chi2_contingency(df, correction=False)

print("期待度数", "¥n", exp)
print("自由度", "¥n", dof)
print("カイ二乗値", "¥n", chi2)
print("p値", "¥n", p)
```

```
期待度数
 [[ 370. 9630.]
 [ 370. 9630.]]
自由度
 1
カイ二乗値
 5.051780752715333
p値
 0.02460064285694141
```

58

## 今日の内容

1. データ分析に必要な統計学の基礎を学ぶ
2. 比較して2変数の関係を考える
3. データに基づいて判断を下すための手法を学ぶ
4. ビジネスにおける予想と分析結果の報告

59

## 第2章の内容

1. クロス集計の軸設定と見方
2. 散布図と相関の調べ方
3. 相関係数と因果関係の違い
4. 時系列データの見方、分析方法

60

# 1.クロス集計の軸設定と見方

## クロス集計とは

数量データの関係性を見る際は相関係数が利用できるが，カテゴリカルデータの関係性を見る際には**クロス集計**を用いるのが便利。分割表とも言う場合もある。
単純にはカテゴリごとの度数を記録した表，ただし，2つ以上の変数を対象とし，その組み合わせで度数を求める。

縦軸：表側（＝原因）どのような視点から調査結果を見たいか ※分析軸
横軸：表頭（＝結果）どのような結果を見たいか

61

# 1.クロス集計の軸設定と見方

## CSVファイルのマウント

```
import numpy as np
import pandas as pd

from google.colab import files

uploaded = files.upload()
```

62

# 1.クロス集計の軸設定と見方

## CSVファイルのマウント

```
import pandas as pd
import io

df = pd.read_csv('sample_cross.csv')
print(df)
```

```
    広告    購入 性別 年齢
0    B しなかった 男性 31
1    B しなかった 女性 28
2    A しなかった 女性 25
3    A しなかった 男性 31
4    B しなかった 男性 33
.. ..   ... .. ..
988  B しなかった 女性 27
989  B しなかった 男性 25
990  B しなかった 男性 32
991  B しなかった 女性 32
992  B しなかった 女性 28

[993 rows x 4 columns]
```

63

# 1.クロス集計の軸設定と見方

## CSVファイルのマウント

```
n=len(df)
print(n)
df.head()
```

993

| | 広告 | 購入 | 性別 | 年齢 |
|---|---|---|---|---|
| 0 | B | しなかった | 男性 | 31 |
| 1 | B | しなかった | 女性 | 28 |
| 2 | A | しなかった | 女性 | 25 |
| 3 | A | しなかった | 男性 | 31 |
| 4 | B | しなかった | 男性 | 33 |

64

# 1.クロス集計の軸設定と見方

## CSVファイルのマウント

```
ad_cross=pd.crosstab(df['広告'], df['性別'])
ad_cross
```

| 性別 | 女性 | 男性 |
|---|---|---|
| 広告 | | |
| A | 200 | 199 |
| B | 297 | 297 |

65

# 1.クロス集計の軸設定と見方

## CSVファイルのマウント

```
ad_cross=pd.crosstab(df['購入'], df['広告'])
ad_cross
```

| 広告 | A | B |
|---|---|---|
| 購入 | | |
| した | 41 | 68 |
| しなかった | 358 | 526 |

66

# 1.クロス集計の軸設定と見方

## CSVファイルのマウント

```
ad_cross=pd.crosstab(df['広告'], df['性別'], normalize=True)
ad_cross
```

| 性別 | 女性 | 男性 |
|---|---|---|
| 広告 | | |
| A | 0.201410 | 0.200403 |
| B | 0.299094 | 0.299094 |

pandas.crosstab()
第一引数：indexに結果の行見出し
第二引数：columsに結果の列見出し
引数normalizeで全体・行ごと・列ごとに規格化（正規化）

pandas.DataFrame を返す

67

# 2.散布図と相関の調べ方

## 散布図とは

2つの要素からなる1組のデータが得られたときに，2つの要素の間にある関係（相関関係）を見るためのグラフ。因果関係（どちらかが原因となって，もう一方が起こる）を示すものではない。QC7つ道具の一つ。

例1）数学の点数と英語の点数：数学の点数が高い生徒は英語の点数も高い傾向がある（反対も含める）。
例2）高齢者の運動量と体力：運動量が増えると体力も増える（〃）。

68

## 2.散布図と相関の調べ方

### 相関分析

2つの要素（2変数）間の関係を数値で表現する分析方法。「相関」とは2つ以上の変数があるときに，「**どれぐらい類似しているのか**」という「類似度」を意味する。２つの変量の強弱を数値化したものを「相関係数」という。「類似度」の強さを「-1から1」までの範囲で表現される。正（または負）の相関関係が強いほど1（または-1）に近く，相関関係が弱いほど0に近くなる。

69

## 2.散布図と相関の調べ方

### CSVファイルのマウント

```
from google.colab import files

uploaded = files.upload()
```

```
import pandas as pd
import io

df = pd.read_csv(io.BytesIO(uploaded['sample_covid19.csv']))
df
```

70

# 2.散布図と相関の調べ方

## CSVファイルのマウント

```
[1] from google.colab import files

    uploaded = files.upload()

    ファイル選択 sample_covid19.csv
    • sample_covid19.csv(text/csv) - 42033 bytes, last modified: 2023/12/17 - 100% done
    Saving sample_covid19.csv to sample_covid19.csv

    import pandas as pd
    import io

    df = pd.read_csv(io.BytesIO(uploaded['sample_covid19.csv']))
    df
```

| | Date | ALL | Hokkaido | Aomori | Iwate | Miyagi | Akita | Yamagata | Fukushima | Ibaraki | ... | Ehime | Kochi | Fukuoka | Saga | Nagasaki | Kumamoto | Oi |
|---|---|---|---|---|---|---|---|---|---|---|---|---|---|---|---|---|---|---|
| 0 | 2021/1/1 | 3249 | 98 | 10 | 4 | 30 | 3 | 3 | 12 | 42 | ... | 6 | 6 | 158 | 1 | 20 | 30 | |
| 1 | 2021/1/2 | 3055 | 77 | 4 | 2 | 4 | 0 | 1 | 13 | 20 | ... | 6 | 7 | 124 | 5 | 28 | 26 | |
| 2 | 2021/1/3 | 3136 | 68 | 10 | 3 | 20 | 3 | 6 | 14 | 52 | ... | 7 | 11 | 104 | 3 | 30 | 22 | |
| 3 | 2021/1/4 | 3333 | 93 | 10 | 0 | 18 | 3 | 5 | 25 | 32 | ... | 9 | 2 | 128 | 23 | 24 | 34 | |
| 4 | 2021/1/5 | 4936 | 79 | 7 | 6 | 37 | 8 | 5 | 25 | 67 | ... | 25 | 7 | 187 | 10 | 55 | 63 | |
| ... | ... | ... | ... | ... | ... | ... | ... | ... | ... | ... | ... | ... | ... | ... | ... | ... | ... | |
| 268 | 2021/9/26 | 2146 | 54 | 14 | 2 | 16 | 0 | 1 | 9 | 47 | ... | 10 | 0 | 88 | 4 | 8 | 14 | |
| 269 | 2021/9/27 | 1159 | 19 | 5 | 1 | 6 | 1 | 1 | 3 | 31 | ... | 2 | 3 | 46 | 12 | 9 | 10 | |
| 270 | 2021/9/28 | 1743 | 26 | 25 | 0 | 12 | 6 | 1 | 3 | 25 | ... | 10 | 4 | 43 | 8 | 5 | 17 | |
| 271 | 2021/9/29 | 1980 | 45 | 23 | 1 | 21 | 0 | 1 | 4 | 44 | ... | 7 | 7 | 44 | 8 | 7 | 19 | |
| 272 | 2021/9/30 | 1571 | 26 | 23 | 0 | 14 | 2 | 1 | 5 | 20 | ... | 14 | 3 | 37 | 6 | 6 | 15 | |

273 rows × 49 columns

71

# 2.散布図と相関の調べ方

## CSVファイルのマウント

```
# 変数dfに格納したデータの何番目を
    取得するか指定
df.iloc[:,9]

df.iloc[:,14]
```

```
df['Ibaraki']

df['Tokyo']
```

```
df.iloc[:,9]
0    42
1    20
2    52
3    32
4    67
    ..
268  47
269  31
270  25
271  44
272  20
Name: Ibaraki, Length: 273, dtype: int64
```

```
df.iloc[:,14]
0     793
1     829
2     826
3     905
4    1315
     ...
268   302
269   155
270   250
271   268
272   219
Name: Tokyo, Length: 273, dtype: int64
```

72

# 2.散布図と相関の調べ方

## プロット（東京都と茨城県の新規感染者数）

```
%matplotlib inline
# グラフツール matplotlibをインポート
import matplotlib.pyplot as plt
# カラーリングするツールをインポート
import warnings

#xlabel、ylabelはX軸、Y軸を指定する
plt.style.use('ggplot')
plt.plot(df.iloc[:,9],
df.iloc[:,14],'bo')
plt.xlabel('Ibaraki')
plt.ylabel('Tokyo')
plt.show()
```

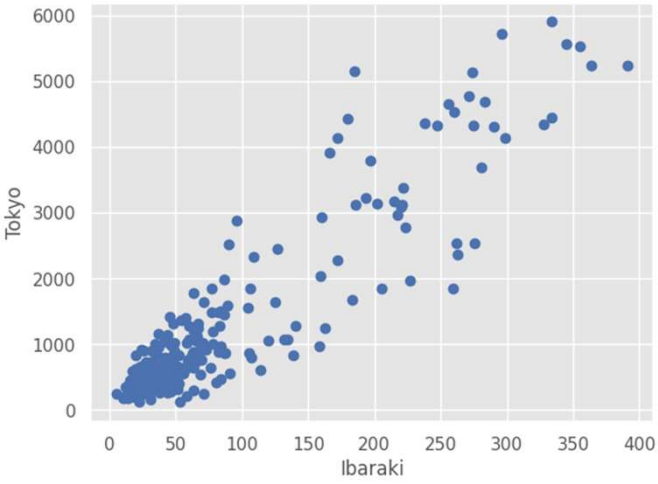


73

# 2.散布図と相関の調べ方

## プロット（東京都と茨城県の新規感染者数）：相関係数

```
y_colum='Tokyo'

# 全体の相関係数を計算し、corrの
matrix上に表示させる
corr_matrix = df.corr()
# 変数y_corrにy_colum(つまりTokyo)
との相関係数を格納
y_corr = corr_matrix[y_colum]
y_corr
```

```
ALL          0.933407
Hokkaido     0.562570
Aomori       0.597597
Iwate        0.720486
Miyagi       0.694157
Akita        0.658737
Yamagata     0.599073
Fukushima    0.857339
Ibaraki      0.919476
Tochigi      0.916396
Gunma        0.889860
Saitama      0.959624
Chiba        0.911269
Tokyo        1.000000
Kanagawa     0.932625
Niigata      0.853796
Toyama       0.835855
Ishikawa     0.793950
Fukui        0.736283
Yamanashi    0.875588
Nagano       0.794002
Gifu         0.681034
Shizuoka     0.848566
Aichi        0.634805
Mie          0.738161
Shiga        0.838877
Kyoto        0.852544
Osaka        0.757124
Hyogo        0.740625
Nara         0.711916
Wakayama     0.751228
Tottori      0.797398
```

```
Ishikawa     0.793950
Fukui        0.736283
Yamanashi    0.875588
Nagano       0.794002
Gifu         0.681034
Shizuoka     0.848566
Aichi        0.634805
Mie          0.738161
Shiga        0.838877
Kyoto        0.852544
Osaka        0.757124
Hyogo        0.740625
Nara         0.711916
Wakayama     0.751228
Tottori      0.797398
Shimane      0.708764
Okayama      0.744315
Hiroshima    0.665415
Yamaguchi    0.670897
Tokushima    0.490078
Kagawa       0.824499
Ehime        0.733994
Kochi        0.660480
Fukuoka      0.882209
Saga         0.786857
Nagasaki     0.789520
Kumamoto     0.856704
Oita         0.722250
Miyazaki     0.761319
Kagoshima    0.828517
Okinawa      0.893809
Name: Tokyo, dtype: float64
```

74

## 2.散布図と相関の調べ方

### プロット（東京都と茨城県の新規感染者数）：相関係数

```
y_colum='Tokyo'

corr_matrix = df.corr()['Ibaraki']
y_corr = corr_matrix[y_colum]
y_corr
```

```
0.9194759486275046
```

75

## 2.散布図と相関の調べ方

### プロット（青森県と茨城県の新規感染者数）

```
plt.style.use('ggplot')
plt.plot(df.iloc[:,9],
df.iloc[:,3],'bo')
plt.xlabel('Ibaraki')
plt.ylabel('Aomori')
plt.show()
```

```
0.6844695489050351
```

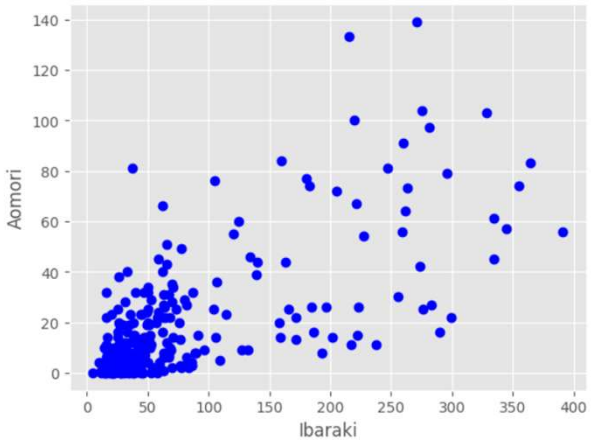


76

# 2.散布図と相関の調べ方

## プロット（神奈川県と北海道の新規感染者数）

```
plt.style.use('ggplot')
plt.plot(df.iloc[:,2],
df.iloc[:,15],'bo')
plt.xlabel('Hokkaido')
plt.ylabel('Kanagawa')
plt.show()
```

