演習授業中の質問対応について

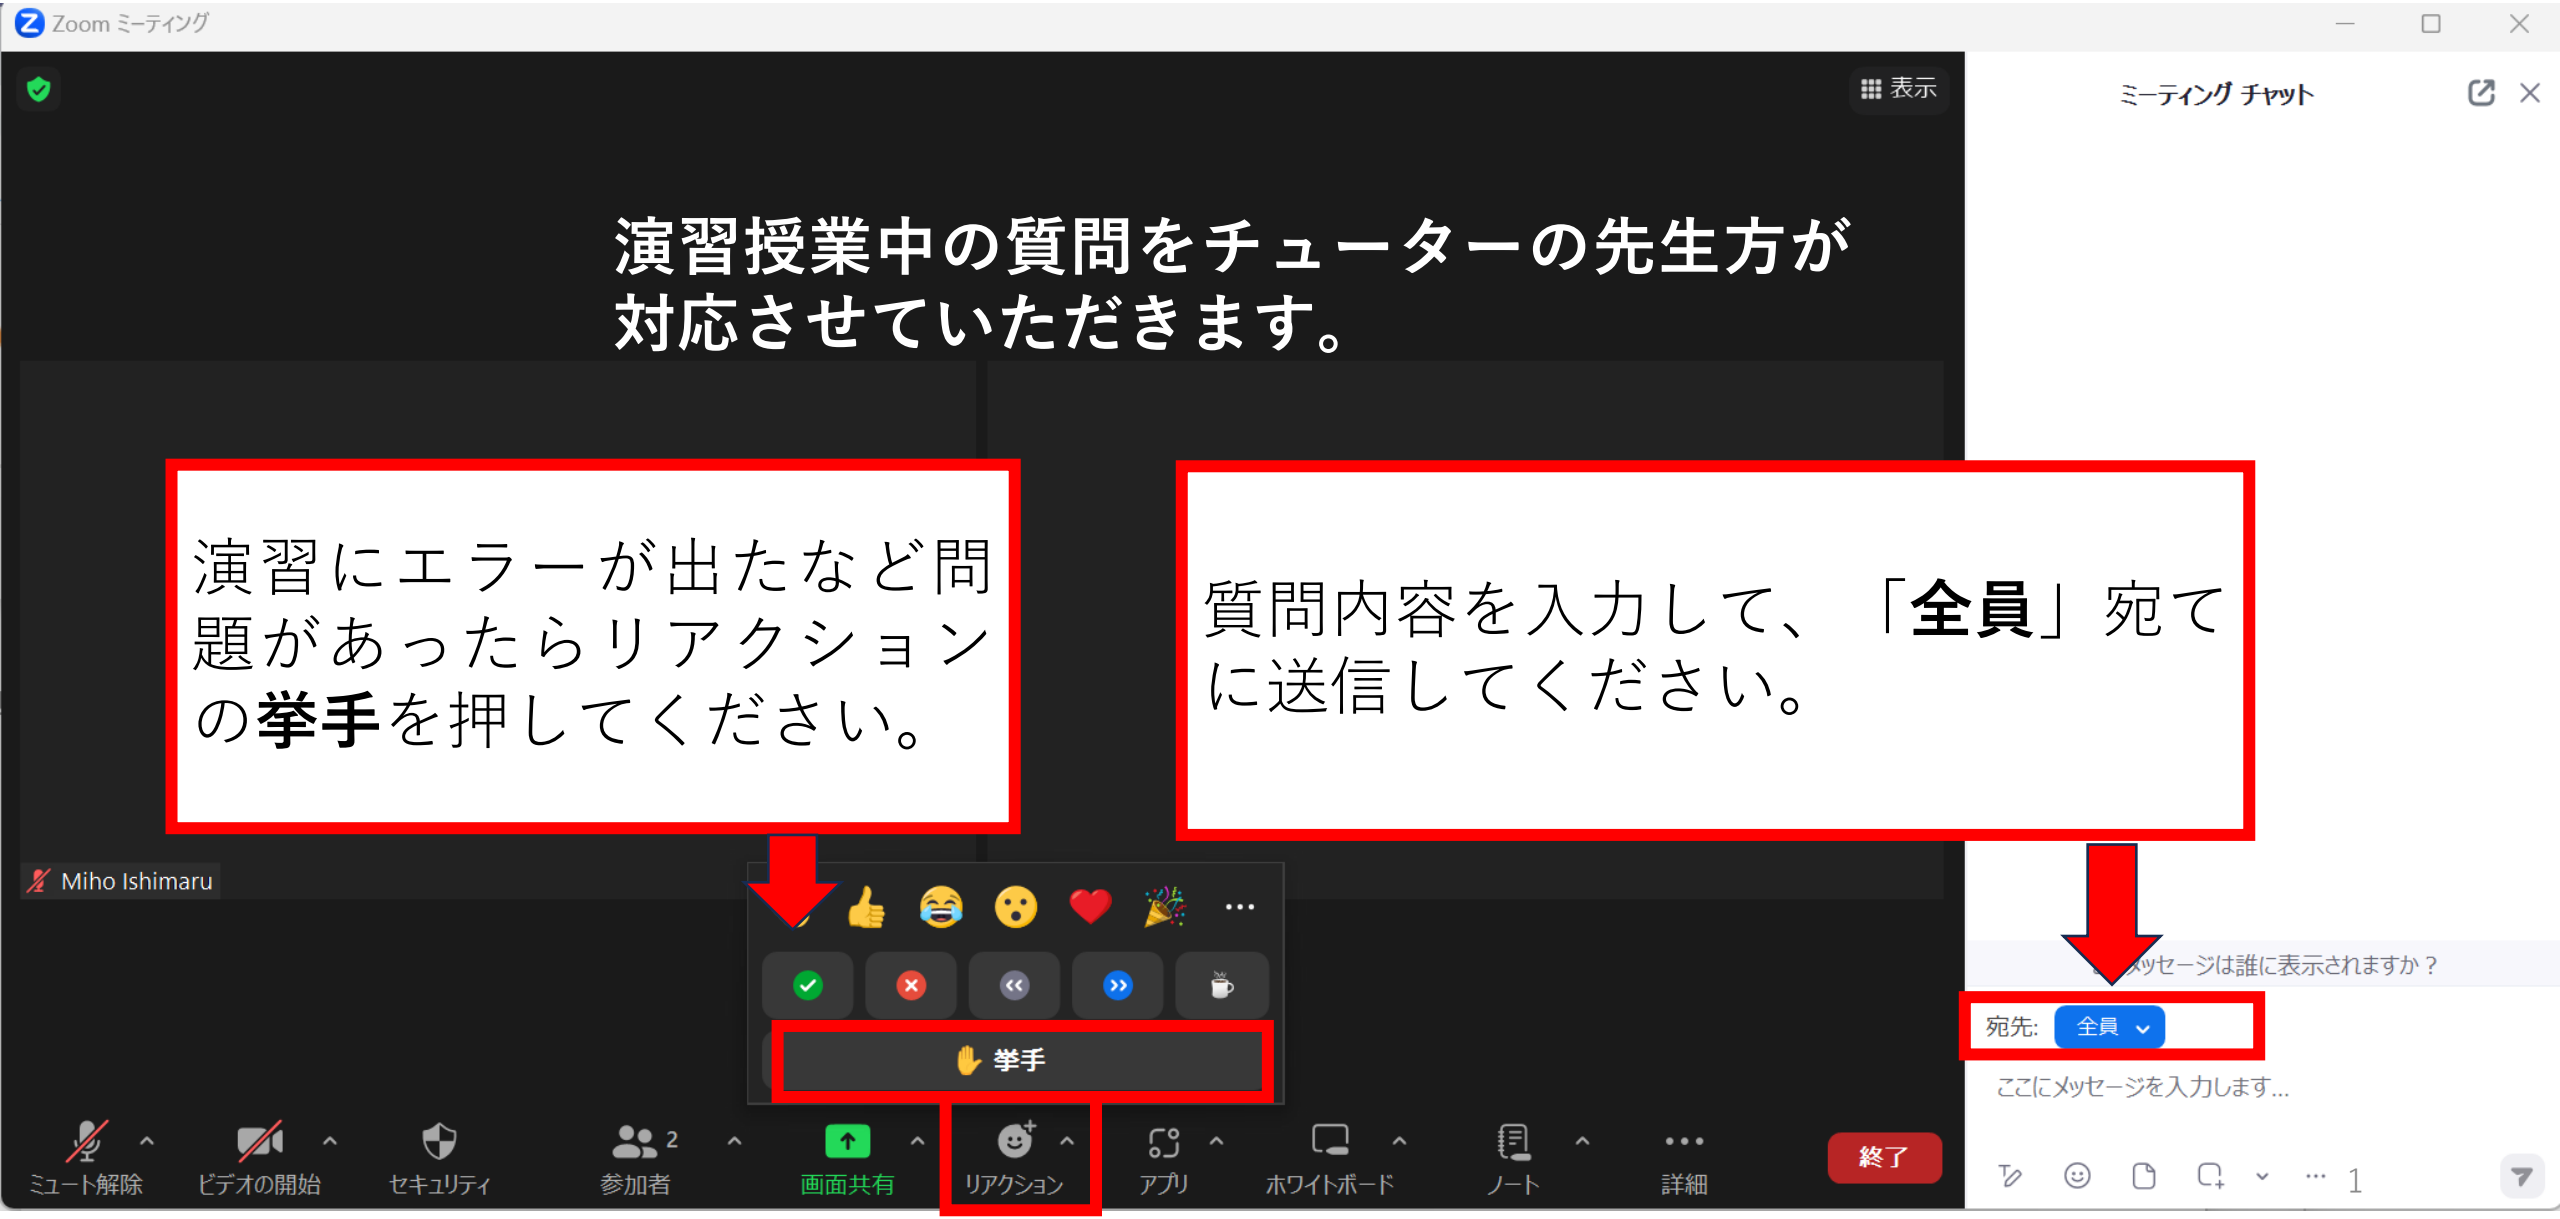

演習7

データクレンジングとデータの可視化

統合教育機構　曹　日丹

演習2-7の構成

Python基礎を学びましょう

演習2

Pythonの変数とデータの型

演習3

プログラミング基礎

演習4

モジュール、パッケージ、ライブラリ

Pythonを使ってみましょう

演習5

患者の歯に関する病院のリアルデータの説明

架空データ

演習6 12/21 10:40-11:35

データクレンジングに必要なライブラリ（Pandas）の応用

演習7 12/21 11:35-12:20

データクレンジングとデータの可視化

検索google colab　Colaboratory へようこそ - Colaboratory - Google