```
0.5503568815983438
```

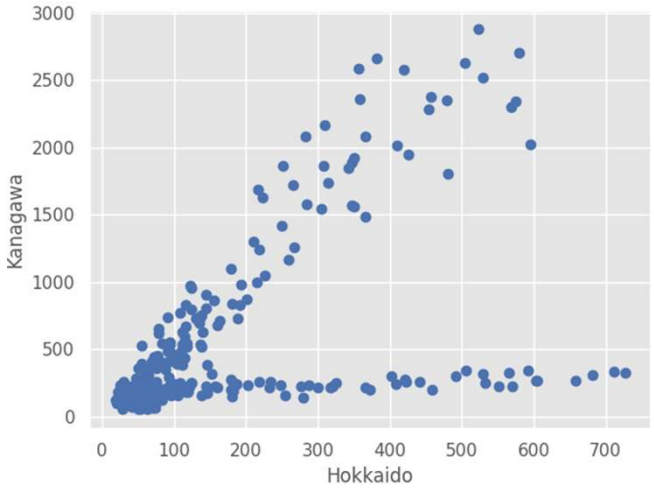


77

# 3.相関係数と因果関係の違い　※セクション3の紹介

## 相関係数

２つの変量の強弱を数値化したものを「相関係数」という。
「類似度」の強さを「-1から1」までの範囲で表現される。
正（または負）の相関関係が強いほど1（または-1）に近く，
相関関係が弱いほど0に近くなる。

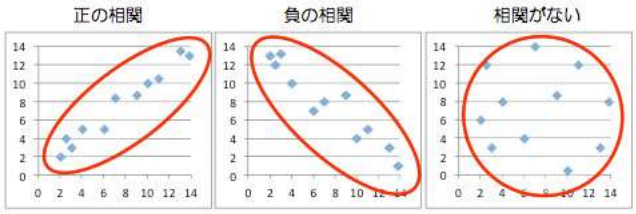


なるほど統計学園：https://www.stat.go.jp/naruhodo/10_tokucho/hukusu.html

78

## 2.散布図と相関の調べ方- iris dataset -

### irisデータセット

```
import pandas as pd
import seaborn as sns
sns.set()
iris = sns.load_dataset('iris')
titanic = sns.load_dataset('titanic')
```

79

## 2.散布図と相関の調べ方- iris dataset -

### データセットの利用

```
print(iris.head())
```

| | sepal_length | sepal_width | petal_length | petal_width | species |
|---|---|---|---|---|---|
| 0 | 5.1 | 3.5 | 1.4 | 0.2 | setosa |
| 1 | 4.9 | 3.0 | 1.4 | 0.2 | setosa |
| 2 | 4.7 | 3.2 | 1.3 | 0.2 | setosa |
| 3 | 4.6 | 3.1 | 1.5 | 0.2 | setosa |
| 4 | 5.0 | 3.6 | 1.4 | 0.2 | setosa |

80

# 2.散布図と相関の調べ方- iris dataset -

## データセットの利用

```
print(titanic.head())
```

```
   survived  pclass     sex   age  sibsp  parch     fare embarked  class
0         0       3    male  22.0      1      0   7.2500        S  Third
1         1       1  female  38.0      1      0  71.2833        C  First
2         1       3  female  26.0      0      0   7.9250        S  Third
3         1       1  female  35.0      1      0  53.1000        S  First
4         0       3    male  35.0      0      0   8.0500        S  Third

     who  adult_male deck  embark_town alive  alone
0    man        True  NaN  Southampton    no  False
1  woman       False    C    Cherbourg   yes  False
2  woman       False  NaN  Southampton   yes   True
3  woman       False    C  Southampton   yes  False
4    man        True  NaN  Southampton    no   True
```

81

# 2.散布図と相関の調べ方- iris dataset -

## データセットの利用

```
print(iris.head())
print(iris.info())
print(iris.shape)
print(iris.ndim)
print(iris.columns)
```

```
   sepal_length  sepal_width  petal_length  petal_width species
0           5.1          3.5           1.4          0.2  setosa
1           4.9          3.0           1.4          0.2  setosa
2           4.7          3.2           1.3          0.2  setosa
3           4.6          3.1           1.5          0.2  setosa
4           5.0          3.6           1.4          0.2  setosa
<class 'pandas.core.frame.DataFrame'>
RangeIndex: 150 entries, 0 to 149
Data columns (total 5 columns):
 #   Column        Non-Null Count  Dtype
---  ------        --------------  -----
 0   sepal_length  150 non-null    float64
 1   sepal_width   150 non-null    float64
 2   petal_length  150 non-null    float64
 3   petal_width   150 non-null    float64
 4   species       150 non-null    object
dtypes: float64(4), object(1)
memory usage: 6.0+ KB
None
(150, 5)
2
Index(['sepal_length', 'sepal_width', 'petal_length', 'petal_width',
       'species'],
      dtype='object')
```

82

# 2.散布図と相関の調べ方- iris dataset -

## データセットの利用

```
%matplotlib inline
import matplotlib.pyplot as plt
import warnings
warnings.filterwarnings('ignore')
plt.style.use('ggplot')
plt.plot(iris.iloc[:,1], iris.iloc[:,2],
'ro')
plt.show()
```

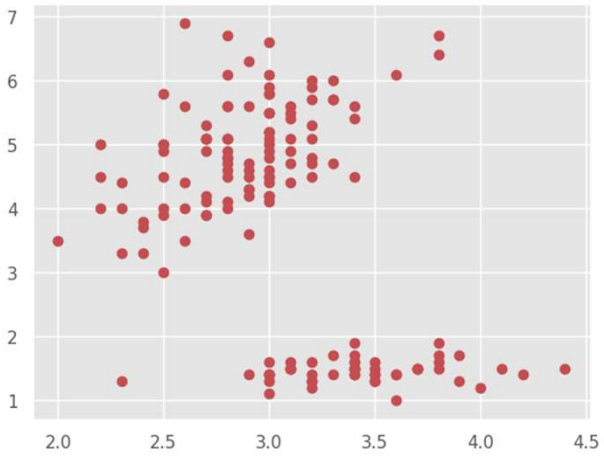


83

# 2.散布図と相関の調べ方- iris dataset -

## データセットの利用

```
iris.corr()
```

| | sepal_length | sepal_width | petal_length | petal_width |
|---|---|---|---|---|
| **sepal_length** | 1.000000 | -0.117570 | 0.871754 | 0.817941 |
| **sepal_width** | -0.117570 | 1.000000 | -0.428440 | -0.366126 |
| **petal_length** | 0.871754 | -0.428440 | 1.000000 | 0.962865 |
| **petal_width** | 0.817941 | -0.366126 | 0.962865 | 1.000000 |

84

## 2.散布図と相関の調べ方- iris dataset -

### データセットの利用

```
y_colum='sepal_width'

corr_matrix = iris.corr()
y_corr = corr_matrix[y_colum]
y_corr
```

```
sepal_length  -0.117570
sepal_width    1.000000
petal_length  -0.428440
petal_width   -0.366126
Name: sepal_width, dtype: float64
```

85

## 2.散布図と相関の調べ方- iris dataset -

### データセットの利用

```
print(iris.describe())
```

```
       sepal_length  sepal_width  petal_length  petal_width
count    150.000000   150.000000    150.000000   150.000000
mean       5.843333     3.057333      3.758000     1.199333
std        0.828066     0.435866      1.765298     0.762238
min        4.300000     2.000000      1.000000     0.100000
25%        5.100000     2.800000      1.600000     0.300000
50%        5.800000     3.000000      4.350000     1.300000
75%        6.400000     3.300000      5.100000     1.800000
max        7.900000     4.400000      6.900000     2.500000
```

86

# 2.散布図と相関の調べ方 - iris dataset -

```
pg=sns.pairplot(iris)
plt.show(pg)
```

87

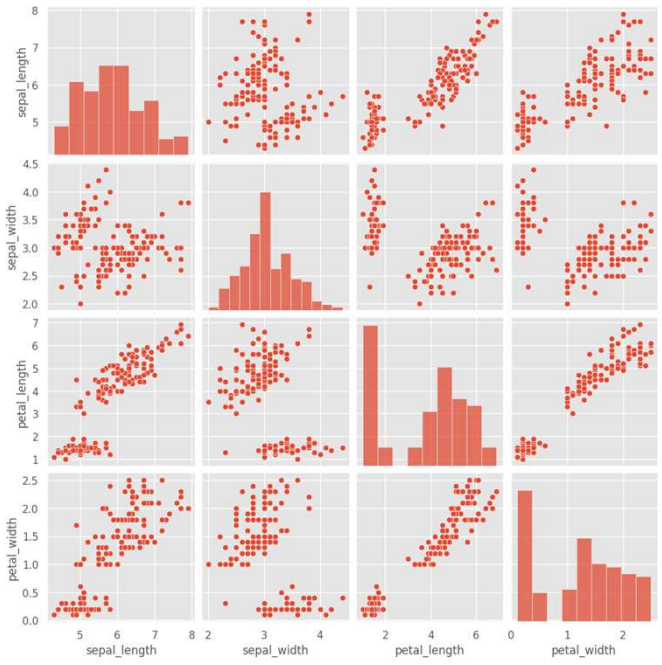


88

# 2.散布図と相関の調べ方 - iris dataset -

```
pg=sns.pairplot(iris,hue='species')
plt.show(pg)
```

89

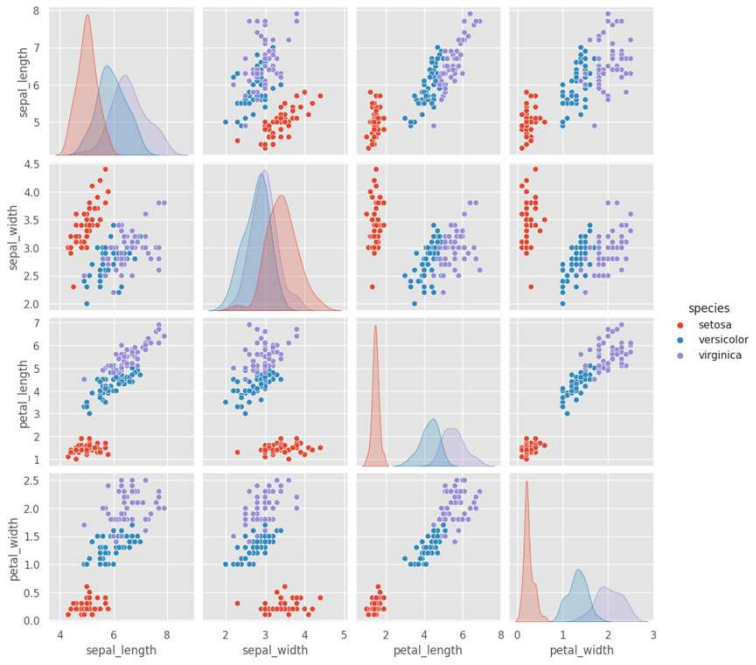


90

# 2.散布図と相関の調べ方 - iris dataset -

```
pg=sns.pairplot(iris,hue='species', kind='reg')
plt.show(pg)
```

91

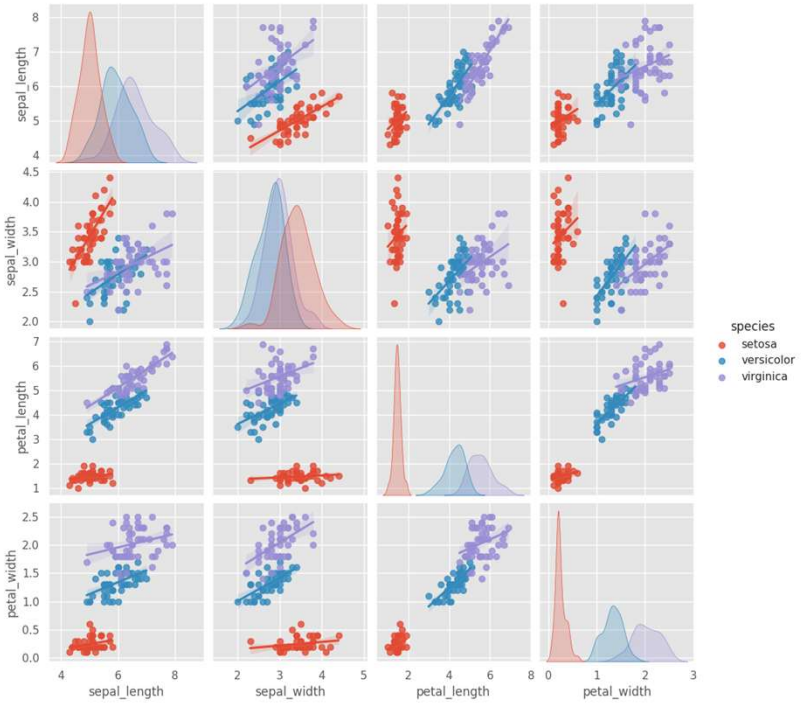


92

## 2.散布図と相関の調べ方 - iris dataset -

```
pg=sns.pairplot(iris,hue='species', kind='reg' ,plot_kws={'ci':
None,'marker': '+','scatter_kws': {'alpha': 0.4},'line_kws':
{'linestyle': '--'}})
plt.show(pg)
```

93

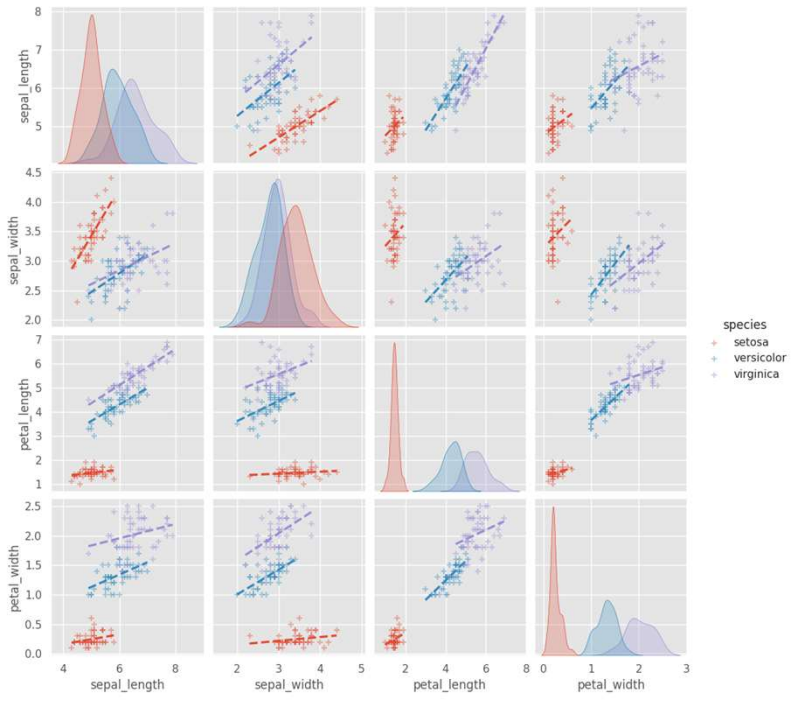


94

## 3.相関係数と因果関係の違い

### 相関係数

２つの変量の強弱を数値化したものを「相関係数」という。「類似度」の強さが「-1から1」までの範囲で表現される。正（または負）の相関関係が強いほど1（または-1）に近く，相関関係が弱いほど0に近くなる。

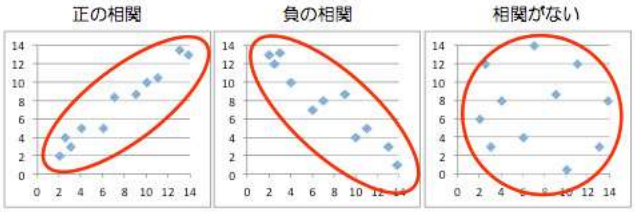


なるほど統計学園：https://www.stat.go.jp/naruhodo/10_tokucho/hukusu.html

95

## 3.相関係数と因果関係の違い

### 因果関係

「原因とそれによって生じる結果との関係」（広辞苑、第6版）を**因果関係**という。要因とアウトカムの間において、関連はみられるが要因が結果を導く関係（真の因果関係）になっていないこともあるため、その判断には注意が必要である。

（一般社団法人日本疫学会：https://jeaweb.jp/glossary/glossary015.html）

相関関係：AとBの事柄になんらかの関連性があるもの
因果関係：Aを原因としてBが変動すること

96

## 4.時系列データの見方、分析方法

### 時系列データ

時間的な順序をともないながら観測されるデータのこと。
ある一定の時間間隔で観測されたデータや、イベントが発生した時刻・頻度などが含まれる。

時系列解析：時系列データに潜む傾向や特徴を把握したり，時系列データの将来の値を予測したりする際に有効な技術

例）株価データ，天気予報の気温や降水確率などの気象データ，
人口統計データ，センサーデータ，販売数データ，など

97

## 4.時系列データの見方、分析方法

### 時系列データがもつ情報

- 長期（傾向）変動（トレンド）
  時系列の長期的傾向、時間の経過とともに増加・減少する傾向
- 循環変動（サイクル）
  傾向変動より短期的で，周期的に繰り返される変動
- 季節変動（シーズナル）
  （通常）1年を周期とする規則的な変動
- 不規則変動（ノイズ）
  上記の変動で説明できないような，短期的かつ不規則な変動

98

# 4.時系列データの見方、分析方法

## CSVファイルのマウント