検索google colab　Colaboratory へようこそ - Colaboratory - Google

検索google colab　Colaboratory へようこそ - Colaboratory - Google

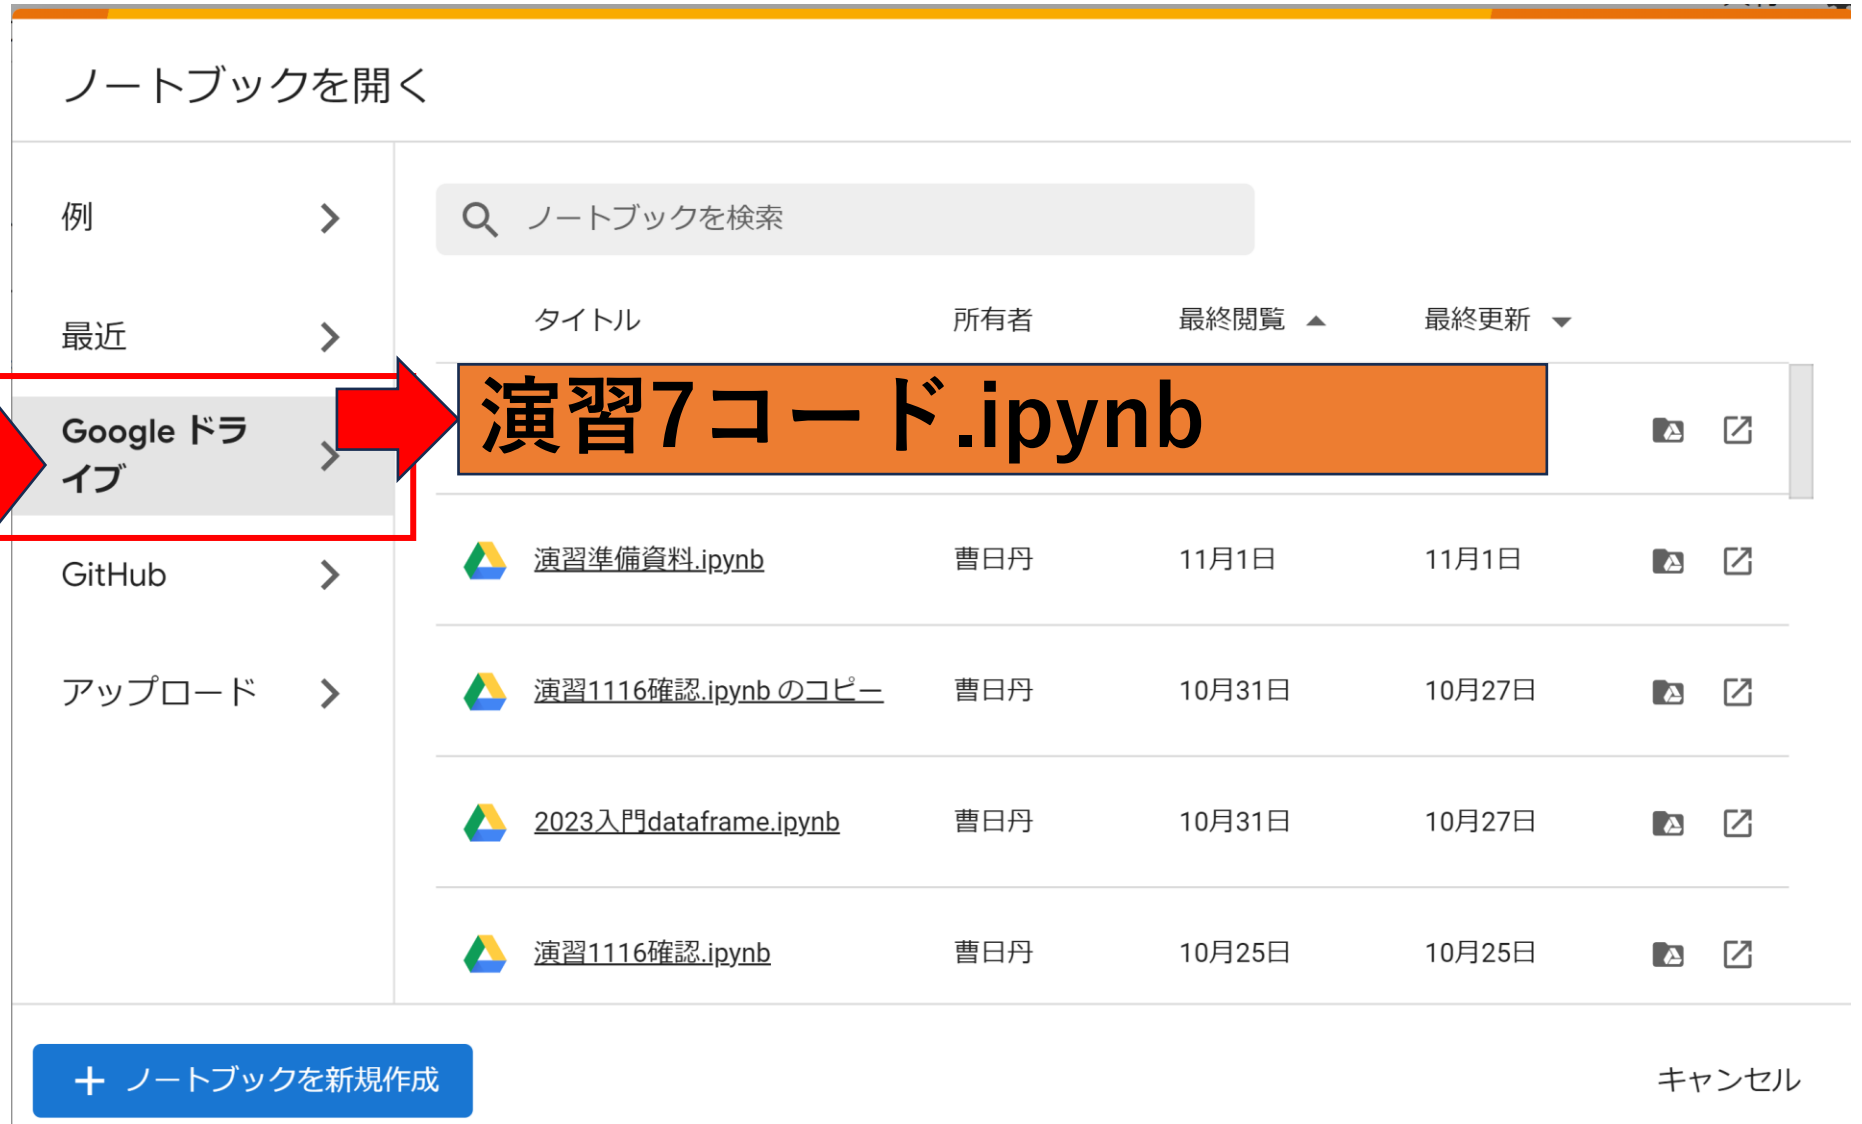

検索google colab　Colaboratory へようこそ - Colaboratory - Google

演習7コード.ipynb

Colab

演習授業中の質問対応について

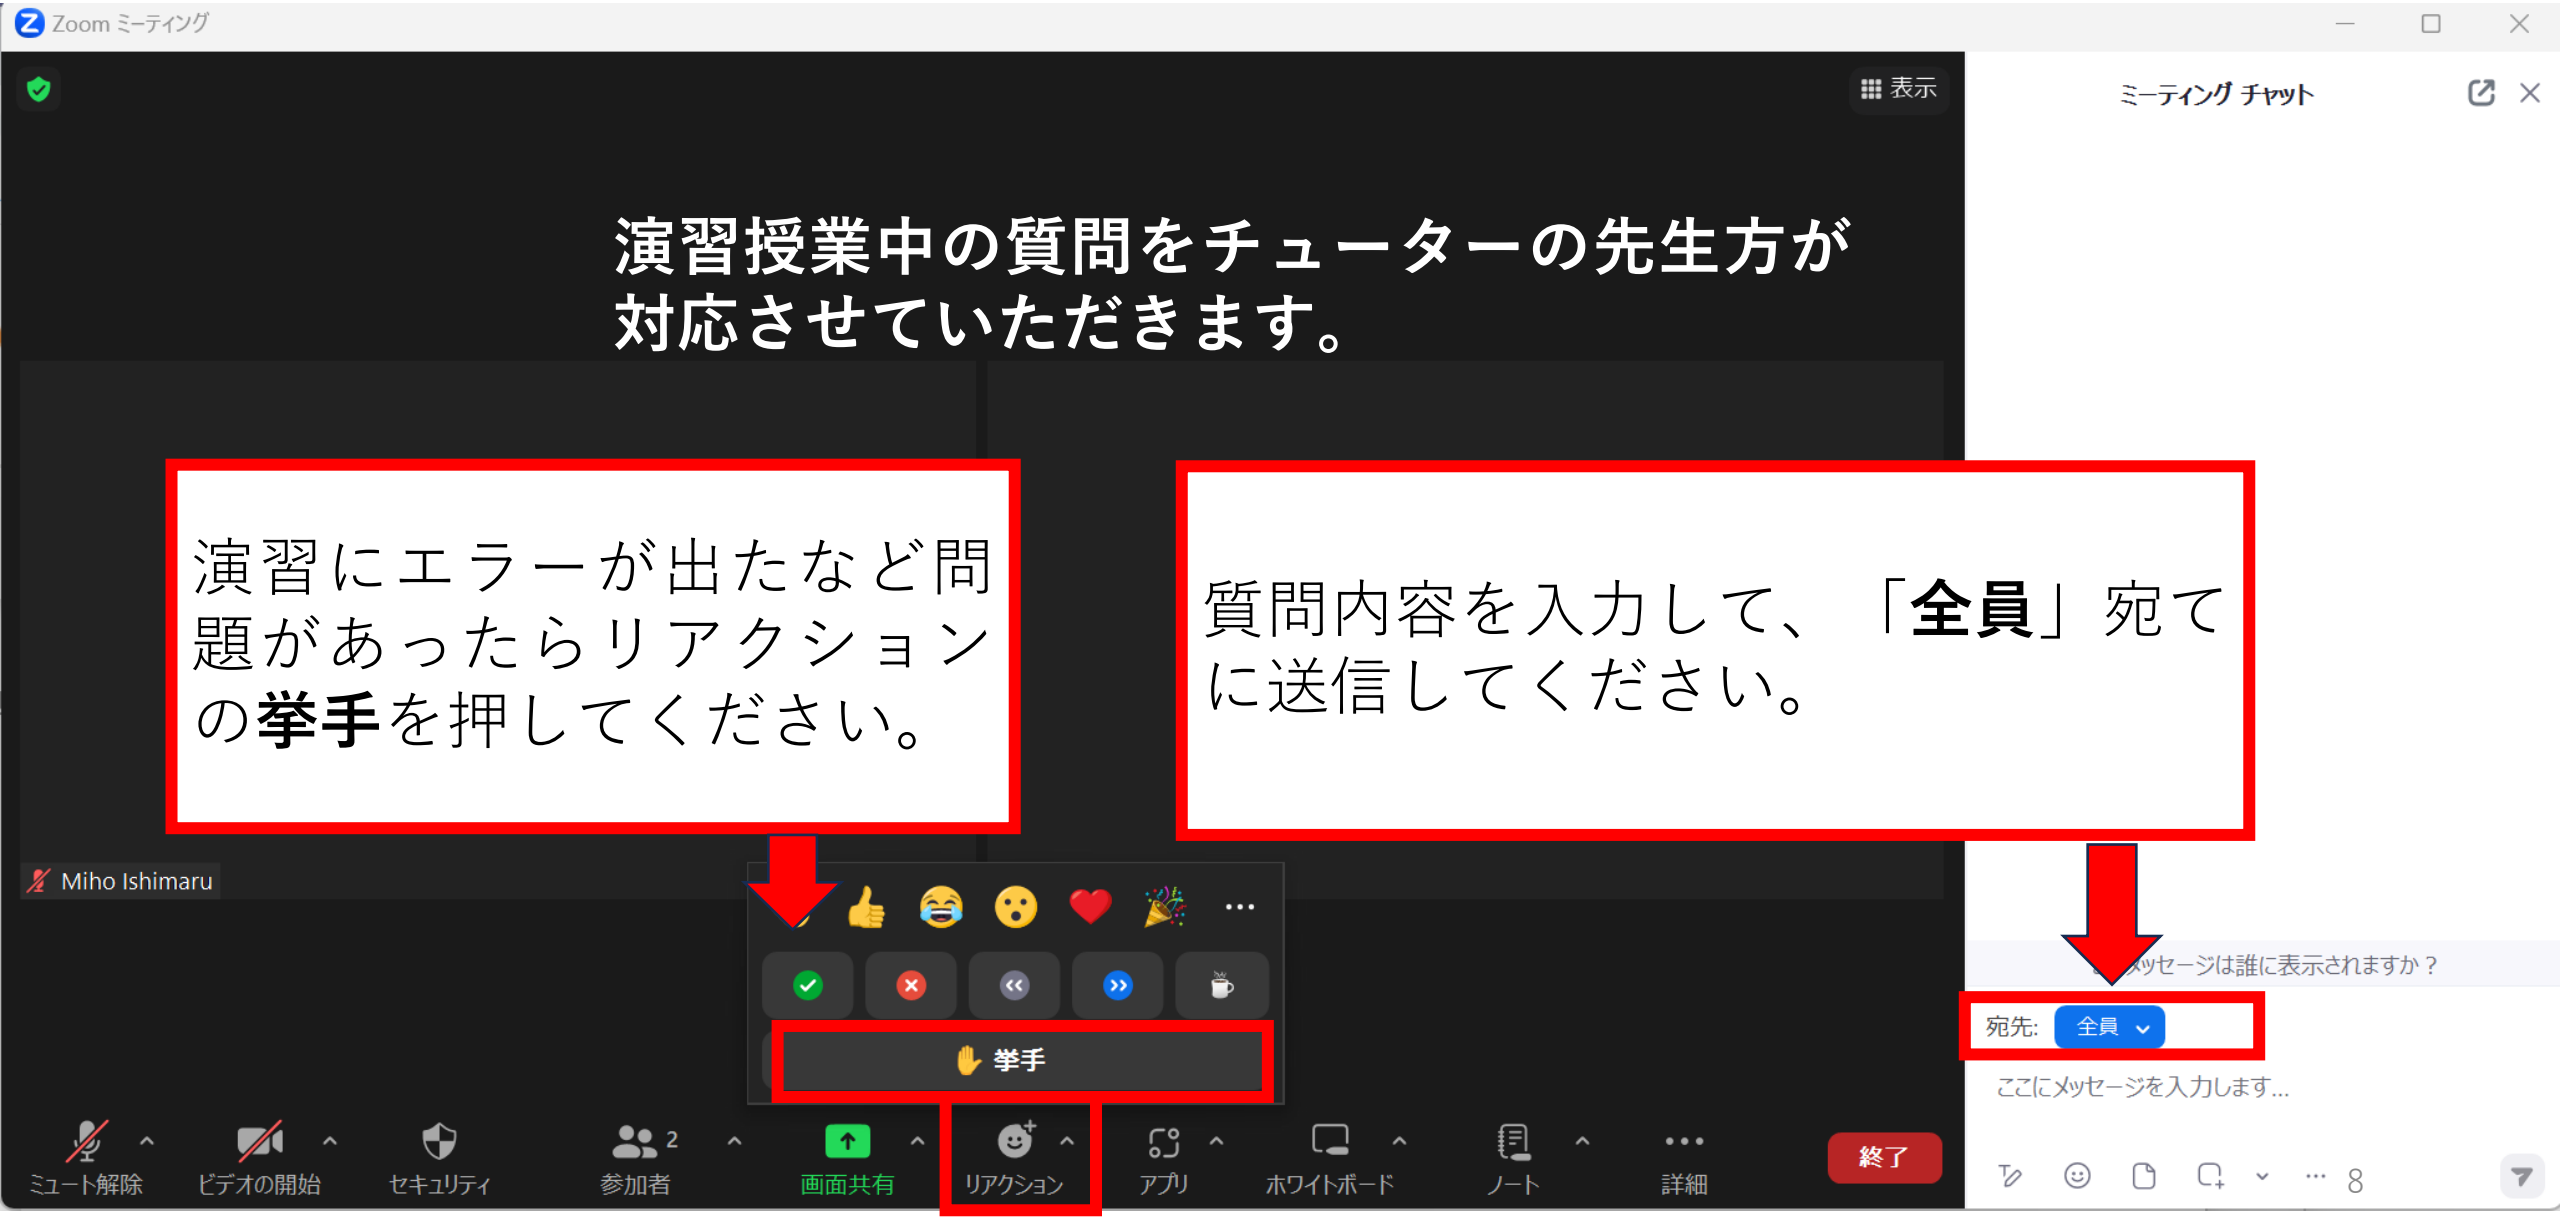

・Pythonを使用してデータクレンジングを行う

☑ ■データの読み込み:
CSVファイルをGoogleドライブにアップロード、GoogleColabで読み込みました。

☑ ■ライブラリのインポート:
Pandasライブラリをインポートしました。

☑ ■データの集計：
患者の人数を集計します。1657人

☑ ■データの集計：
歯の本数を集計します。

☐ **患者初診時の年齢**

演習7データクレンジングとデータの可視化

患者年齢を求めましょう

Klistデータフレーム

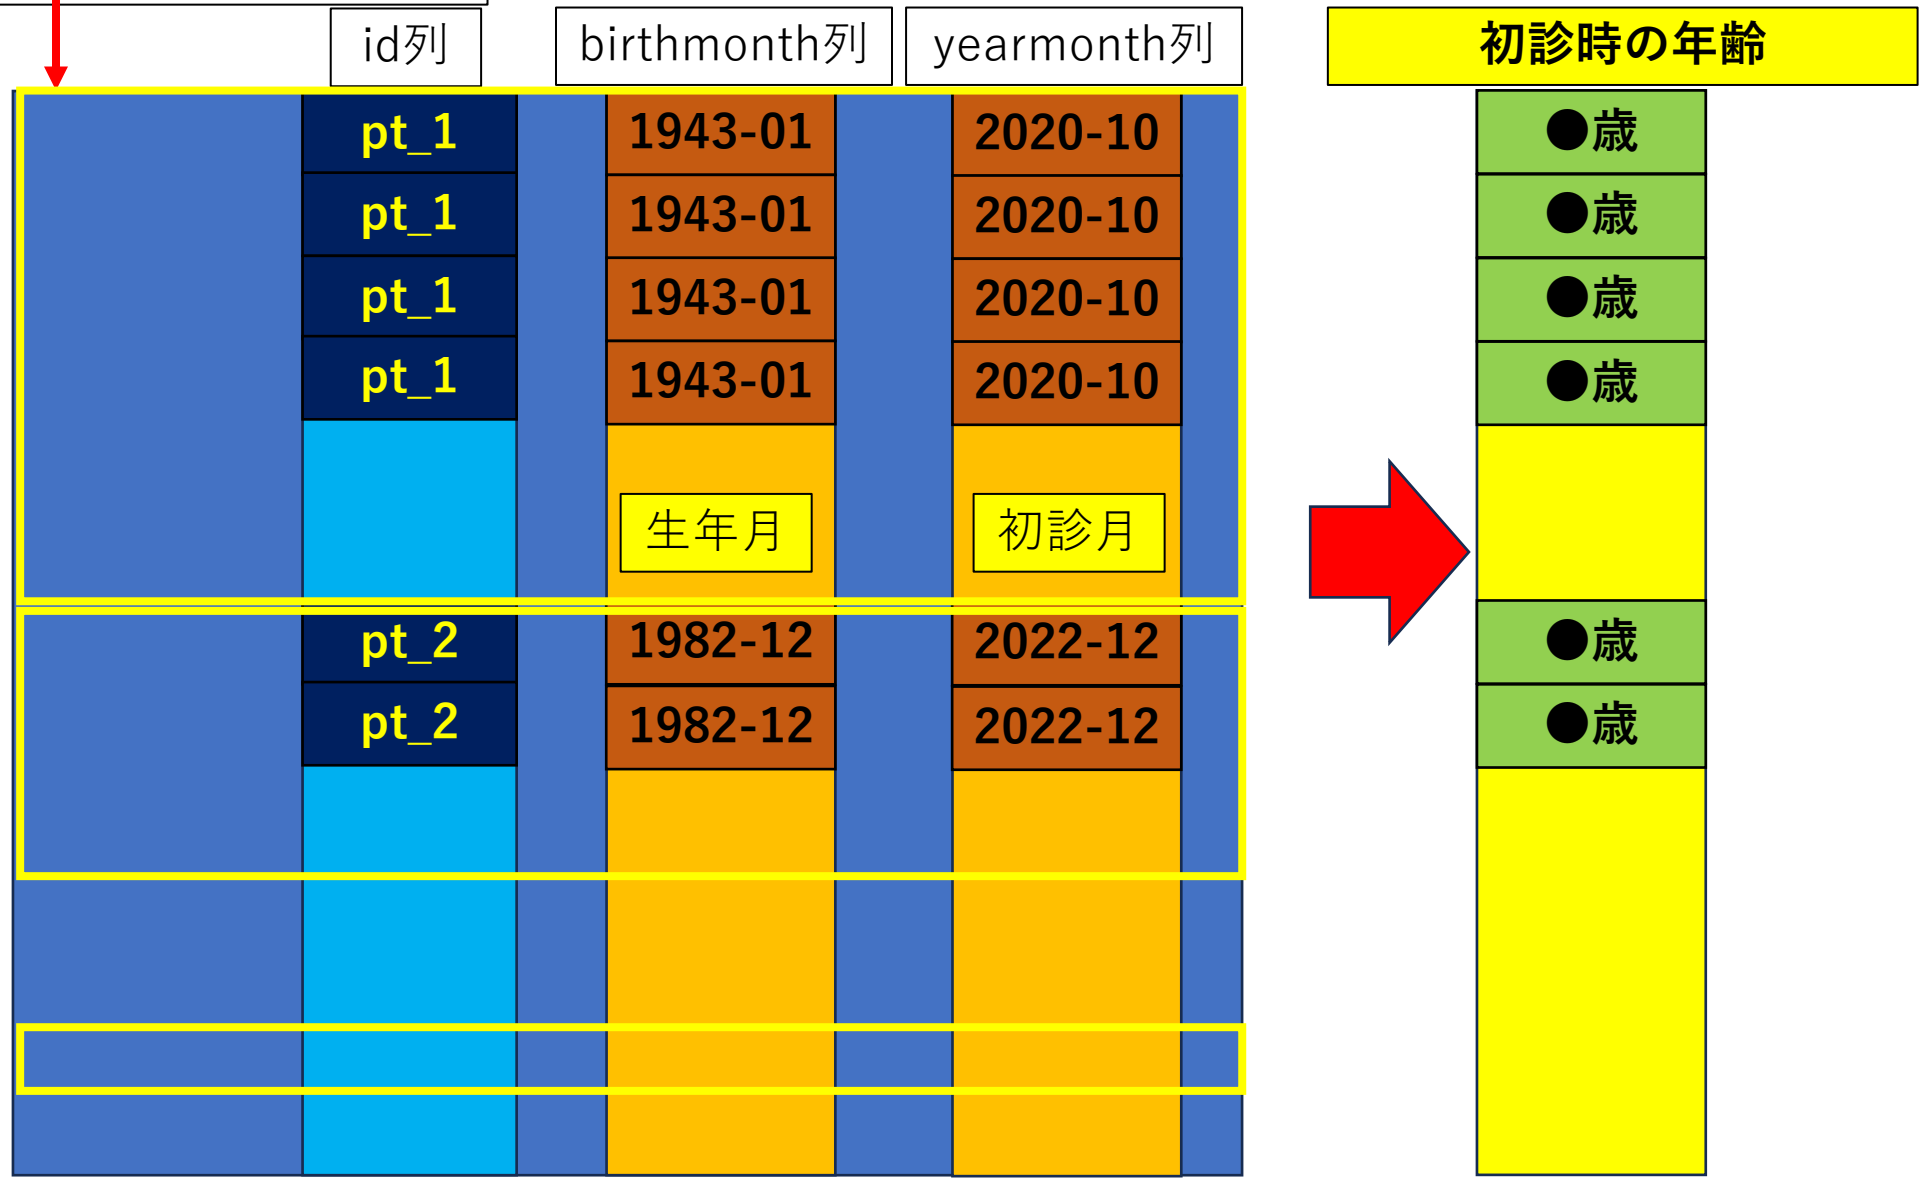

演習7データクレンジングとデータの可視化

患者年齢を求めましょう

Klistデータフレーム

id列	birthmonth列	yearmonth列
pt_1	1943-01	2020-10
pt_1	1943-01	2020-10
pt_1	1943-01	2020-10
pt_1	1943-01	2020-10
	生年月	初診月