```
from google.colab import files

uploaded = files.upload()
```

```
import pandas as pd
import io
                                        ※Date列を日付データとして解析する
df = pd.read_csv(io.BytesIO(uploaded['sample_covid19.csv']) ,
parse_dates=['Date'])
df
```

99

# 4.時系列データの見方、分析方法

## 折れ線グラフで表現

```
import matplotlib.pyplot as plt

plt.plot(df['Date'], df['Tokyo'])
```

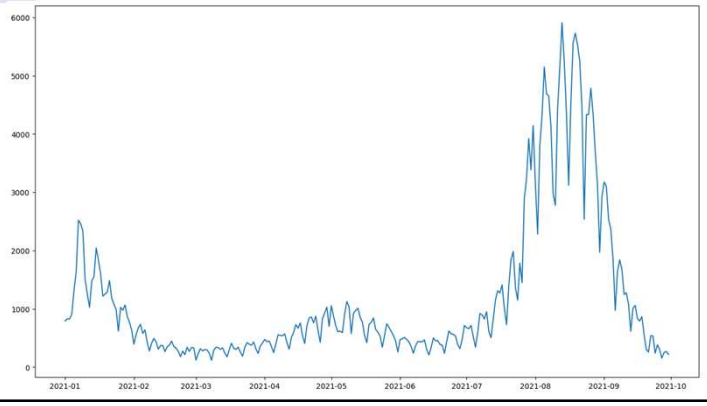


100

# 4.時系列データの見方、分析方法

## 折れ線グラフで表現

```
plt.plot(df['Date'], df['Tokyo'])
# 要素を追加すると、棒グラフが重なって表示される
plt.plot(df['Date'], df['Ibaraki'])
```

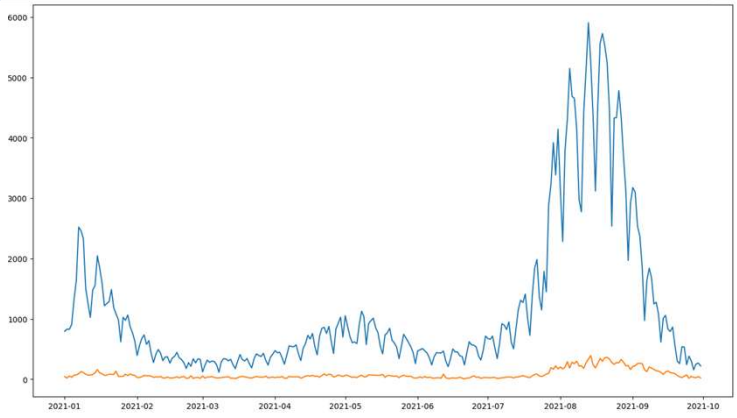


101

# 4.時系列データの見方、分析方法

## 折れ線グラフで表現

```
plt.plot(df['Date'], df['Tokyo'], label='Tokyo')
plt.plot(df['Date'], df['Ibaraki'], label='Ibaraki')
plt.plot(df['Date'], df['Hokkaido'], label='Hokkaido')
plt.plot(df['Date'], df['Kanagawa'], label='Kanagawa')
plt.plot(df['Date'], df['Aomori'], label='Aomori')
plt.legend()
```

※要素にラベルを作成し，凡例に反映させる

102

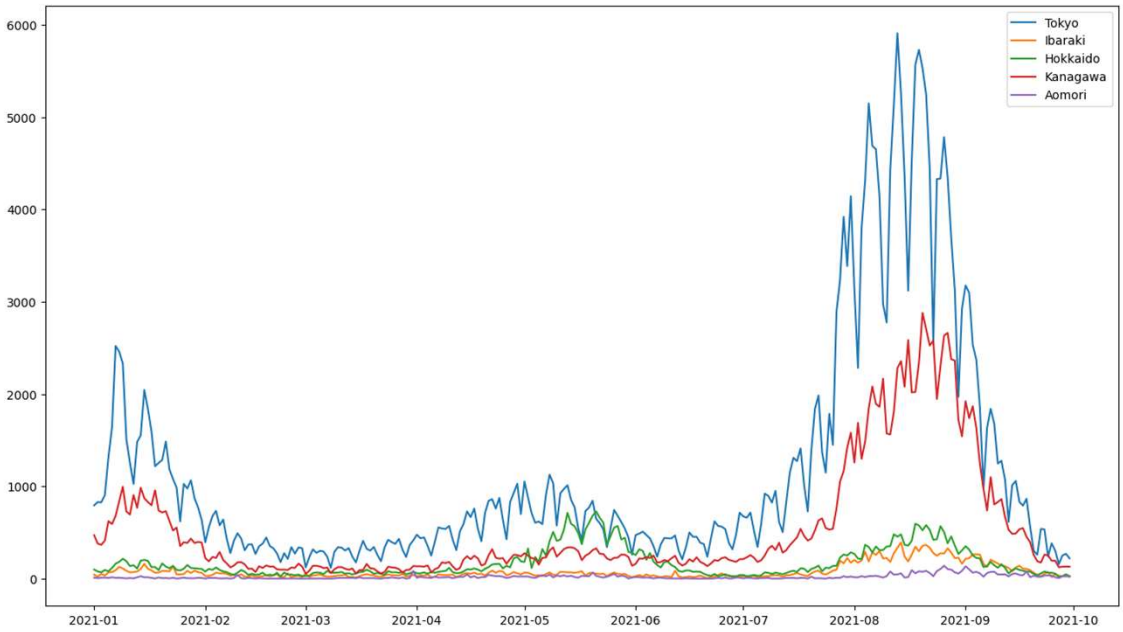


103

## 今日の内容

1 データ分析に必要な統計学の基礎を学ぶ

2 比較して2変数の関係を考える

3 **データに基づいて判断を下すための手法を学ぶ**

4 ビジネスにおける予想と分析結果の報告

104

## 第3章の内容

1. はじめに・推測統計の基本
2. 統計的推定（点推定・区間推定）
3. 統計的仮説検定
   - 基本的な仮説検定 –
   - 2つの標本問題に関する仮説検定 -

105

## 1.はじめに・推測統計の基本

**推測統計とは**

母集団から抽出した標本の情報を用いて母集団の情報を推測すること。つまり，観測対象全体の統計的性質を，その観測対象の一部分のみを使って推測する。

母集団（population）：推測したい観測対象全体のこと
標本（sample）：推測に使う観測対象の一部分
標本抽出（sampling）：母集団から標本を取り出すこと
推定量（estimator）：推定に用いられる統計量
推定値（estimate）：標本データを用いて計算した結果，推定量の実現値

106

## 2.統計的推定（点推定・区間推定）

### 基本的な分布

- 正規分布
  - 統計解析において最もよく使われ，重要な推定や検定の理論は全て正規分布を基礎にしていると言っても過言ではない。
  - 自然界の多くの現象を表現できる連続分布（確率分布）。
  - 18世紀にガウス（Gauss）によって誤差の研究から誘導されたものでガウス分布（Gaussian distribution）とも呼ばれる。

107

## 2.統計的推定（点推定・区間推定）

### 基本的な分布

- 確率密度関数（probability density function, pdf）
  - 連続型確率変数がある値をとるという事象の確率の密度を表す関数

ある事象が起きる確率が決まっているという性質をもつ変数
→確率変数（random variable）

確率変数がどのような値になるかという法則性を与えるもの
→確率分布（probability distribution）
※母集団のばらつき具合を確率分布としてとらえる

108

# 2.統計的推定（点推定・区間推定）

## 基本的な分布

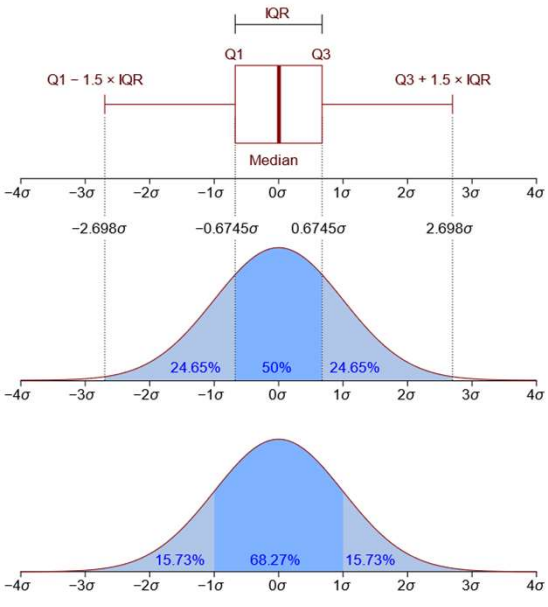


出典：Wikipedia（確率密度関数）

109

# 2.統計的推定（点推定・区間推定）

## 基本的な分布（正規分布：確率密度関数）

```
import matplotlib.pyplot as plt
import numpy as np
from scipy.stats import norm
```

※必要なパッケージ等の読み込み

```
norm.pdf(0)
```

```
0.3989422804014327
```

0が発生する確率

110

## 2.統計的推定（点推定・区間推定）

### 基本的な分布（正規分布：確率密度関数）

```
x = np.linspace(-4, 4, 100)
```

-4から4までの区間で100個の値で近似

```
y_pdf = norm.pdf(x)
```

```
plt.plot(x,y_pdf)
plt.xlabel('x')
plt.ylabel('p')
plt.title('Standart Normal Distribution')
pass
```

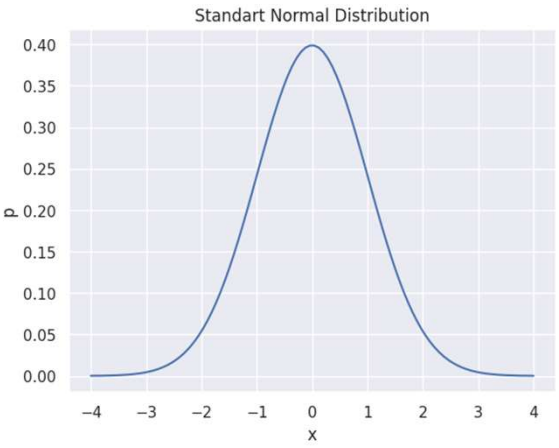


111

## 2.統計的推定（点推定・区間推定）

### 基本的な分布（正規分布：累積分布関数）

```
y_cdf = norm.cdf(x)
```

Cumulative Distribution Function

```
plt.plot(x, y_cdf)
plt.xlabel('x')
plt.ylabel('P')
plt.title('Cumulative Distribution
Function')
pass
```

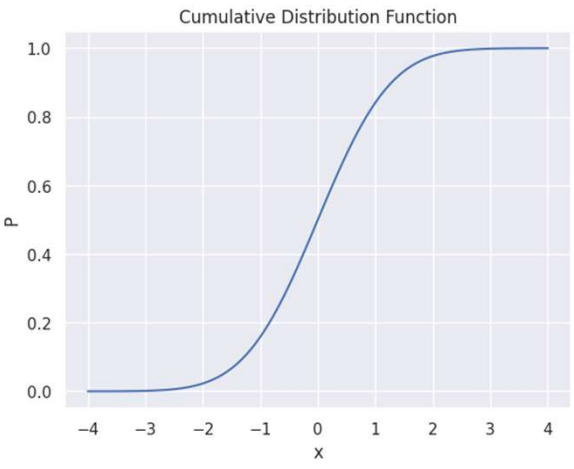


112

## 2.統計的推定（点推定・区間推定）

### 基本的な分布（正規分布：累積分布関数）

```
norm.cdf(0)
```

0以下を取る確率
（平均0を中心に左右対称のため）

```
0.5
```

```
norm.cdf(-4)
```

xが-4以下の場合

```
3.167124183311986e-05
```

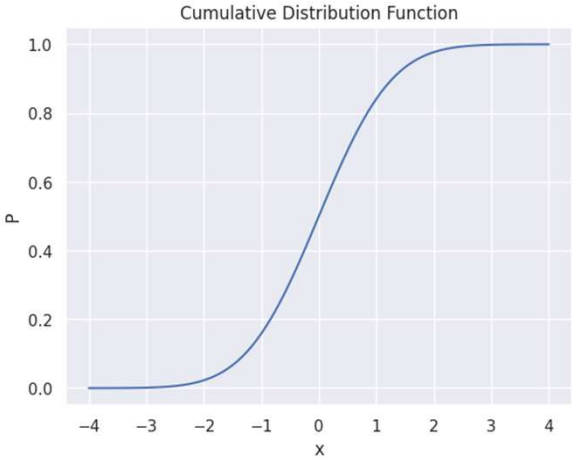


113

## 2.統計的推定（点推定・区間推定）

### 基本的な分布（正規分布：パーセント・ポイント関数）