pt_2	1982-12	2022-12
pt_2	1982-12	2022-12

誕生日の年月と初診日の年月を比較します。

条件式で年齢を計算します

```
if 初診月 >= 誕生月:
    age =初診日の年-生まれた年
else:
    age =初診日の年-生まれた年-1
```

初診時の年齢

変数：age
●歳
●歳
●歳
●歳
●歳

演習7データクレンジングとデータの可視化

患者年齢を求めましょう

Klistデータフレーム

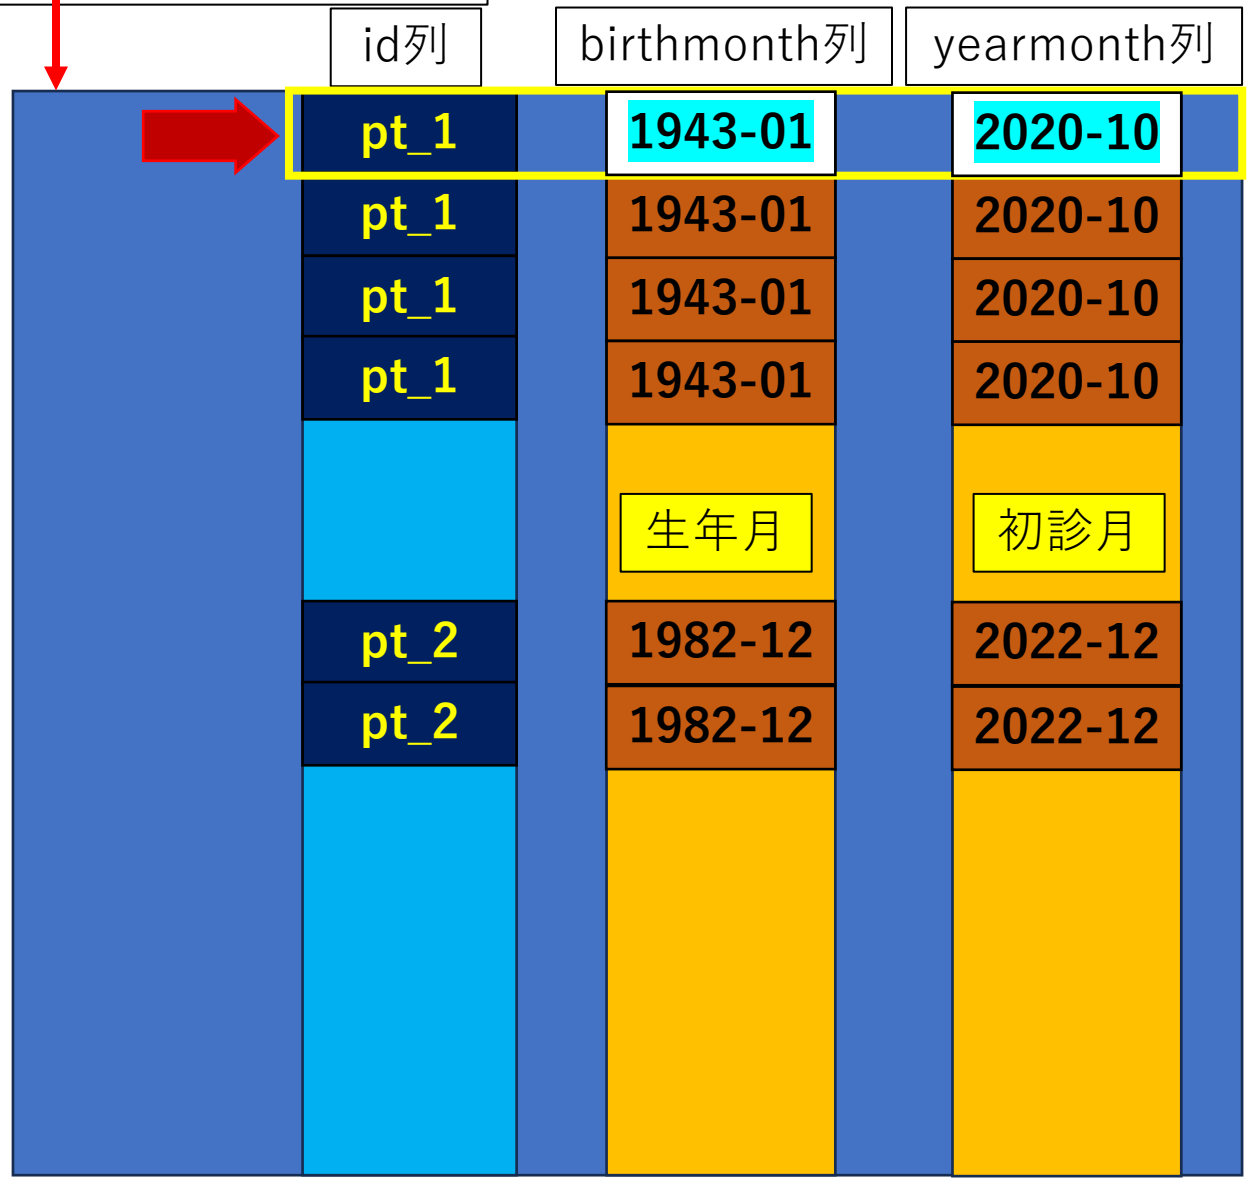

誕生日の年月と初診の年月を比較します。

条件式で年齢を計算します

```
if 初診月 >= 誕生月:
    age =初診の年-生まれた年
else:
    age =初診の年-生まれた年-1
```