```
p = np.linspace(0,1,100)
y_ppf = norm.ppf(p)
```

Percent Point Function

```
plt.plot(p,y_ppf)
plt.xlabel('P')
plt.ylabel('x')
plt.title('Percent Point Function')
pass
```

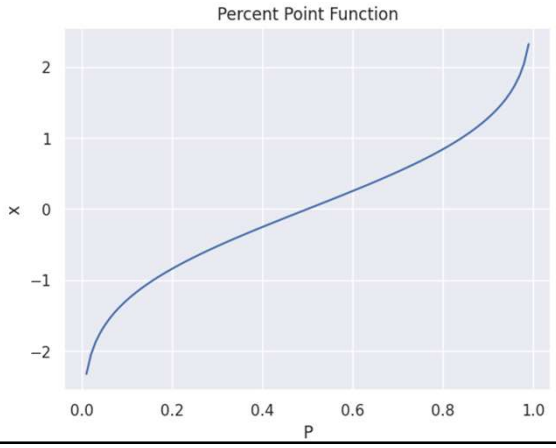


114

## 2.統計的推定（点推定・区間推定）

### 基本的な分布（正規分布：パーセント・ポイント関数）

```
norm.ppf(0.5)
```

P=0.5の場合

```
0.0
```

```
norm.ppf(0.025)
```

P=0.025の場合

```
-1.9599639845400545
```

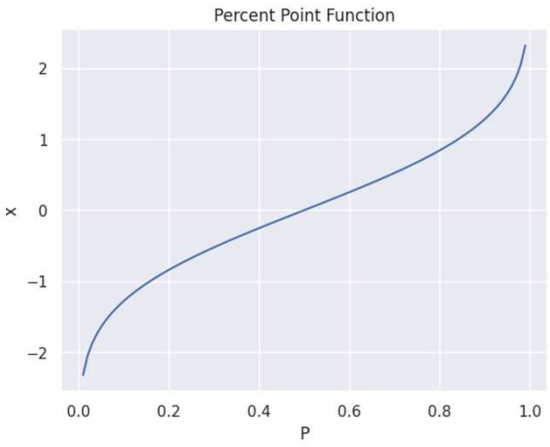


115

## 2.統計的推定（点推定・区間推定）

### 基本的な分布（正規分布：ランダム変数生成関数）

```
y_rvs = norm.rvs(size=10_000)
```

10,000個のランダム変数を生成

```
plt.hist(y_rvs, bins=30)
pass
```

bins=表示する棒の数

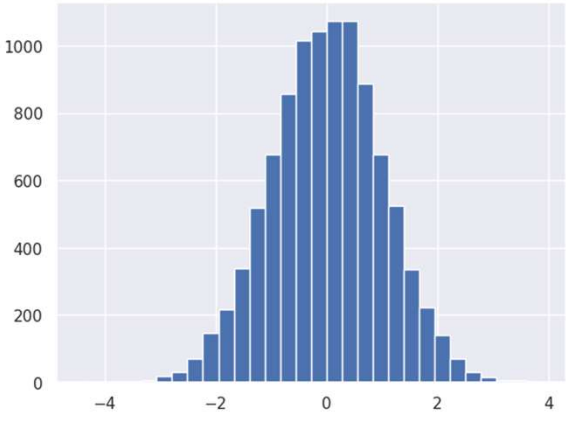


116

# 2.統計的推定（点推定・区間推定）

## 基本的な分布（正規分布：ランダム変数生成関数）

```
from scipy.stats import gaussian_kde
kde = gaussian_kde(y_rvs)
plt.plot(x, kde(x))
pass
```

サブパッケージの読み込みと
y_rvsから確率密度関数を推定

カーネル密度推定：
統計学において、確率変数の確率密度関数を推定するノンパラメトリック手法のひとつ

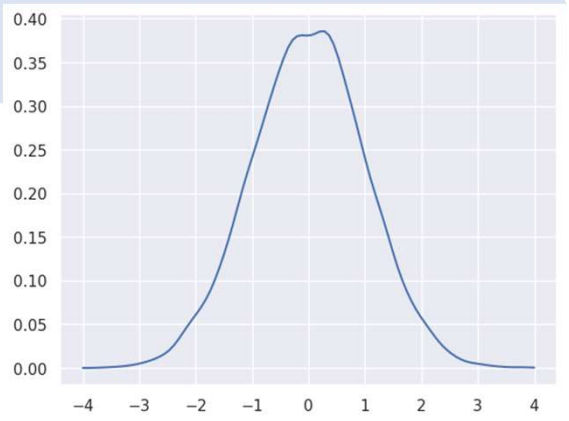


117

# 2.統計的推定（点推定・区間推定）

## 基本的な分布（正規分布：ランダム変数生成関数）

```
plt.hist(y_rvs, bins=30, density=True)
plt.plot(x, kde(x))
pass
```

density=Trueでplt.histとplt.plotの
カーネル密度関数が同じスケールに

推定なので標準正規分布の確率密度と全く同じにならないが，非常に近い

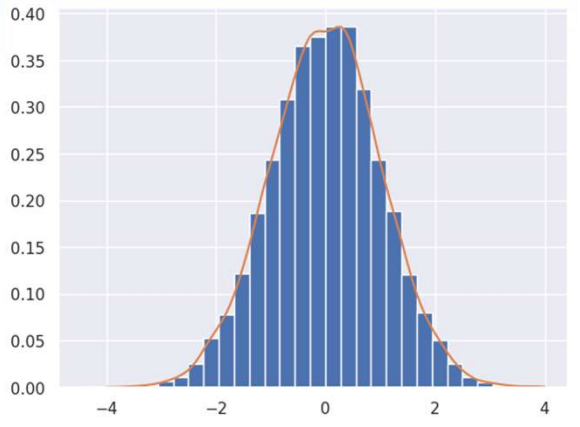


118

# 2.統計的推定（点推定・区間推定）

## 基本的な分布（ t 分布）

```
from scipy.stats import t
x = np.linspace(-4, 4, 100)
y = t.pdf(x, df=1)
plt.plot(x,y)
pass
```

dfn:自由度（degree of freedom）

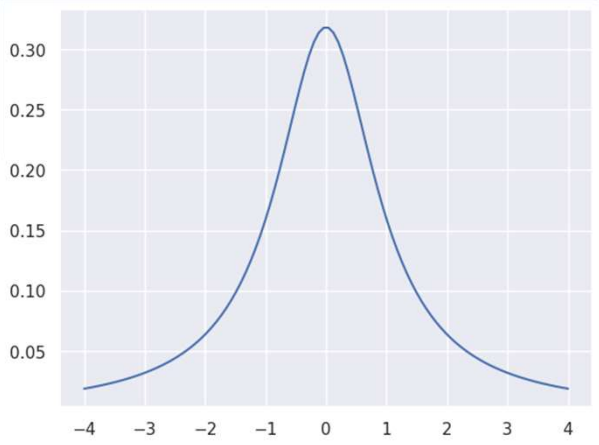


母分散が未知の場合の母平均に関する推論
・母集団が正規分布に従う
・σが未知
・n<30

119

# 2.統計的推定（点推定・区間推定）

## 基本的な分布（ t 分布）

```
t.cdf(-3, df=1)
```

```
0.10241638234956672
```

自由度1の場合にxが-3以下となる確率

```
1-t.cdf(3, df=1)
```

```
0.10241638234956672
```

自由度1の場合にxが3以上となる確率

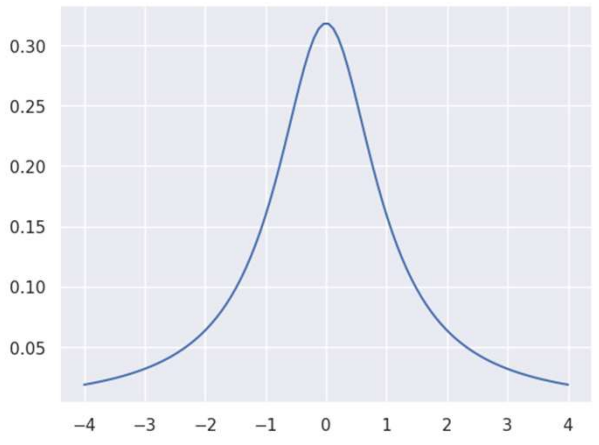


120

# 2.統計的推定（点推定・区間推定）

## 基本的な分布（ t 分布）

```
!pip install japanize-matplotlib
```
japanize-matplotlibのインストール

```
import japanize_matplotlib
```
インポート

```
x = np.linspace(-4, 4, 100)
plt.plot(x, t.pdf(x, 30), label=r'$t$ 分布')
plt.plot(x, norm.pdf(x), label='標準正規分布')
plt.legend()
pass
```
自由度30で標準正規分布と重ねてプロット

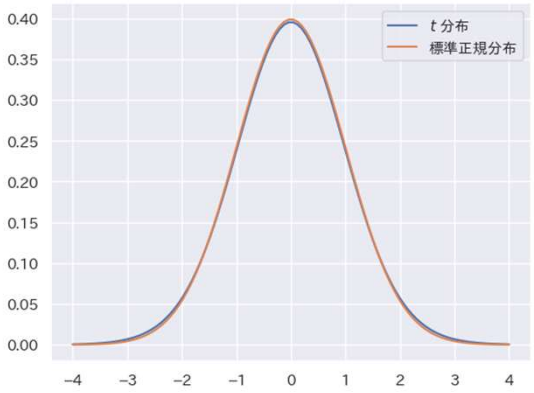


121

# 2.統計的推定（点推定・区間推定）

## 基本的な分布（$X^2$分布）

```
from scipy.stats import chi2
x = np.linspace(0,12,100)
y = chi2.pdf(x, df=3)
plt.plot(x,y)
pass
```

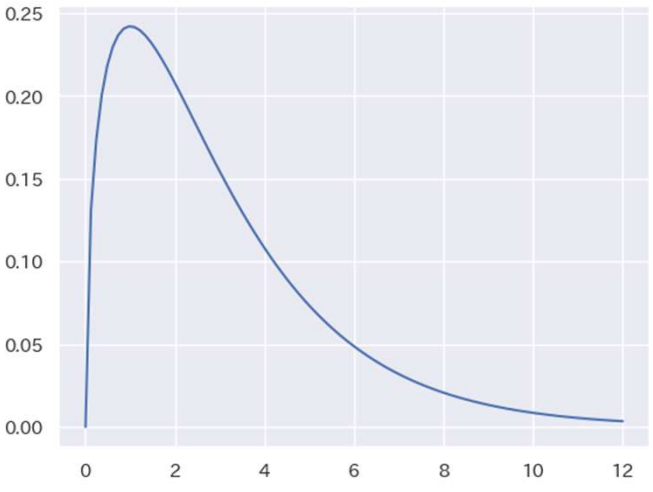


122

# 2.統計的推定（点推定・区間推定）

## 基本的な分布（X²分布）

```
chi2.cdf(1, df=3)
```

```
0.19874804309879915
```

自由度3の場合にxが1以下の確率

```
1-chi2.cdf(10, df=3)
```

```
0.0185661354630432
```

自由度3の場合にxが10以上となる確率

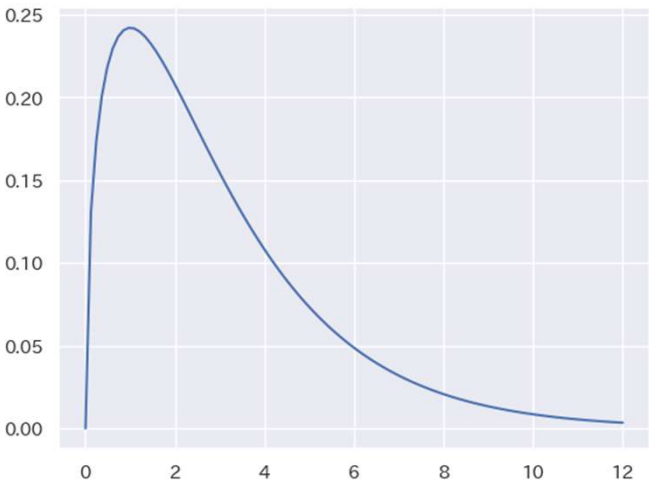


123

# 2.統計的推定（点推定・区間推定）

## 基本的な分布（F分布）

```
from scipy.stats import f
x = np.linspace(0.001, 5, 1000)
y = f.pdf(x, dfn=5, dfd=1)
plt.plot(x, y)
pass
```

dfn:分子の自由度
（numerator degree of freedom）
dfd:分母の自由度
（denominator degree of freedom）

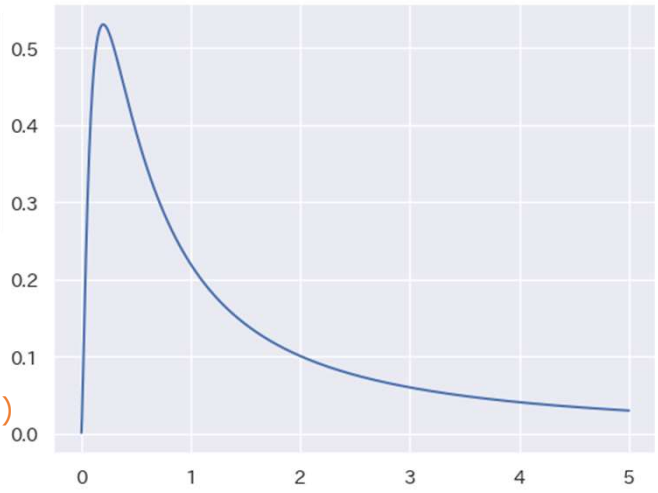


124

## 2.統計的推定（点推定・区間推定）

### 基本的な分布（$X^2$分布）

```
f.cdf(0.1, dfn=5, dfd=1)
```

```
0.02503101581845294
```

dfn=5, dfd=1の場合にxが0.1以下の確率

```
1-f.cdf(5, dfn=5, dfd=1)
```

```
0.32657156446244606
```

dfn=5, dfd=1の場合にxが5以上の確率

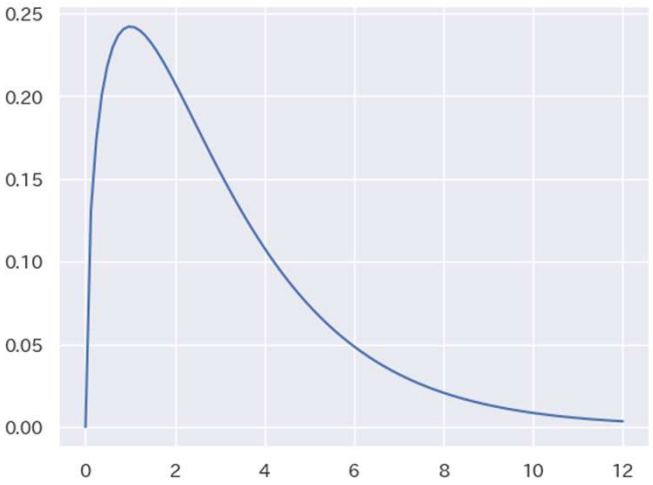


125

## 2.統計的推定（点推定・区間推定）

### 点推定

- 母集団分布のパラメータである1つの値として指定する推定方法

### 区間推定

- 推定値に幅を持たせた推定方法

126

## 2.統計的推定（点推定・区間推定）

### 点推定

- 架空のデータのサイズ10，このデータは正規母集団からの無作為標本であると仮定する

```
weight = [8.033, 7.298, 6.223, 7.538, 2.546, 9.251, 5.006, 5.769, 9.628, 6.512]
```

- 母平均を推定する場合は標本平均を，母分散を推定する場合は不偏分散を，推定量として扱う

127

## 2.統計的推定（点推定・区間推定）

### 点推定

- 母平均を推定する場合は標本平均を，母分散を推定する場合は不偏分散を，推定量として扱う

```
x_bar = np.mean(weight)
u2 = np.var(weight, ddof=1)

print('標本平均 : ', round(x_bar, 3))
print('不偏分散 : ', round(u2, 3))
```

```
標本平均: 6.78
不偏分散: 4.345
```

128

## 2.統計的推定（点推定・区間推定）

### 区間推定（用語の整理）

- 信頼係数
  - 区間推定の幅における信頼の度合いを確率で表現したもの
- 信頼区間
  - ある信頼係数を満たす区間
- 信頼限界
  - 信頼区間の下限値（下側信頼限界）と上限値（上側信頼限界）

129

## 2.統計的推定（点推定・区間推定）

### 区間推定（手順）

- 信頼区間95%として，母平均の区間推定
  - 母分散が明らかであれば標準正規分布が利用できるが普通はない
    → t 分布を活用する

130

# 2.統計的推定（点推定・区間推定）

## 区間推定（手順）

1. 標本平均$\bar{X}$と標準誤差$SE$を計算
2. サンプルサイズを$n$とするとき，自由度$n-1$のｔ分布における2.5%点と97.5%点を計算する
   - ｔ分布における2.5%点を$t_{0.025}$と表記
   - ｔ分布における97.5%点を$t_{0.975}$と表記
   - ｔ分布における従う確率変数が$t_{0.025}$以上$t_{0.975}$以下になる確率は95%
   - このとき95%が信頼係数となる
3. $\bar{X} - t_{0.975} * SE$が下側信頼限界となる
4. $\bar{X} - t_{0.025} * SE$が上側信頼限界となる

131

# 2.統計的推定（点推定・区間推定）

## 区間推定

```
n = len(weight)
df = n - 1
u = np.std(weight, ddof=1)
se = u / np.sqrt(n)

print('サンプルサイズ  : ', n)
print('自由度          : ', df)
print('標準偏差        : ', round(u, 3))
print('標準誤差        : ', round(se, 3))
print('標本平均        : ', round(x_bar, 3))
```

区間推定に必要なのは
自由度，標本平均，標準誤差
標本平均は計算済み

```
サンプルサイズ : 10
自由度       : 9
標準偏差     : 2.085
標準誤差     : 0.659
標本平均     : 6.78
```

132

## 2.統計的推定（点推定・区間推定）

### 区間推定

```
t_025 = stats.t.ppf(q=0.025, df=df)
t_975 = stats.t.ppf(q=0.975, df=df)

print('t分布の2.5%点　: ', round(t_025, 3))
print('t分布の97.5%点 : ', round(t_975, 3))
```

自由度n-1の t 分布における2.5%点と97.5%点を計算

```
t分布の2.5%点 : -2.262
t分布の97.5%点 : 2.262
```

133

## 2.統計的推定（点推定・区間推定）

### 区間推定

```
lower_mu = x_bar - t_975 * se
upper_mu = x_bar - t_025 * se

print('下限信頼区間： ', round(lower_mu, 3))
print('上限信頼区間： ', round(upper_mu, 3))
```

t 分布は左右対称なので，
$t_{0.025}$ - $t_{0,975}$で信頼区間を計算

```
下限信頼区間: 5.289
上限信頼区間: 8.272
```

母平均の95%信頼区間は，5.289から8.272となった

134

## 2.統計的推定（点推定・区間推定）おまけ問題

### 区間推定

1. 標本$n = 10$
   405g, 395g, 374g, 410g, 417g, 426g, 383g, 398g, 390g, 402g
   母標準偏差：15g
   信頼水準95%で信頼区間を推定せよ

2. 工場で生産している製品Aがある
   以下のデータがわかっている
   標本$n = 100$，標本平均=150g，母分散＝$15^2$g
   母平均$\mu$を信頼水準95%で信頼区間を推定せよ

135

## 3.統計的仮説検定

### 統計的仮説検定

- データを使って何かを判断したいときに使われる手法
- さまざまな種類があり判断する対象も手法によって
  さまざま，単に検定と呼ぶ場合もある

- 統計的推定 → 母集団分布のパラメータを言い当てる試み
- 統計的検定 → 母集団のパラメータについて判断を下す
  例）「母平均が50か，あるいは50ではないか」を判断

136

## 3.統計的仮説検定 - 基本的な仮説検定 -

### t検定（母平均に関する1標本のt検定）

- データは正規母集団からの無作為標本，と仮定
- 平均値が「ある値」と異なると言えるかどうか，を判断

例

内容量が135gと書かれたスナック菓子，測ってみると134gの場合もあれば，136gの場合もある。工場の機械に問題がないか検査する必要がある。
「スナック菓子の内容量の母平均が135gと異なっていると言えるかどうか」という判断をサポート。

137

## 3.統計的仮説検定 - 基本的な仮説検定 -

### 仮説検定の流れ

1. 仮説を立てる
2. 有意水準を決める
3. 検定統計量を計算
4. p値を計算
5. p値より有意水準が大きいか
   - （Yes）帰無仮説を採択
   - （No）帰無仮説を棄却

138

## 3.統計的仮説検定 - 基本的な仮説検定 -

**仮説検定の流れ**

1. 仮説を立てる
2. 有意水準を決める
3. 検定統計量を計算
4. p値を計算
5. p値より有意水準が大きいか
   - （Yes）帰無仮説を採択
   - （No）帰無仮説を棄却

139

## 3.統計的仮説検定 - 基本的な仮説検定 -

**1. 仮説を立てる**

- 帰無仮説$H_0$：スナック菓子の母平均は135gである
- 対立仮説$H_1$：スナック菓子の母平均は135gと異なる

- 帰無仮説が棄却されたならば，有意差あり，つまり「スナック菓子の母平均は135gと異なる」と判断する
  （135gより大きい or 少ない，ではない）

140

## 3.統計的仮説検定 - 基本的な仮説検定 -

**仮説検定の流れ**

1. 仮説を立てる
2. 有意水準を決める
3. 検定統計量を計算
4. p値を計算
5. p値より有意水準が大きいか
   - （Yes）帰無仮説を採択
   - （No）帰無仮説を棄却

141

## 3.統計的仮説検定 - 基本的な仮説検定 -

**有意水準を決める**

- 有意である：偶然ではなく，何か意味があるということ
- 帰無仮説が間違っていると判断（棄却）する区間のことを棄却域（rejection region），採択される区間を採択域（acceptance region）といい，この境の基準となる確率のこと
- つまり，帰無仮説を棄却する基準
- 伝統的に$\alpha$と表記し，5%や1%が使われることが多い

142

## 3.統計的仮説検定 - 基本的な仮説検定 -

**有意水準を決める（危険率）**

- 第一種の過誤：帰無仮説が正しいのに誤って帰無仮説を棄却してしまうこと
- 第二種の過誤：帰無仮説が間違っているのに，誤って帰無仮説を採択してしまうこと

- 有意水準は第一の過誤を許容できる確率

143

## 3.統計的仮説検定 - 基本的な仮説検定 -

**仮説検定の流れ**

1. 仮説を立てる
2. 有意水準を決める
3. 検定統計量を計算
4. p値を計算
5. p値より有意水準が大きいか
   - （Yes）帰無仮説を採択
   - （No）帰無仮説を棄却

144

## 3.統計的仮説検定 - 基本的な仮説検定 -

### 検定統計量を計算（準備）

```
import numpy as np
import pandas as pd
from scipy import stats

food = [111, 124, 125, 126, 127, 134, 135, 136, 139, 141]
```

- 帰無仮説$H_0$：スナック菓子の母平均は135gである
- 対立仮説$H_1$：スナック菓子の母平均は135gと異なる
- 有意水準は5%

145

## 3.統計的仮説検定 - 基本的な仮説検定 -

### 標本平均

```
x_bar = np.mean(food)
round(x_bar, 3)
```

```
129.8
```

### 自由度

```
n = len(food)
df = n - 1
df
```

```
9
```

146

## 3.統計的仮説検定 - 基本的な仮説検定 -

### 標準誤差（標準偏差 / サンプルサイズの平方根）

```
u = np.std(food, ddof=1)
se = u / np.sqrt(n)
round(se, 3)
```

```
2.839
```

### t値の計算

```
t_sample = (x_bar - 135) / se
round(t_sample, 3)
```

```
-1.831
```

147

## 3.統計的仮説検定 - 基本的な仮説検定 -

### 棄却域の計算

```
round(stats.t.ppf(q=0.025, df=df), 3)
```

```
-2.262
```

```
round(stats.t.ppf(q=0.975, df=df), 3)
```

```
2.262
```

$-t_{0.025} < |t_sample| < t_{0.975}$の範囲が採択域となる，
よって帰無仮説を棄却することはできない

148

# 3.統計的仮説検定 - 基本的な仮説検定 -

## 仮説検定の流れ

1. 仮説を立てる
2. 有意水準を決める
3. 検定統計量を計算
4. p値を計算
5. p値より有意水準が大きいか
   - （Yes）帰無仮説を採択
   - （No）帰無仮説を棄却

149

# 3.統計的仮説検定 - 基本的な仮説検定 -

## p値の計算

```
p_value = stats.t.cdf(-np.abs(t_sample), df=df) * 2
round(p_value, 3)
```

```
0.1
```

p値が有意水準0.05を上回っているので，帰無仮説を支持する確率が高い

スナック菓子の平均重量は135gと有意に異なっていないと判断することができる

150

# 3.統計的仮説検定 - 基本的な仮説検定 -

## stats.ttest_1samp関数（1標本のt検定）

```
stats.ttest_1samp(food, 135)
```

```
TtestResult(statistic=-1.831369433567421, pvalue=0.10027730072021666, df=9)
```

statisticがt値，pvalueがp値

151

# 3.統計的仮説検定 - 2つの標本問題に関する仮説検定 -

## 2郡のデータに対するt検定

- 2つの変数の間で平均値に差があるかどうか，を判断

例

あるボディビルにより体重の増減がおこるかどうか調べるために，10人についてその効果を調べる場合など，
「同じ対象を異なった条件で２回測定して，その違いをみる」とった場合

152

## 3.統計的仮説検定 - 2つの標本問題に関する仮説検定 -

### 2郡のデータに対するt検定

| | 正規分布を仮定できる | 正規分布を仮定できない |
|---|---|---|
| 対応あり | 対応のあるｔ検定※1 | ウィルコクソンの符号付き順位検定 |
| 対応なし | 対応のないｔ検定※2 | マン・ホイットニーのU検定 |

※1　「データの差」を取ってから母平均に関する１標本のｔ検定
※2　「平均値の差」に注目する

153

## 3.統計的仮説検定 - 2つの標本問題に関する仮説検定 -

### 1. 仮説を立てる

- 帰無仮説$H_0$：ボディビルにより体重の増減は起こっていない
- 対立仮説$H_1$：ボディビルにより体重の増減は起こっている

### 2. 有意水準を決める

- 有意水準5%とし，p値が0.05を下回れば，帰無仮説が棄却され，ボディビルでの体重増減への有意な変化が認められると主張できる

154

# 3.統計的仮説検定 - 2つの標本問題に関する仮説検定 -

## 3. 検定統計量を計算する

| No. | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | 10 | 平均 |
|---|---|---|---|---|---|---|---|---|---|---|---|
| 前 | 57.6 | 88.5 | 73.5 | 77.1 | 64.9 | 93.0 | 76.2 | 79.4 | 89.4 | 61.7 | |
| 後 | 61.2 | 90.7 | 73.4 | 82.6 | 66.7 | 93.7 | 78.0 | 84.4 | 88.0 | 64.0 | |
| 後－前 | 3.6 | 2.2 | -0.1 | 5.5 | 1.8 | 0.7 | 1.8 | 5 | -1.4 | 2.3 | 2.14 |

155

# 3.統計的仮説検定 - 2つの標本問題に関する仮説検定 -

## 3. 検定統計量を計算する（ライブラリの読み込み等）

```
from google.colab import files
uploaded = files.upload()
```

```
import numpy as np
import pandas as pd
from scipy import stats
```

```
bodybuilding = pd.read_csv('sample_t-test.csv')
print(bodybuilding)
```

```
    person bodybuilding  weight
0        1     before    57.6
1        2     before    88.5
2        3     before    73.5
3        4     before    77.1
4        5     before    64.9
5        6     before    93.0
6        7     before    76.2
7        8     before    79.4
8        9     before    89.4
9       10     before    61.7
10       1      after    61.2
11       2      after    90.7
12       3      after    73.4
13       4      after    82.6
14       5      after    66.7
15       6      after    93.7
16       7      after    78.0
17       8      after    84.4
18       9      after    88.0
19      10      after    64.0
```

156

# 3.統計的仮説検定 - 2つの標本問題に関する仮説検定 -

## 3. 検定統計量を計算する

```
before = bodybuilding.query('bodybuilding == "before"')['weight']
after = bodybuilding.query('bodybuilding == "after"')['weight']
```

ボディビル前と後の標本平均

```
before = np.array(before)
after = np.array(after)
```

アレイに変換

```
diff = after - before
diff
```

差を計算

```
array([ 3.6,  2.2, -0.1,  5.5,  1.8,  0.7,  1.8,  5. , -1.4,  2.3])
```

157

# 3.統計的仮説検定 - 2つの標本問題に関する仮説検定 -

## 対応のない t 検定（不等分散）

```
#平均値
x_bar_bef = np.mean(before)
x_bar_aft = np.mean(after)

#分散
u2_bef = np.var(before, ddof=1)
u2_aft = np.var(after, ddof=1)

#サンプルサイズ
m = len(before)
n = len(after)

#t値
t_value = (x_bar_aft - x_bar_bef) / np.sqrt((u2_bef/m + u2_aft/n))
round(t_value, 3)
```