2020-10 初診日の年月

2020 | 10

1943-01 誕生日の年月

1943 | 01

演習7データクレンジングとデータの可視化

患者年齢を求めましょう

Klistデータフレーム

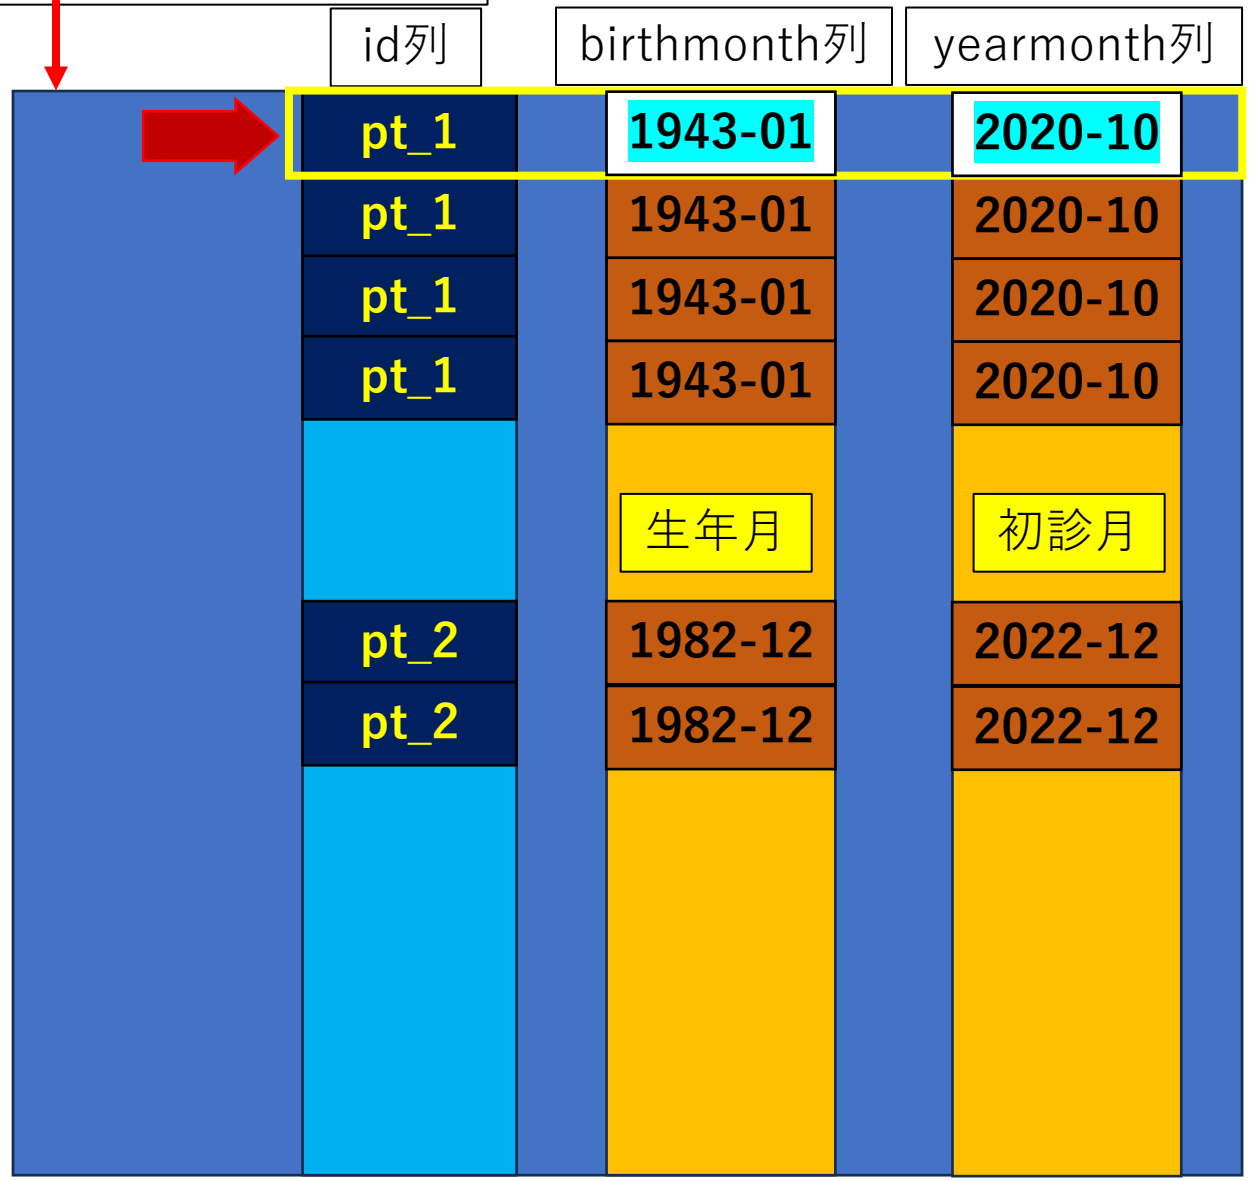

年と月を分解します

split()メソッド
文字列を特定の区切り文字で分割してリストにすることができます。

文字列：1943-01

区切り文字:"-"

コード書き方：

文字列.**split**("-")

["1943", "01"]

文字列.**split**("-")[0] → ["1943"]

文字列.**split**("-")[1] → ["01"]

演習7データクレンジングとデータの可視化

患者年齢を求めましょう

Klistデータフレーム

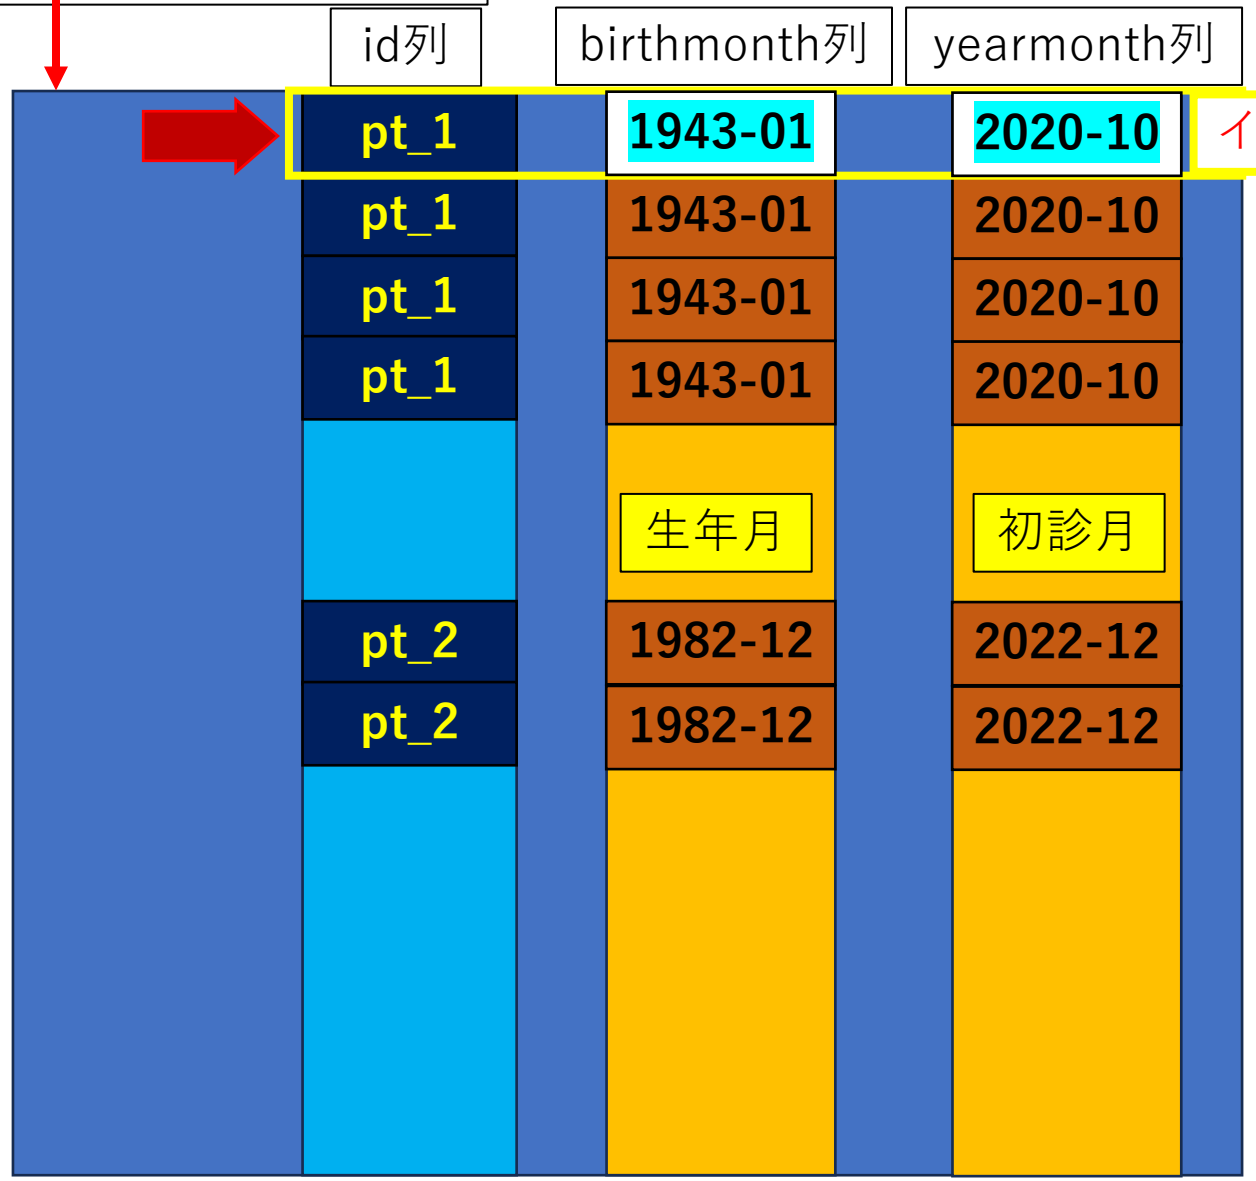

年と月を分解します

インデックス番号0

文字列:

生年月：`Klist["birthmonth"][0]`

文字列:

初診月：`Klist["yearmonth"][0]`

演習7データクレンジングとデータの可視化

患者年齢を求めましょう

Klistデータフレーム

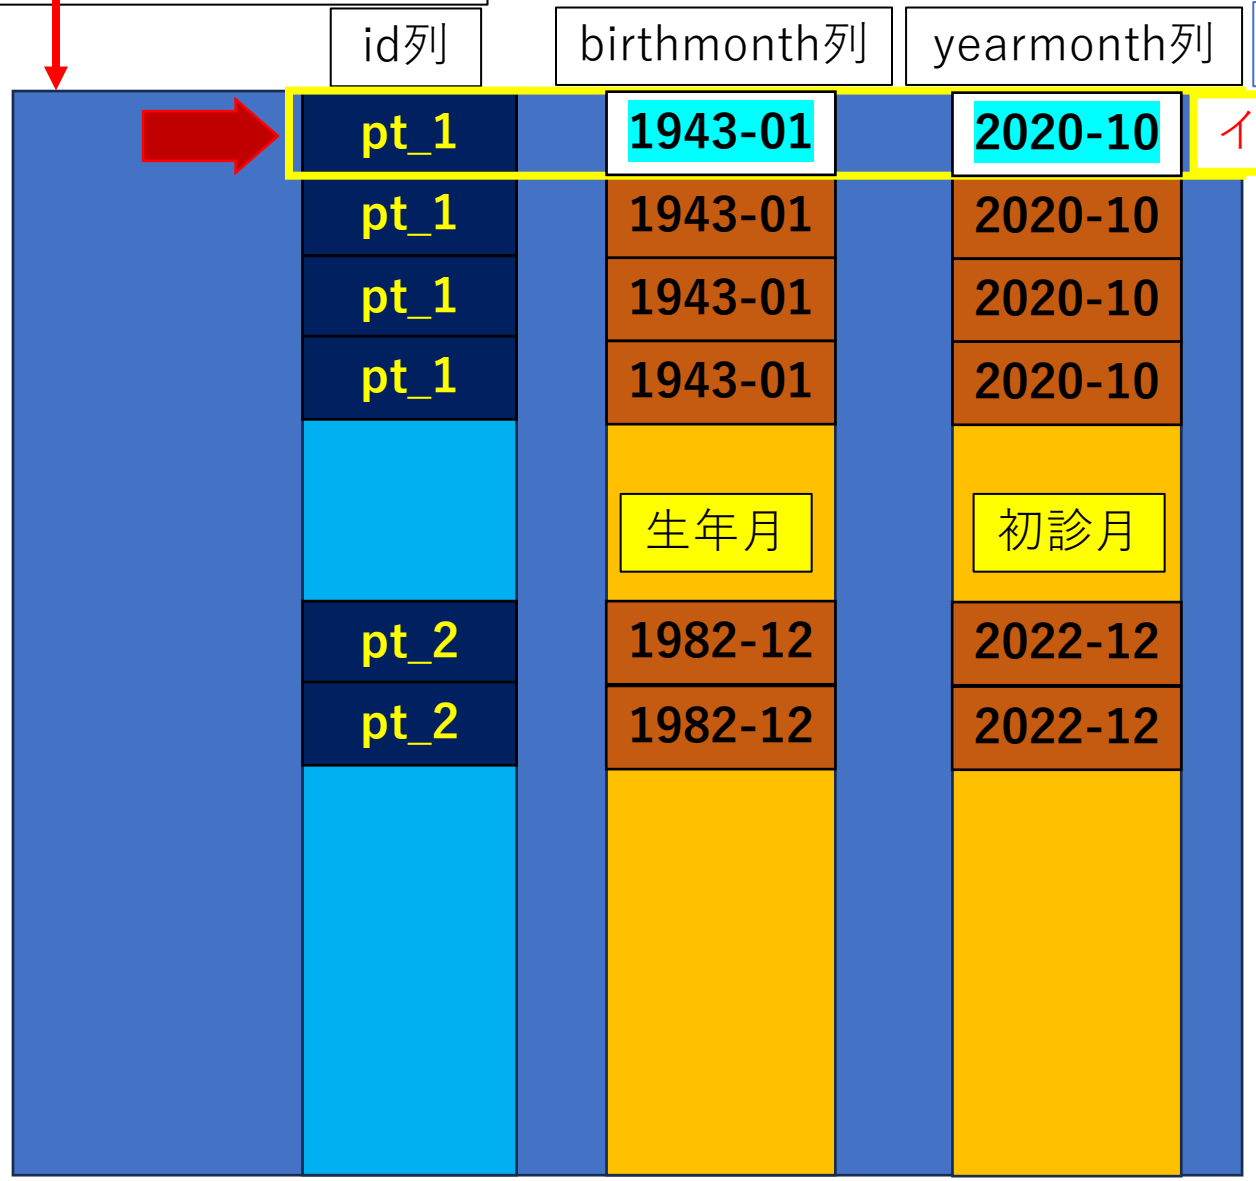

年と月を分解します

インデックス番号0

生年月：`Klist["birthmonth"][0]`

`Klist["birthmonth"][0].split("-")`

1943-01 ⟶ **["1943", "01"]**

初診月：`Klist["yearmonth"][0]`

`Klist["yearmonth"][0].split("-")`

2020-10 ⟶ **["2020", "10"]**

演習7データクレンジングとデータの可視化

患者年齢を求めましょう

Klistデータフレーム

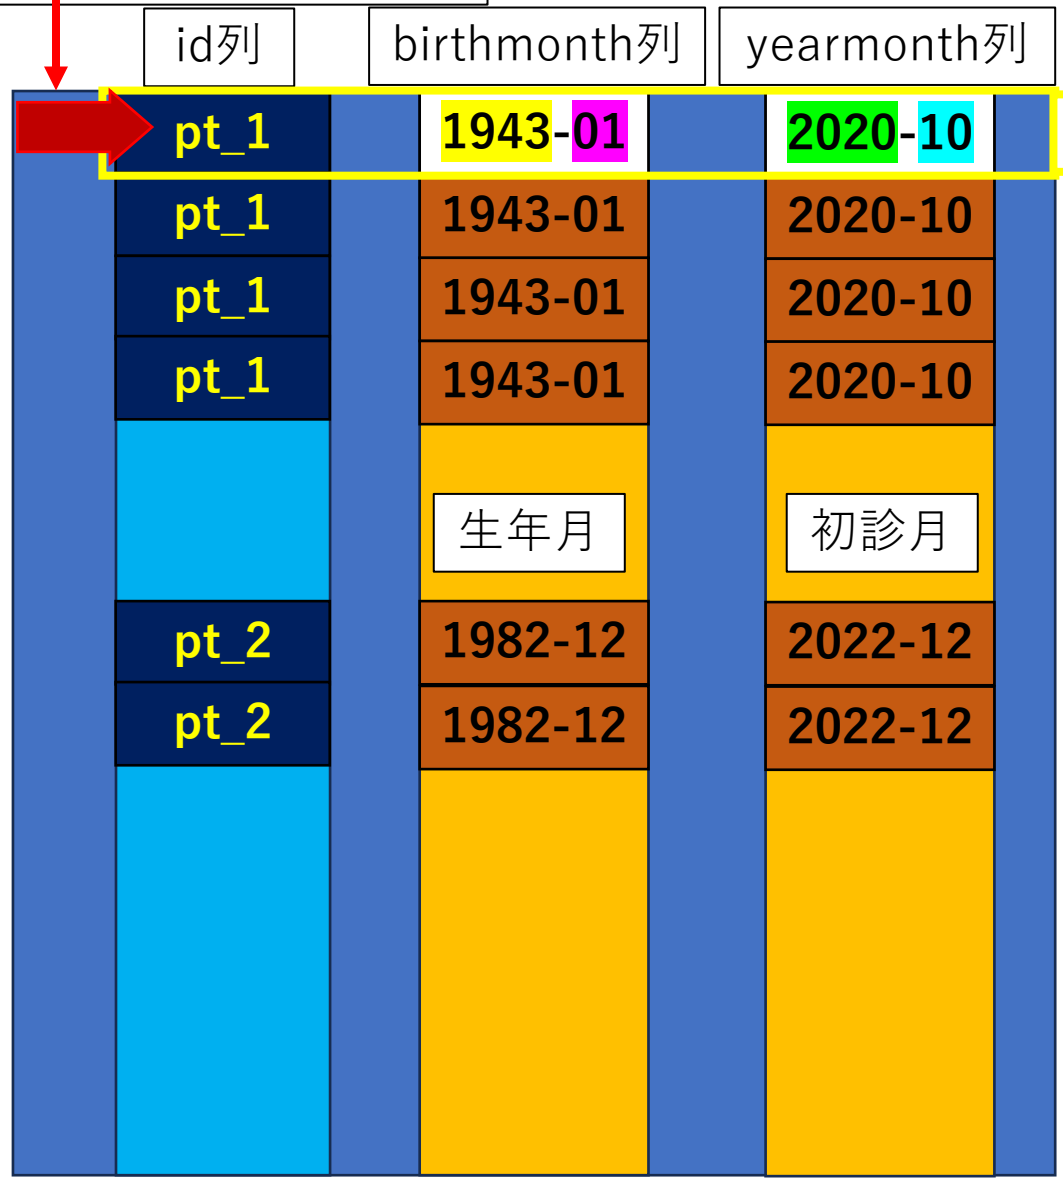

年と月を分解します

インデックス番号0

["1943", "01"]

```
Klist["birthmonth"][0].split("-")[0]
```

1943

```
Klist["birthmonth"][0].split("-")[1]
```

01

["2020", "10"]

```
Klist["yearmonth"][0].split("-")[0]
```

2020

```