```
0.406
```

158

## 3.統計的仮説検定 - 2つの標本問題に関する仮説検定 -

### 対応のない t 検定（不等分散）

```
df = (u2_bef / m + u2_aft / n)**2 / ((u2_bef / m)**2 / (m-1) + (u2_aft / n)**2 / (n-1))
round(df, 3)
```

```
17.963
```

```
p_value = stats.t.cdf(-np.abs(t_value), df=df)*2
round(p_value,5)
```

```
0.68988
```

```
stats.ttest_ind(after, before, equal_var=False)
```

```
TtestResult(statistic=0.4055321209937369, pvalue=0.6898758363640115, df=17.963028980728833)
```

159

## 今日の内容

1. データ分析に必要な統計学の基礎を学ぶ
2. 比較して2変数の関係を考える
3. データに基づいて判断を下すための手法を学ぶ
4. ビジネスにおける予想と分析結果の報告

160

## 第4章の内容

1. 回帰分析による予想
2. 決定木による予想
3. クラスター分析
   – その1 –
   – その2 –

161

## 1.回帰分析による予想

**回帰分析とは**

- 因果関係が疑われる複数の変数を使って，ある変数から他の変数の値を予測する手法
- 原因となる変数のことを説明変数，結果となる変数のことを応答変数という
- 説明変数と応答変数はそれぞれ独立変数と従属変数という
- 説明変数が数量データであるモデルを用いた分析手法
  （説明変数が複数あるものを重回帰分析と呼ぶ）

162

# 1.回帰分析による予想

## 回帰分析

```
import seaborn as sns
x = [1, 2, 3, 4, 5, 6, 7]
y = [1, 3, 2, 5, 4, 7, 6]
sns.regplot(x=x, y=y)
```
散布図

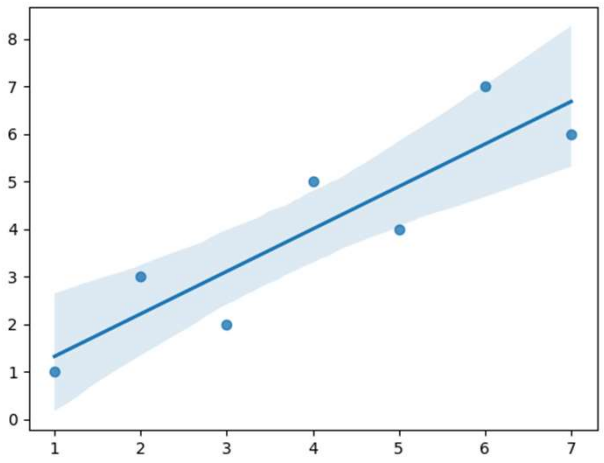


163

# 1.回帰分析による予想

## 回帰分析

```
!pip install pingouin
```
Pingouin（ピングイン）というパッケージをインストール

```
import pingouin as pg
pg.corr(x, y)
```

R:相関係数

| | n | r | CI95% | p-val | BF10 | power |
|---|---|---|---|---|---|---|
| pearson | 7 | 0.892857 | [0.43, 0.98] | 0.006807 | 8.961 | 0.854032 |

p値

95%信頼区間

```
pg.linear_regression(x, y)
```

| | names | coef | se | T | pval | r2 | adj_r2 | CI[2.5%] | CI[97.5%] |
|---|---|---|---|---|---|---|---|---|---|
| 0 | Intercept | 0.428571 | 0.900680 | 0.475831 | 0.654258 | 0.797194 | 0.756633 | -1.886700 | 2.743843 |
| 1 | x1 | 0.892857 | 0.201398 | 4.433293 | 0.006807 | 0.797194 | 0.756633 | 0.375147 | 1.410568 |

傾き　　p値　$R^2$（相関係数の二乗）　95%信頼区間

164

# 1.回帰分析による予想

## 回帰分析と結果の可視化

既知のデータ
sales_data.csv

| | A | B |
|---|---|---|
| 1 | temperature | sales |
| 2 | 4.7 | 507 |
| 3 | 5.4 | 416 |
| 4 | 11.5 | 607 |
| 5 | 17 | 746 |
| 6 | 19.8 | 894 |
| 7 | 22.4 | 1021 |
| 8 | 28.3 | 1506 |
| 9 | 28.1 | 1443 |
| 10 | 22.9 | 861 |
| 11 | 19.1 | 640 |
| 12 | 14 | 492 |
| 13 | 8.3 | 537 |
| 14 | 5.6 | 494 |
| 15 | 7.2 | 423 |
| 16 | 10.6 | 542 |
| 17 | 13.6 | 667 |
| 18 | 20 | 1000 |
| 19 | 21.8 | 991 |
| 20 | 24.1 | 1236 |
| 21 | 28.4 | 1513 |
| 22 | 25.1 | 996 |
| 23 | 19.4 | 724 |
| 24 | 13.1 | 531 |
| 25 | 8.5 | 584 |
| 26 | 7.1 | 510 |
| 27 | 8.3 | 482 |
| 28 | 10.7 | 610 |

予測対象データ
sales_future.csv

| | A | B |
|---|---|---|
| 1 | temperature | |
| 2 | 12.6 | |
| 3 | 18.7 | |
| 4 | 10.2 | |
| 5 | 15.1 | |
| 6 | 20.5 | |
| 7 | | |
| 8 | | |
| 9 | | |
| 10 | | |
| 11 | | |
| 12 | | |
| 13 | | |
| 14 | | |
| 15 | | |
| 16 | | |
| 17 | | |
| 18 | | |
| 19 | | |
| 20 | | |
| 21 | | |
| 22 | | |
| 23 | | |
| 24 | | |
| 25 | | |
| 26 | | |
| 27 | | |

sales_future

**一般社団法人　日本アイスクリーム協会**
（https://www.icecream.or.jp/about/）と
**国土交通省気象庁**
（https://www.data.jma.go.jp/obd/stats/etrn/view/monthly_s3.php?prec_no=44&block_no=47662）のデータを合わせて作成した

sales_data.csvに基づいて回帰分析を行い，
sales_future.csvに対して売上予測

165

# 1.回帰分析による予想

## 回帰分析と結果の可視化

```
from google.colab import files
uploaded = files.upload()
```

ファイルの読み込み等

```
import pandas as pd

df = pd.read_csv('sample_sales_data.csv')
df_test = pd.read_csv('sample_sales_future.csv')
```

166

# 1.回帰分析による予想

## 回帰分析と結果の可視化

```
x_name = "temperature"        xとyに分離
y_name = "sales"
x = df[x_name]
y = df[y_name]

import statsmodels.api as sm   回帰分析の実行
model = sm.OLS(y, sm.add_constant(x))
result = model.fit(disp=0)
print(result.summary())
```

求めたいもの（目的変数）が「y」で，その計算に使うもの（説明変数）が「x」
「add_constant」は切片を使う場合に指定
つまり，y=ax + b のbの項を使う場合に付ける

167

# 1.回帰分析による予想

## 回帰分析と結果の可視化

```
                            OLS Regression Results
==============================================================================
Dep. Variable:                  sales   R-squared:                       0.832
Model:                            OLS   Adj. R-squared:                  0.829
Method:                 Least Squares   F-statistic:                     287.1
Date:                Fri, 17 Nov 2023   Prob (F-statistic):           3.96e-24
Time:                        08:27:53   Log-Likelihood:                -380.86
No. Observations:                  60   AIC:                             765.7
Df Residuals:                      58   BIC:                             769.9
Df Model:                           1
Covariance Type:            nonrobust
==============================================================================
                 coef    std err          t      P>|t|      [0.025      0.975]
------------------------------------------------------------------------------
const        155.0243     44.387      3.493      0.001      66.175     243.874
temperature   41.4521      2.447     16.943      0.000      36.555      46.349
==============================================================================
Omnibus:                        0.628   Durbin-Watson:                   1.324
Prob(Omnibus):                  0.731   Jarque-Bera (JB):                0.706
Skew:                           0.048   Prob(JB):                        0.703
Kurtosis:                       2.477   Cond. No.                         44.5
==============================================================================

Notes:
[1] Standard Errors assume that the covariance matrix of the errors is correctly specified.
```

coefとconstが交わった所が切片
「155.0243」

R-squaredが$R^2$値
「0.832」

coefとtemperatureが交わった所が傾き「41.4521」

アイスクリームの売上をy,
気温をx,
y = 41.45x + 155.02
という関係があるっぽい

168

# 1.回帰分析による予想

## 回帰分析と結果の可視化（未知のデータの推測）

```
y_result=[]
for i in range(len(df_test.index)):
    y_tmp = result.params.const + result.params[x_name] *
df_test[x_name][i]
    y_result.append(y_tmp)
print(y_result)
```

Xの傾きが格納

切片が格納

```
[677.3210908376445, 930.1790552581247, 577.8359900820456, 780.9514041247264, 1004.7928808248239]
```

169

# 1.回帰分析による予想

## 回帰分析と結果の可視化（未知のデータの推測）

```
df_test_y = pd.DataFrame(y_result,columns=["y"])
df_result = pd.concat([df_test,df_test_y],axis=1)
df_result.to_csv("result.csv")
df_result
```

| | temperature | y |
|---|---|---|
| 0 | 12.6 | 677.321091 |
| 1 | 18.7 | 930.179055 |
| 2 | 10.2 | 577.835990 |
| 3 | 15.1 | 780.951404 |
| 4 | 20.5 | 1004.792881 |

読み込んだファイル（sales_future.csv）に計算結果（y列）を追記し，
csvファイルとして出力することも可能

170

# 1.回帰分析による予想

## 回帰分析と結果の可視化（プロット）

```
import matplotlib.pyplot as plt
plt.plot(x, y, 'o')
plt.plot(x, result.params.const+result.params[x_name]*x)
plt.show()
```

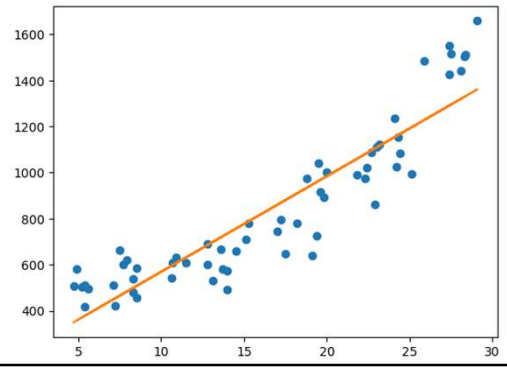


そこそこ良い感じの分析精度

171

# 2.決定木による予想

## 決定木とは（Decision Tree Analysis:DCA）

- データから分類・判別のために作られる決定木と呼ばれる樹形図を作成し，予測や検証をする分析（機械学習の1つ）
- 購買情報やアンケート結果等のさまざまなデータに対して実施することが可能
- 目的変数の予測や目的変数に影響している因子の検証等に活用

172

# 2.決定木による予想

## 決定木分析と回帰分析の違い

- どちらも目的変数を予想するモデル、ただプロセスが違う
- 計算式などを使わずにシンプルな分岐のみで予想
  （Yes or No）

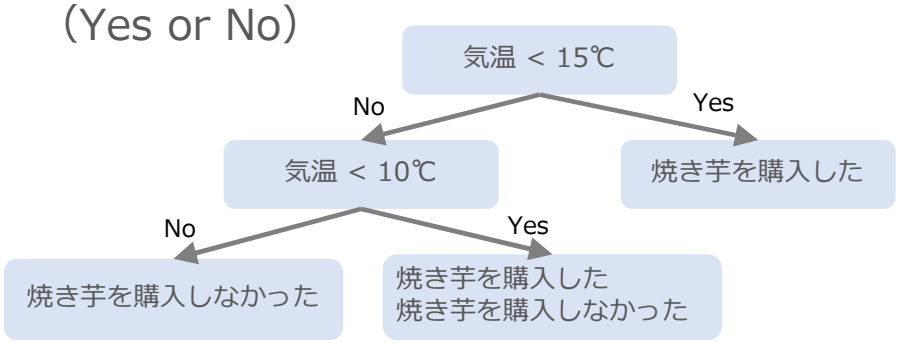


173

# 2.決定木による予想

## 流れ

- 事前準備
- 決定木の前処理
  - 説明変数（x）と目的変数（y）に分割
  - ダミー変数処理（文字列→数値）
  - 学習用-テスト用に分割
- 決定木モデルの作成と予想
  - パラメータ：max_depth（最大深度）
- 決定木の可視化（plot_tree）
  - ツリーの見方
  - パラメータ：説明変数の名前（feature_names）
  - パラメータ：目的変数の名前（class_names）
  - パラメータ：色（filled）

174

# 2.決定木による予想

## 事前準備（タイタニック号データ）

```
import seaborn as sns
import pandas as pd
from sklearn.model_selection import train_test_split
from sklearn import tree
df = sns.load_dataset('titanic')
df.head()
```

| | survived | pclass | sex | age | sibsp | parch | fare | embarked | class | who | adult_male | deck | embark_town | alive | alone |
|---|---|---|---|---|---|---|---|---|---|---|---|---|---|---|---|
| 0 | 0 | 3 | male | 22.0 | 1 | 0 | 7.2500 | S | Third | man | True | NaN | Southampton | no | False |
| 1 | 1 | 1 | female | 38.0 | 1 | 0 | 71.2833 | C | First | woman | False | C | Cherbourg | yes | False |
| 2 | 1 | 3 | female | 26.0 | 0 | 0 | 7.9250 | S | Third | woman | False | NaN | Southampton | yes | True |
| 3 | 1 | 1 | female | 35.0 | 1 | 0 | 53.1000 | S | First | woman | False | C | Southampton | yes | False |
| 4 | 0 | 3 | male | 35.0 | 0 | 0 | 8.0500 | S | Third | man | True | NaN | Southampton | no | True |

175

# 2.決定木による予想

## 事前準備（タイタニック号データ）

| | |
|---|---|
| **survived** | 生存フラグ |
| **pclass** | チケットクラス |
| **sex** | 性別 |
| **age** | 年齢 |
| **sibsp** | 兄弟・配偶者の数 |
| **parch** | 親・子の数 |
| **fare** | 料金 |

| | |
|---|---|
| **embarked** | 出航地 |
| **class** | チケットクラス |
| **who** | 性別 |
| **adult_male** | 成人男性かどうか |
| **deck** | 乗船していたデッキ |
| **embark_town** | 出航地名 |
| **alive** | 生存 |
| **alone** | 一人だったか |

176

# 2.決定木による予想

## 決定木の前処理：説明変数（x）と目的変数（y）に分割

```
df_x = df[['sex','pclass','fare']]
df_y = df['survived']
```

事前に定義したタイタニック号のデータの変数（df）から，説明変数（df_x）と目的変数（df_y）に分ける

決定木の可視化を見やすくするために，性別・チケットクラス・運賃に限定

177

# 2.決定木による予想

## 決定木の前処理：ダミー変数処理（文字列→数値）