Klist["yearmonth"][0].split("-")[1]
```

10

演習7データクレンジングとデータの可視化

患者年齢を求めましょう

Klistデータフレーム

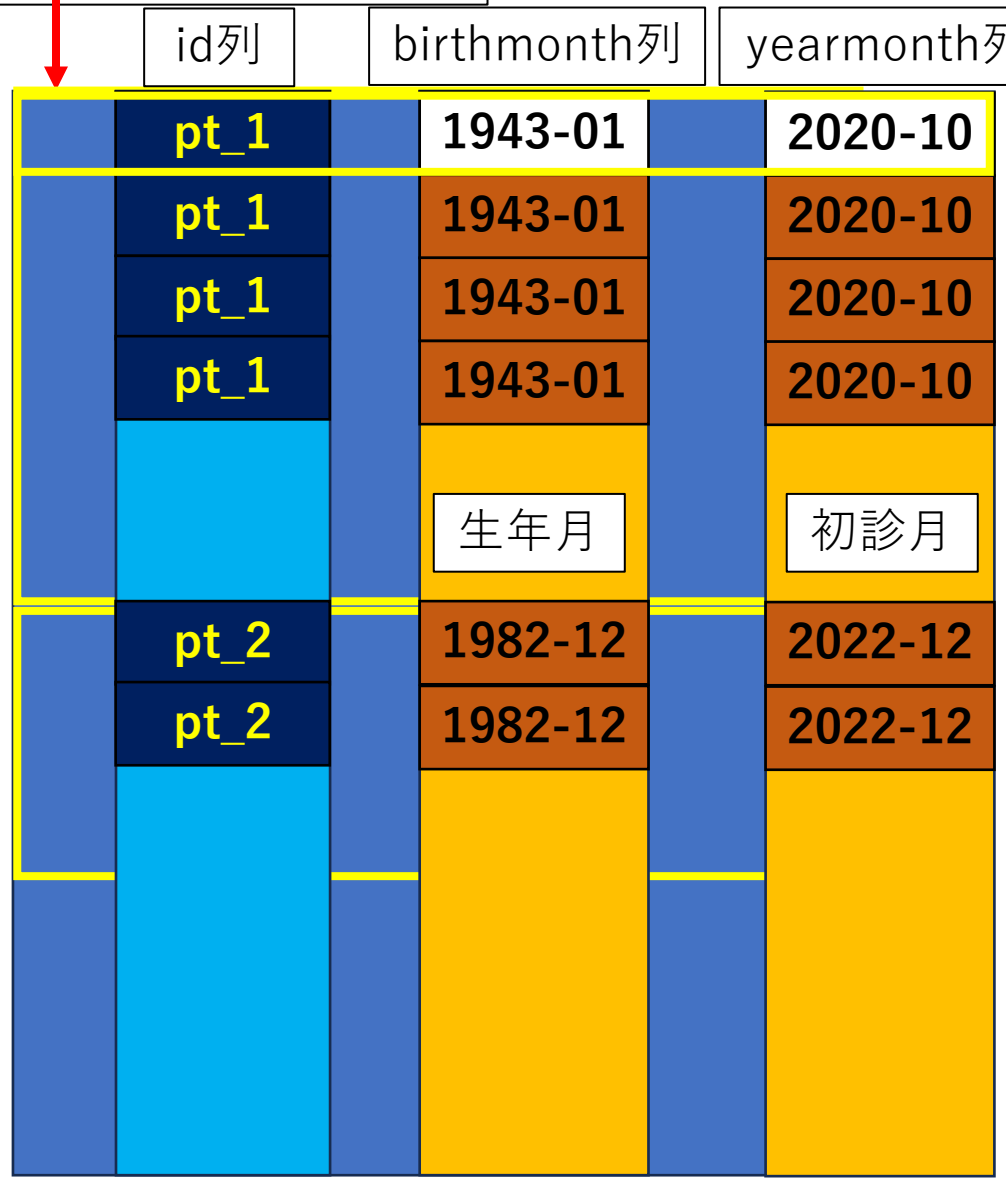

年と月を分解します

コード

```
print(Klist["birthmonth"][0].split("-")[0])
```

1943

```
print(Klist["birthmonth"][0].split("-")[1])
```

01

```
print(Klist["yearmonth"][0].split("-")[0])
```

2020

```
print(Klist["yearmonth"][0].split("-")[1])
```

10

演習7データクレンジングとデータの可視化

患者年齢を求めましょう

Klistデータフレーム

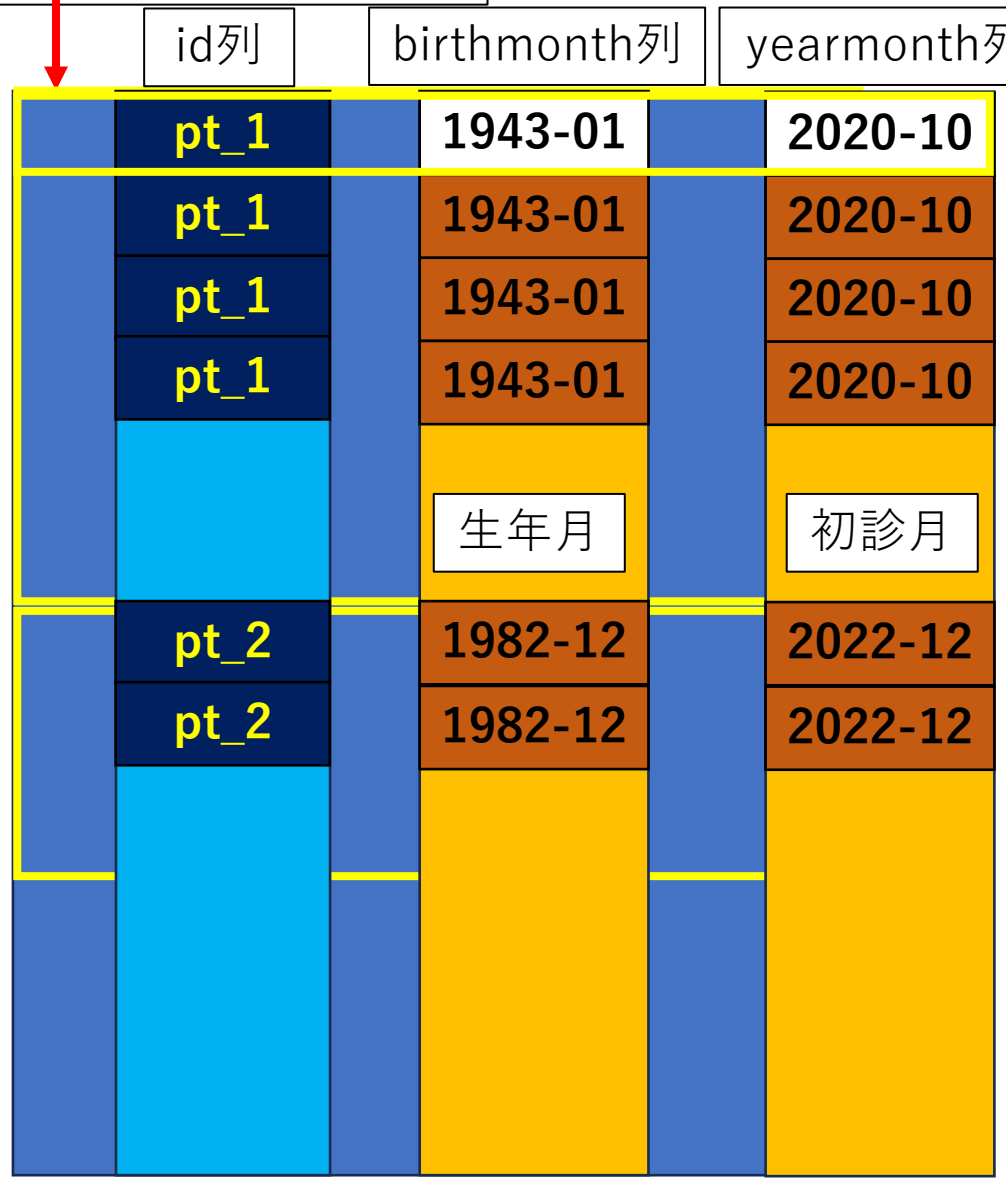

年と月を分解します

コード

```
print(Klist["birthmonth"][0].split("-")[0])
1943
print(Klist["birthmonth"][0].split("-")[1])
01
print(Klist["yearmonth"][0].split("-")[0])
2020
print(Klist["yearmonth"][0].split("-")[1])
10
```