```
df_x = pd.get_dummies(df_x, drop_first=True)
```

drop_first カラム数を減らすパラメータ

性別のカラムに「male / female」の文字列が格納されているので，数値列に変換
get_dummies

| | pclass | fare | sex_male |
|---|---|---|---|
| 0 | 3 | 7.2500 | 1 |
| 1 | 1 | 71.2833 | 0 |
| 2 | 3 | 7.9250 | 0 |
| 3 | 1 | 53.1000 | 0 |
| 4 | 3 | 8.0500 | 1 |

178

# 2.決定木による予想

## 決定木の前処理：学習用-テスト用に分割

```
from sklearn.model_selection import train_test_split
train_x, test_x, train_y, test_y =
train_test_split(df_x,df_y,random_state=1)
```

学習用とテスト用にデータを分割
train_test_split

| 説明変数（df_x） | | | 目的変数（df_y） |
|---|---|---|---|
| **sex_male** | **pclass** | **fare** | **survived** |
| 1 | 3 | 7.2500 | 0 |
| ⋮ | ⋮ | ⋮ | ⋮ |
| ⋮ | ⋮ | ⋮ | ⋮ |
| 0 | 1 | 55.008 | 0 |

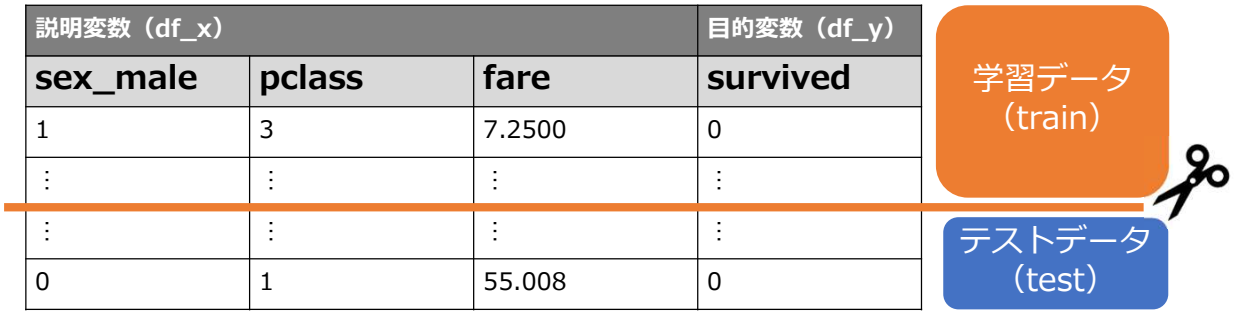


179

# 2.決定木による予想

## 決定木の前処理：学習用-テスト用に分割

```
from sklearn.model_selection import train_test_split
train_x, test_x, train_y, test_y =
train_test_split(df_x,df_y,random_state=1)
```

学習用とテスト用にデータを分割
train_test_split

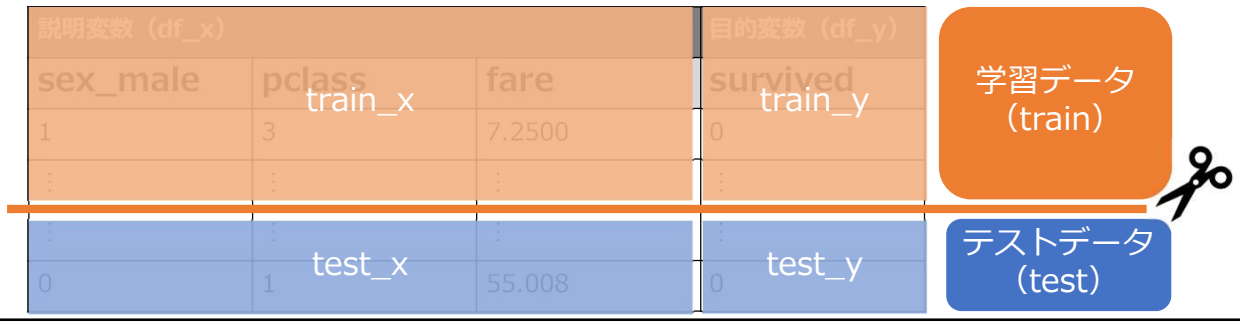


180

# 2.決定木による予想

## 決定木モデルの作成と予測

```
from sklearn import tree
model = tree.DecisionTreeClassifier(max_depth=2, random_state=1)
```

決定木のモデルを作成
scikit-learnというpython用機械学習ライブラリの中から決定木モデルのtreeを拝借
sklearn.tree.DecisionTreeClassifierというクラスに決定木が実装されている
max_depth：分類技の最大深さ
random_state：学習時の乱数シード，常に同じ結果を得たい場合は適当な整数を指定

181

# 2.決定木による予想

## 決定木モデルの作成と予測

```
model.fit(train_x, train_y)
```

fitメソッドで学習を行う

fit(x, y)：特徴量 x, クラス y を教師データとして学習する

182

## 2.決定木による予想

### 決定木モデルの作成と予測

model.predict(test_x)　　モデルに対してpredictfitで予想を実施

predict (x)：特徴量 x に対するクラスの予想結果を返す

```
array([1, 0, 1, 0, 1, 0, 0, 1, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 1, 0, 0,
       1, 0, 0, 0, 1, 1, 0, 1, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 1, 0,
       0, 0, 0, 0, 0, 0, 0, 1, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0,
       0, 0, 0, 0, 0, 0, 0, 0, 1, 0, 1, 0, 0, 1, 0, 0, 0, 0, 1, 0, 0, 0,
       0, 1, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 1, 0, 0, 0, 0,
       0, 0, 0, 0, 0, 0, 0, 0, 1, 0, 1, 0, 0, 0, 1, 1, 1, 0, 0, 0, 0, 0,
       0, 0, 0, 1, 1, 0, 0, 0, 1, 0, 1, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0,
       0, 0, 0, 0, 1, 0, 0, 0, 0, 0, 0, 0, 1, 0, 0, 0, 1, 0, 1, 0, 1, 0,
       0, 0, 0, 0, 1, 1, 0, 0, 1, 0, 0, 1, 0, 1, 0, 0, 0, 0, 0, 1, 0, 1,
       0, 0, 0, 1, 0, 0, 0, 1, 1, 0, 0, 0, 1, 0, 0, 0, 0, 0, 0, 1, 1, 0,
       0, 0, 0])
```

183

## 2.決定木による予想

### 決定木モデルの作成と予測

model.score(test_x,test_y)　　scoreメソッドでスコア（正解率）を算出

score (x, y)：決定係数を出力，予想値 xと正解値 yの相関を測る

```
0.7533632286995515
```

184

# 2.決定木による予想

## 決定木の可視化（plot_tree）

```
from sklearn.tree import plot_tree
plot_tree(model, feature_names=train_x.columns, class_names=True,
filled=True)
```

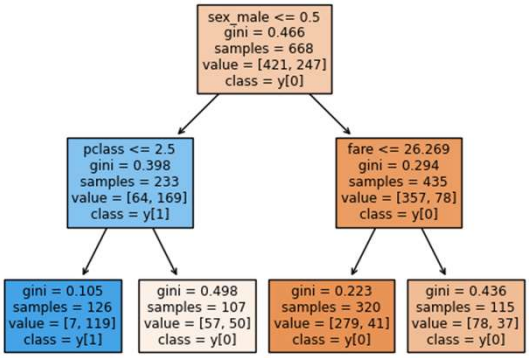


性別（男性=1）が0.5より小さい

Yes=女性　No=男性

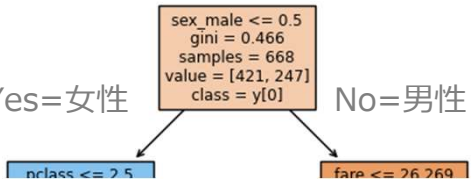


185

# 2.決定木による予想

## 決定木の可視化（plot_tree）

```
from sklearn.tree import plot_tree class_name：目的変数の名前
plot_tree(model, feature_names=train_x.columns, class_names=True,
filled=True)                                          filled：色
```

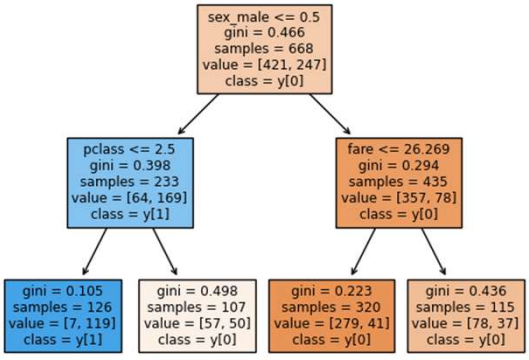


gini（ジニ係数）：不純度
各葉（ノード）にどれくらい間違いが含まれているのか
不純度が低い（正しい）と値は「0」
不純度が高い（間違い）と「1」に近づく

色合い：濃いほど目的変数に近い
（ジニ係数も低い）
sample：ノードの個数
value：その条件に当てはまる数

186

# 3.クラスター分析

## クラスター分析とは（クラスタリング）

- 個々のデータから似ているデータ同士をグルーピングする分析手法
- クラスタ（群）ごとに分けることで，データの中身を理解しやすくしたり，群ごとに施策を行うことができる

187

# 3.クラスター分析

## 流れ

- 事前準備
- k-meansの前処理
  - データを限定する
  - 欠損値を処理する
  - ダミー変数処理（文字列→数値）
  - データを標準化する
- k-meansのクラスタリングを実行
- クラスタリングの結果を確認
  - 主成分分析でグラフ化

188

# 3.クラスター分析

## 事前準備（タイタニック号データ）

```
import seaborn as sns
import pandas as pd
df = sns.load_dataset('titanic')
df.head()
```

| | survived | pclass | sex | age | sibsp | parch | fare | embarked | class | who | adult_male | deck | embark_town | alive | alone |
|---|---|---|---|---|---|---|---|---|---|---|---|---|---|---|---|
| 0 | 0 | 3 | male | 22.0 | 1 | 0 | 7.2500 | S | Third | man | True | NaN | Southampton | no | False |
| 1 | 1 | 1 | female | 38.0 | 1 | 0 | 71.2833 | C | First | woman | False | C | Cherbourg | yes | False |
| 2 | 1 | 3 | female | 26.0 | 0 | 0 | 7.9250 | S | Third | woman | False | NaN | Southampton | yes | True |
| 3 | 1 | 1 | female | 35.0 | 1 | 0 | 53.1000 | S | First | woman | False | C | Southampton | yes | False |
| 4 | 0 | 3 | male | 35.0 | 0 | 0 | 8.0500 | S | Third | man | True | NaN | Southampton | no | True |

189

# 3.クラスター分析

## 事前準備（タイタニック号データ）

| | |
|---|---|
| survived | 生存フラグ |
| pclass | チケットクラス |
| sex | 性別 |
| age | 年齢 |
| sibsp | 兄弟・配偶者の数 |
| parch | 親・子の数 |
| fare | 料金 |

| | |
|---|---|
| embarked | 出航地 |
| class | チケットクラス |
| who | 性別 |
| adult_male | 成人男性かどうか |
| deck | 乗船していたデッキ |
| embark_town | 出航地名 |
| alive | 生存 |
| alone | 一人だったか |

190

# 3.クラスター分析

## k-meansの前処理：データを限定する

```
columns = ['survived','pclass','sex','age','fare']
df = df[columns]
```

生存・チケットクラス・性別・年齢・運賃に絞り込む

191

# 3.クラスター分析

## k-meansの前処理：欠損値を処理する

```
df.isnull().sum()
```
isnull と sum の組み合わせ

年齢に177件の欠損を確認，これを今回は平均で補う

```
survived    0
pclass      0
sex         0
age       177
fare        0
dtype: int64
```

```
mean = df['age'].mean()
df['age'] = df['age'].fillna(mean)
```
fillna を使う

192

# 3.クラスター分析

## k-meansの前処理：ダミー変数処理（文字列→数値）

```
df = pd.get_dummies(df, drop_first=True)
df.head()
```

isnull と sum の組み合わせ

データに文字列が含まれているのでダミー変数処理を行う

| | survived | pclass | age | fare | sex_male |
|---|---|---|---|---|---|
| 0 | 0 | 3 | 22.0 | 7.2500 | 1 |
| 1 | 1 | 1 | 38.0 | 71.2833 | 0 |
| 2 | 1 | 3 | 26.0 | 7.9250 | 0 |
| 3 | 1 | 1 | 35.0 | 53.1000 | 0 |
| 4 | 0 | 3 | 35.0 | 8.0500 | 1 |

193

# 3.クラスター分析

## k-meansの前処理：データの標準化

```
from sklearn.preprocessing import StandardScaler
sc = StandardScaler()
df_sc = sc.fit_transform(df)
df_sc = pd.DataFrame(df_sc, columns=df.columns)
df_sc.head()
```

StandardScalerを使用

年齢は22・26…，チケットクラスは1・3…，スケールの違いを合わせる：標準化

| | survived | pclass | age | fare | sex_male |
|---|---|---|---|---|---|
| 0 | -0.789272 | 0.827377 | -0.592481 | -0.502445 | 0.737695 |
| 1 | 1.266990 | -1.566107 | 0.638789 | 0.786845 | -1.355574 |
| 2 | 1.266990 | 0.827377 | -0.284663 | -0.488854 | -1.355574 |
| 3 | 1.266990 | -1.566107 | 0.407926 | 0.420730 | -1.355574 |
| 4 | -0.789272 | 0.827377 | 0.407926 | -0.486337 | 0.737695 |

194

# 3.クラスター分析

## k-meansのクラスタリングを実行

```
from sklearn.cluster import KMeans
model = KMeans(n_clusters=4, random_state=1)
model.fit(df_sc)
```

n_clustersは分割するクラスタ数

sklearnからKMeansをインポートし，モデルを作成

```
cluster = model.labels_
cluster
```

labels_ でクラスタ番号を取得

```
array([3, 1, 2, 1, 3, 3, 0, 3, 2, 2, 2, 1, 3, 3, 2, 2, 3, 0, 2, 2, 0, 0,
       2, 0, 2, 2, 3, 1, 2, 3, 0, 1, 2, 0, 0, 0, 3, 3, 2, 2, 2, 2, 3, 2,
       2, 3, 3, 2, 3, 2, 3, 3, 1, 2, 0, 0, 2, 3, 2, 3, 3, 1, 0, 3, 0, 3,
       2, 3, 2, 3, 3, 2, 3, 3, 3, 3, 3, 3, 3, 2, 3, 3, 2, 0, 2, 2, 3, 3,
       1, 3, 3, 3, 0, 3, 0, 3, 0, 0, 2, 3, 2, 3, 0, 3, 3, 3, 2, 3, 3, 2,
       0, 2, 3, 2, 2, 3, 0, 3, 1, 2, 3, 3, 3, 2, 0, 3, 3, 3, 2, 3, 3, 3,
```

195

# 3.クラスター分析

## k-meansのクラスタリングを実行

```
df['cluster'] = cluster
df
```

DataFrame の新しいカラムに
クラスタ番号を追加

| | survived | pclass | age | fare | sex_male | cluster |
|---|---|---|---|---|---|---|
| **0** | 0 | 3 | 22.000000 | 7.2500 | 1 | 3 |
| **1** | 1 | 1 | 38.000000 | 71.2833 | 0 | 1 |
| **2** | 1 | 3 | 26.000000 | 7.9250 | 0 | 2 |
| **3** | 1 | 1 | 35.000000 | 53.1000 | 0 | 1 |
| **4** | 0 | 3 | 35.000000 | 8.0500 | 1 | 3 |
| **...** | ... | ... | ... | ... | ... | ... |
| **886** | 0 | 2 | 27.000000 | 13.0000 | 1 | 3 |
| **887** | 1 | 1 | 19.000000 | 30.0000 | 0 | 2 |

196

# 3.クラスター分析

## クラスタリングの結果を確認

```
# style.bar で DataFrame にカラーバーを追加
df.groupby('cluster').mean().style.bar(axis=0)
```

読み込ませたデータの平均値をクラスタごとに確認

| cluster | survived | pclass | age | fare | sex_male |
|---|---|---|---|---|---|
| 0 | 0.280000 | 1.320000 | 42.981210 | 37.686277 | 0.986667 |
| 1 | 0.925926 | 1.009259 | 33.376021 | 123.153357 | 0.148148 |
| 2 | 0.650000 | 2.645455 | 25.380733 | 18.052823 | 0.000000 |
| 3 | 0.138015 | 2.828087 | 26.213949 | 13.968097 | 1.000000 |

197

# 3.クラスター分析

## クラスタリングの結果を確認

```
import matplotlib.pyplot as plt
fig, axes = plt.subplots(2,3, figsize=(14, 6))
sns.barplot(ax=axes[0,0], data=df, x='cluster', y='survived')
sns.barplot(ax=axes[0,1], data=df, x='cluster', y='pclass')
sns.barplot(ax=axes[0,2], data=df, x='cluster', y='age')
sns.barplot(ax=axes[1,0], data=df, x='cluster', y='fare')
sns.barplot(ax=axes[1,1], data=df, x='cluster', y='sex_male')
```

198

# 3.クラスター分析

## クラスタリングの結果を確認

クラスタ0：男性で高齢，良い客室に泊まっており，生存率が低い
クラスタ1：女性で良い客室に泊まり運賃が最も高く，生存率も一番高い
クラスタ2：女性で安い客室に泊まっている
クラスタ3：男性で若年，安い客室に泊まっており，一番生存率が低い

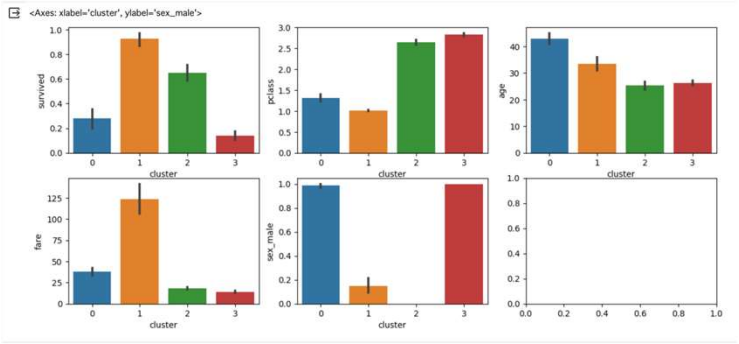


199

# 3.クラスター分析

## クラスタリングの結果を確認：主成分分析でグラフ化

```
df_sc['cluster'] = cluster
```

```
from sklearn.decomposition import PCA
pca = PCA(n_components=2, random_state=1)
pca.fit(df_sc)
feature = pca.transform(df_sc)
feature
```

PCAをインポートし学習させる

```
array([[-1.79546026,  0.2666309 ],
       [ 2.61164075, -0.78970203],
       [ 0.02143814, -1.73958101],
       ...,
       [-0.43069953, -0.47767583],
       [ 2.14671007,  0.27131272],
       [-1.59197757,  0.65939251]])
```

200

# 3.クラスター分析

## クラスタリングの結果を確認：主成分分析でグラフ化

```
import matplotlib.pyplot as plt
plt.figure(figsize=(6, 6))
plt.scatter(feature[:, 0], feature[:, 1], alpha=0.8,
c=cluster)
plt.xlabel('principal component 1')
plt.ylabel('principal component 2')
plt.show()
```

散布図で可視化

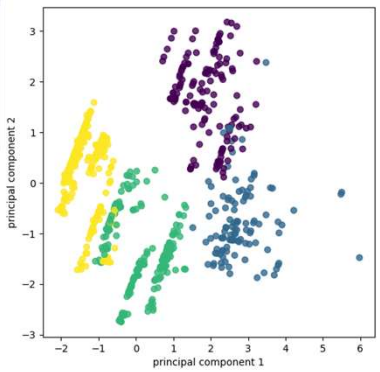


201

# 3.クラスター分析（その2）

## 階層的クラスタリング（Hierarchical Clustering）

- 最も類似する（または最も類似しない）サンプルデータの組み合わせを見つけ出し，順番にグループ分けしていく手法
- 樹形図（デンドログラム）をプロットできる
- 二分木で階層的クラスタリングを可視化したもの

202

## 3.クラスター分析（その2）

**計算の流れ**

- 各サンプルを単一のクラスターとみなし，全てのクラスター間のユークリッド距離を計算
- クラスター間の距離に基づき，クラスターを連結
- クラスター情報を更新し，ユークリッド距離を再計算
- クラスターが最終的に１つになるまで繰り返す

203

## 3.クラスター分析（その2）

**流れ**

- 事前準備
- 最適なクラスターの数を見つけるための樹形図の作成
- クラスター数の決定・モデル学習
- クラスター可視化

204

# 3.クラスター分析（その2）

## 事前準備（SSDSE：教育用標準データセット）

```
from google.colab import files
uploaded = files.upload()
```

```
import pandas as pd
df = pd.read_csv('sample_7.csv')
df.head()
```

サンプルデータをインポート

統計センターのSSDSE（教育用標準データセット）を利用
https://www.nstac.go.jp/use/literacy/ssdse/

205

# 3.クラスター分析（その2）

## 事前準備（SSDSE：教育用標準データセット）

```
from google.colab import files
uploaded = files.upload()
```

```
import pandas as pd
df = pd.read_csv('sample_7.csv')
df.head()
```

サンプルデータをインポート

統計センターのSSDSE（教育用標準データセット）を利用
https://www.nstac.go.jp/use/literacy/ssdse/

| | Unnamed: 0 | 総人口 | 幼稚園の数(10万人あたり) | 残業時間の平均(時間/月) | 科学技術振興費の研究費(万円/10万人あたり) | 情報通信業の企業数 |
|---|---|---|---|---|---|---|
| 0 | 北海道 | 5250000 | 7.695238 | 12.0 | 95.238095 | 143 |
| 1 | 青森県 | 1246000 | 7.062600 | 10.5 | 0.000000 | 30 |
| 2 | 岩手県 | 1227000 | 7.497963 | 11.5 | 2086.389568 | 36 |
| 3 | 宮城県 | 2306000 | 10.320902 | 12.5 | 1036.426713 | 51 |
| 4 | 秋田県 | 966000 | 4.037267 | 9.0 | 5621.118012 | 16 |

206

# 3.クラスター分析（その2）

## 事前準備（SSDSE：教育用標準データセット）

```
import numpy as np
df.describe()
```

基本統計量を確認

| | 総人口 | 幼稚園の数（10万人あたり） | 残業時間の平均（時間/月） | 科学技術振興費の研究費（万円/10万人あたり） | 情報通信業の企業数 |
|---|---|---|---|---|---|
| count | 4.700000e+01 | 47.000000 | 47.000000 | 47.000000 | 47.000000 |
| mean | 2.684404e+06 | 8.555025 | 11.553191 | 1584.176816 | 117.425532 |
| std | 2.779720e+06 | 3.126166 | 1.372217 | 1573.513577 | 419.861610 |
| min | 5.560000e+05 | 3.597122 | 8.500000 | 0.000000 | 9.000000 |
| 25% | 1.075500e+06 | 6.671337 | 10.500000 | 807.490314 | 26.500000 |
| 50% | 1.602000e+06 | 7.796773 | 11.500000 | 1142.857143 | 34.000000 |
| 75% | 2.693500e+06 | 10.313550 | 12.500000 | 1660.102424 | 57.500000 |
| max | 1.392100e+07 | 16.758242 | 15.000000 | 7591.145833 | 2899.000000 |

207

# 3.クラスター分析（その2）

## 事前準備（SSDSE：教育用標準データセット）

```
import scipy.cluster.hierarchy as sch
# import matplotlib.pyplot as plt
```

クラスタリング軸設定　（人口vs残業時間の平均）

```
X = df.iloc[:, [1, 3]].values

dendrogram = sch.dendrogram(sch.linkage(X, method = 'ward'))
```

樹形図作成用インスタンス

scipy.cluster.hierarchyクラスからインスタンスを生成することで、樹形図を作成
インスタンス内のlinkage()メソッドはデータ間の距離を計算しつながりを作る。
連結方法としてウォード連結法で距離を計算。

208

# 3.クラスター分析（その2）

## 最適なクラスターの数を見つけるための樹形図の作成

```
plt.xlabel('population vs over work hours')
plt.ylabel('Euclidean distances')
plt.show()
```

ラベルを貼りながら出力

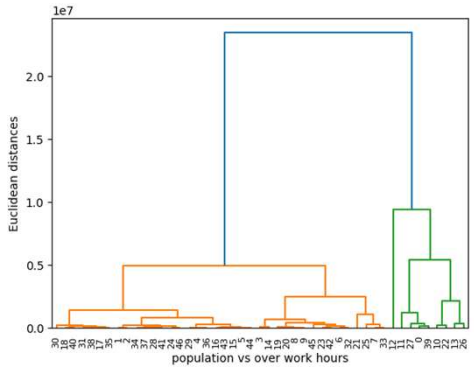


この結果から２つのクラスターで
分割するのが良いかもしれない。

209

# 3.クラスター分析（その2）

## モデル学習

```
from sklearn.cluster import AgglomerativeClustering
```

モデルの訓練

```
hir_clus = AgglomerativeClustering(n_clusters = 3, affinity = 'euclidean',
linkage = 'ward')
y_hir_clus = hir_clus.fit_predict(X)
```

第一引数：クラスター数（n_clusters）デフォルト値は2
第二引数：距離のパラメータ（affinity）
第三引数：クラスター連結法（linkage）

210

# 3.クラスター分析（その2）

## モデル学習によって予想されたクラスターの結果

```
print(y_hir_clus)
```

```
[0 1 1 1 1 1 1 1 1 1 0 0 2 0 1 1 1 1 1 1 1 0 1 1 1 0 0 1 1 1 1 1 1 1 1
 1 1 0 1 1 1 1 1 1 1]
```

211

# 3.クラスター分析（その2）

## クラスターの可視化

```
import numpy as np
import matplotlib.pyplot as plt
from matplotlib import cm

cluster_labels = np.unique(y_hir_clus)
n_clusters = cluster_labels.shape[0]
```

クラスターの配列情報
一意なクラスター要素
配列の長さ

```
for i in range(len(cluster_labels)):
    color = cm.jet(float(i) / n_clusters)
    plt.scatter(X[y_hir_clus == i, 0], X[y_hir_clus == i, 1], s = 50, c = color, label =
'Cluster'+str(i))
```

可視化

```
plt.title('Clusters of population')
plt.xlabel('population')
plt.ylabel('over work hours')
plt.legend(loc="best")
plt.show()
```

グラフに関する情報

212

# 3.クラスター分析（その2）

## クラスターの可視化

（以下再掲）

```
plt.title('Clusters of population')
plt.xlabel('population')
plt.ylabel('over work hours')
plt.legend(loc="best")
plt.show()
```

グラフに関する情報

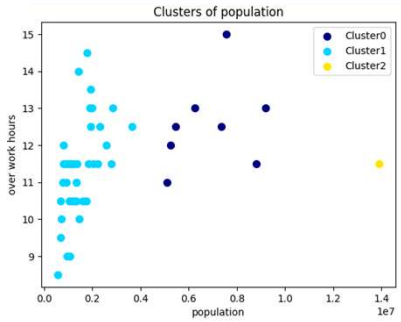


213

# 参考文献（継続して学習したい方向け）


- 谷合廣紀（2018）
  『Pythonで理解する統計解析の基礎』技術評論社
- 塚本邦尊 (著), 山田典一 (著), 大澤文孝 (著), 中山浩太郎（監修）(その他), 松尾豊（監修）（2019）
  『東京大学のデータサイエンティスト育成講座 Pythonで手を動かして学ぶデータ解析』マイナビ出版
- 馬場真哉 (著)（2022）
  『Pythonで学ぶあたらしい統計学の教科書 第2版』翔泳社


214

# データサイエンス・オンライン講座のご紹介

## 「誰でも使える統計オープンデータ」受講者募集中！


申込はこちらから！

講座の目的：e-Stat、jSTAT MAP、API機能等を使い、
統計オープンデータを活用したデータ分析の
基本的な知識を習得する
開 講 期 間：令和６年１月16日（火）～３月19日（火）
学 習 時 間：１回10分程度×５～７回程度（１週間）×４週
課　　題：各週の確認テストと最終課題の実施
講　　師：西内啓氏（統計家）ほか

| 週※5 | 各週のテーマ | 内　容 |
|---|---|---|
| 1 | e-Statを使ったデータ分析 | e-Statの統計データを活用したデータ分析の事例、基本的な活用方法を学ぶ<br>（e-Statの機能紹介、活用事例紹介等） |
| 2 | 公的統計データの使い方 | 公的統計データの基本事項及び読み方を学ぶ<br>（公的統計の種類と体系、労働力調査・家計調査の基礎知識及び利用の際のポイント等） |
| 3 | 地図で見る統計（jSTAT MAP）の活用 | 統計データと地図を組み合わせた活用方法を学ぶ<br>（地図で見る統計（jSTAT MAP）の機能紹介、簡単にできるレポート作成、活用事例紹介等） |
| 4 | 統計オープンデータの高度利用 | 統計API機能の仕組みや具体的な活用事例等の統計オープンデータの高度な活用方法を学ぶ<br>（統計APIの仕組み、統計オープンデータの活用事例、講座のまとめ等） |

215