文字列リストの要素であるため、型は文字です。比較演算子で比較するため、型を文字から整数に変換する必要があります。

演習7データクレンジングとデータの可視化

患者年齢を求めましょう

Klistデータフレーム

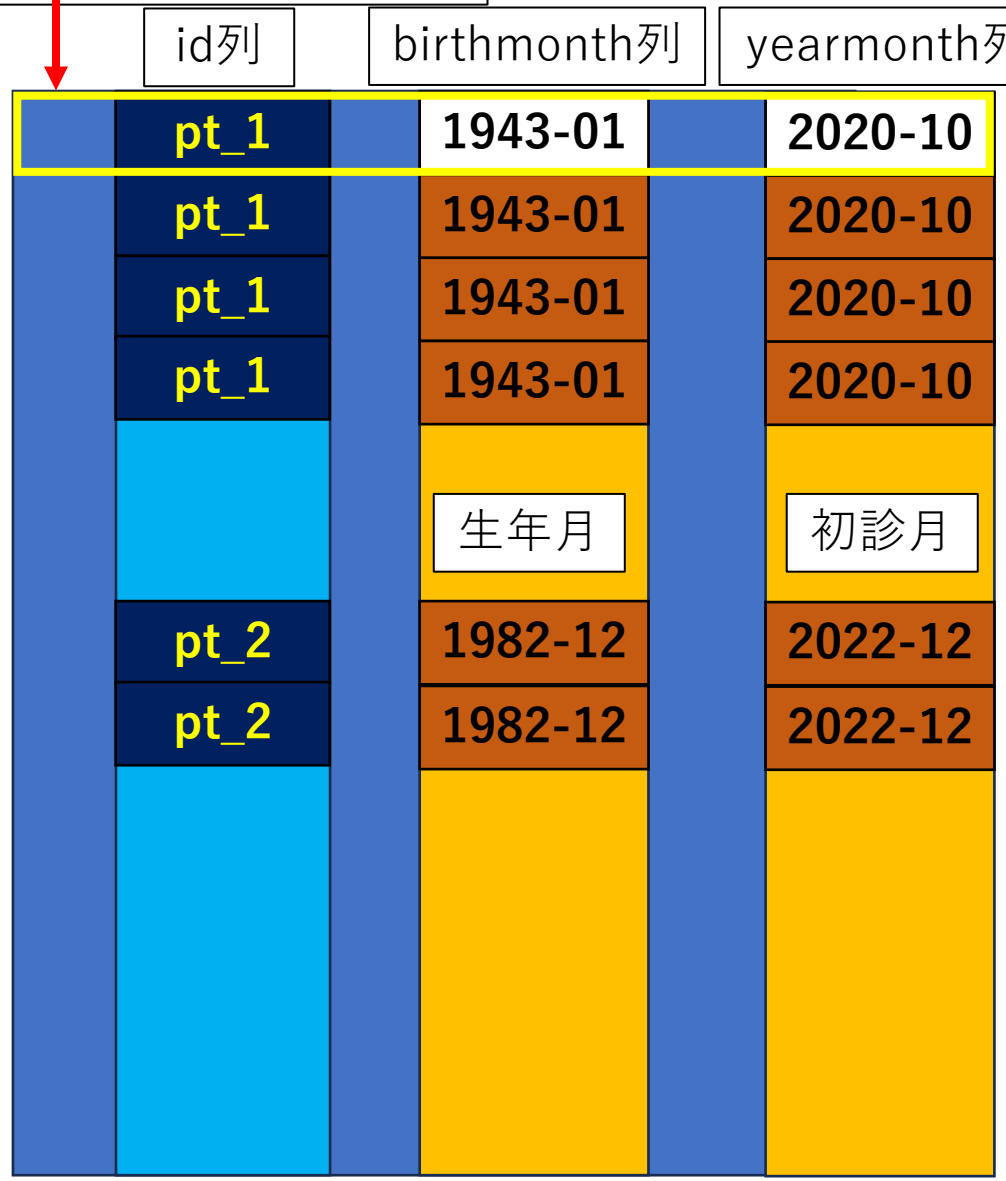

年と月をの型を整数に変換します

int() 関数は文字列の値を、整数に変換します。

コードの書き方：int(文字列)

コード　文字列 ⇨ 整数

```
print(int(Klist["birthmonth"][0].split("-")[0]))
```

1943

```
print(int(Klist["birthmonth"][0].split("-")[1]))
```

01

```
print(int(Klist["yearmonth"][0].split("-")[0]))
```

2020

```
print(int(Klist["yearmonth"][0].split("-")[1]))
```

10

演習7データクレンジングとデータの可視化

患者年齢を求めましょう

Klistデータフレーム

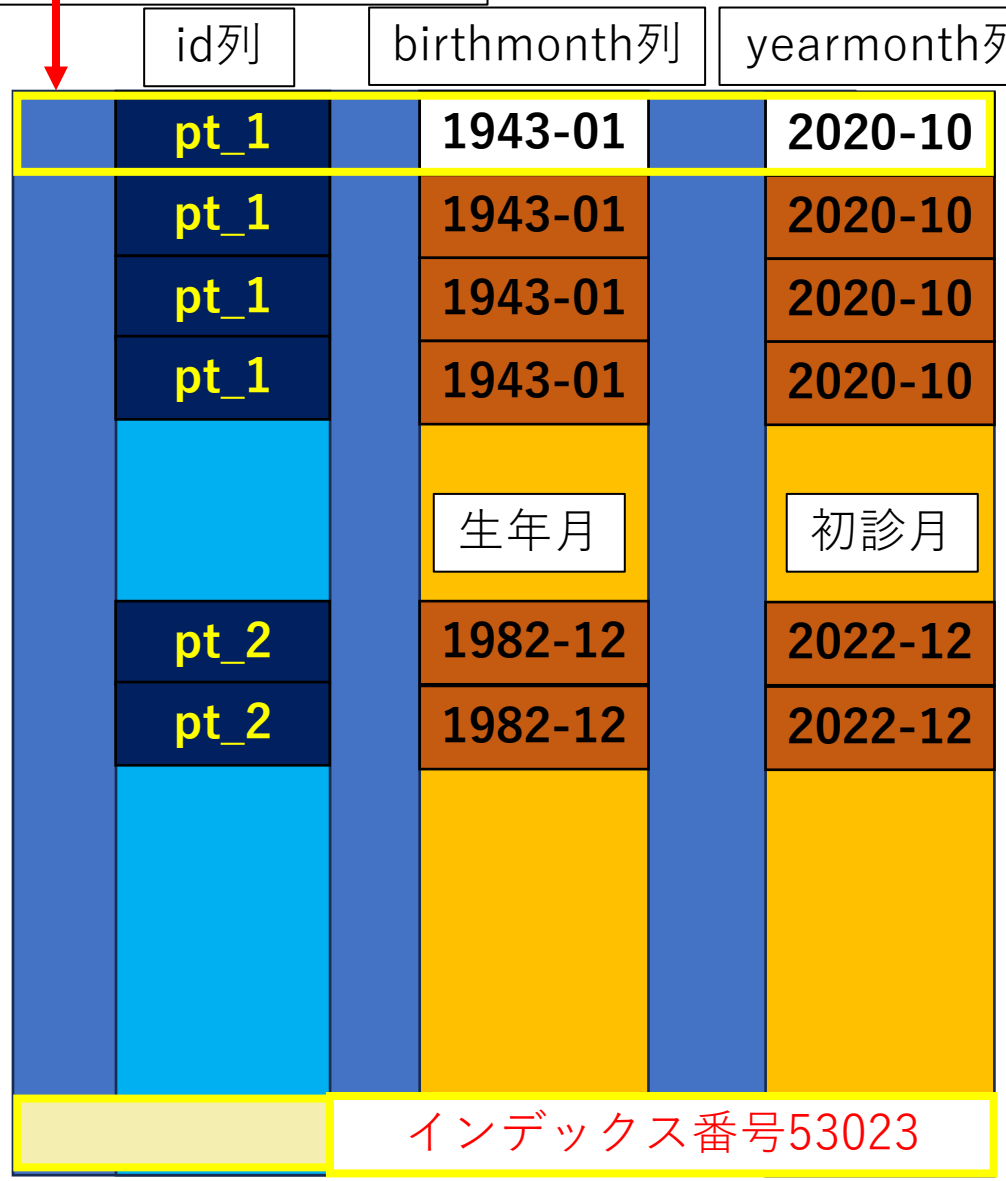

年と月をの型を整数に変換します

int() 関数は文字列の値を、整数に変換します。

コードの書き方：int(文字列)

コード　文字列 ⇨ 整数

Colab

```
print(int(Klist["birthmonth"][53023].split("-")[0]))
```

1982

```
print(int(Klist["birthmonth"][53023].split("-")[1]))
```

12

```
print(int(Klist["yearmonth"][53023].split("-")[0]))
```

2022

```
print(int(Klist["yearmonth"][53023].split("-")[1]))
```

12

演習7データクレンジングとデータの可視化

患者年齢を求めましょう

Klistデータフレーム

id列	birthmonth列	yearmonth列
pt_1	1943-01	2020-10
pt_1	1943-01	2020-10
pt_1	1943-01	2020-10
pt_1	1943-01	2020-10
	生年月	初診月
pt_2	1982-12	2022-12
pt_2	1982-12	2022-12

誕生日の年月と初診の年月を比較します。

インデックス番号0 ⇒ インデックス番号0

初診時の年齢

●歳
●歳
●歳
●歳
●歳
●歳

コード：

```
条件式で年齢を計算します
if 初診月 >= 誕生月:
   age =初診の年-生まれた年
else:
   age =初診の年-生まれた年-1
```

```
条件式で年齢を計算します          = ●歳
if visitmonth >= birthmonth:
   age = visityear - birthyear
else:
   age = visityear - birthyear -1
```

演習7データクレンジングとデータの可視化

患者年齢を求めましょう

Klistデータフレーム

id列	birthmonth列	yearmonth列
pt_1	1943-01	2020-10
pt_1	1943-01	2020-10
pt_1	1943-01	2020-10
pt_1	1943-01	2020-10
	生年月	初診月
pt_2	1982-12	2022-12
pt_2	1982-12	2022-12

インデックス番号0

コード：

```
birthyear = int(Klist["birthmonth"][0].split("-")[0])
birthmonth = int(Klist["birthmonth"][0].split("-")[1])
visityear = int(Klist["yearmonth"][0].split("-")[0])
visitmonth = int(Klist["yearmonth"][0].split("-")[1])

if visitmonth >= birthmonth:
    age = visityear - birthyear
else:
    age = visityear = birthyear -1

print(age)
```

＝●歳

初診時の年齢

インデックス番号0	
	●歳
	●歳
	●歳
	●歳
	●歳
	●歳

演習7データクレンジングとデータの可視化

患者年齢を求めましょう

Klistデータフレーム

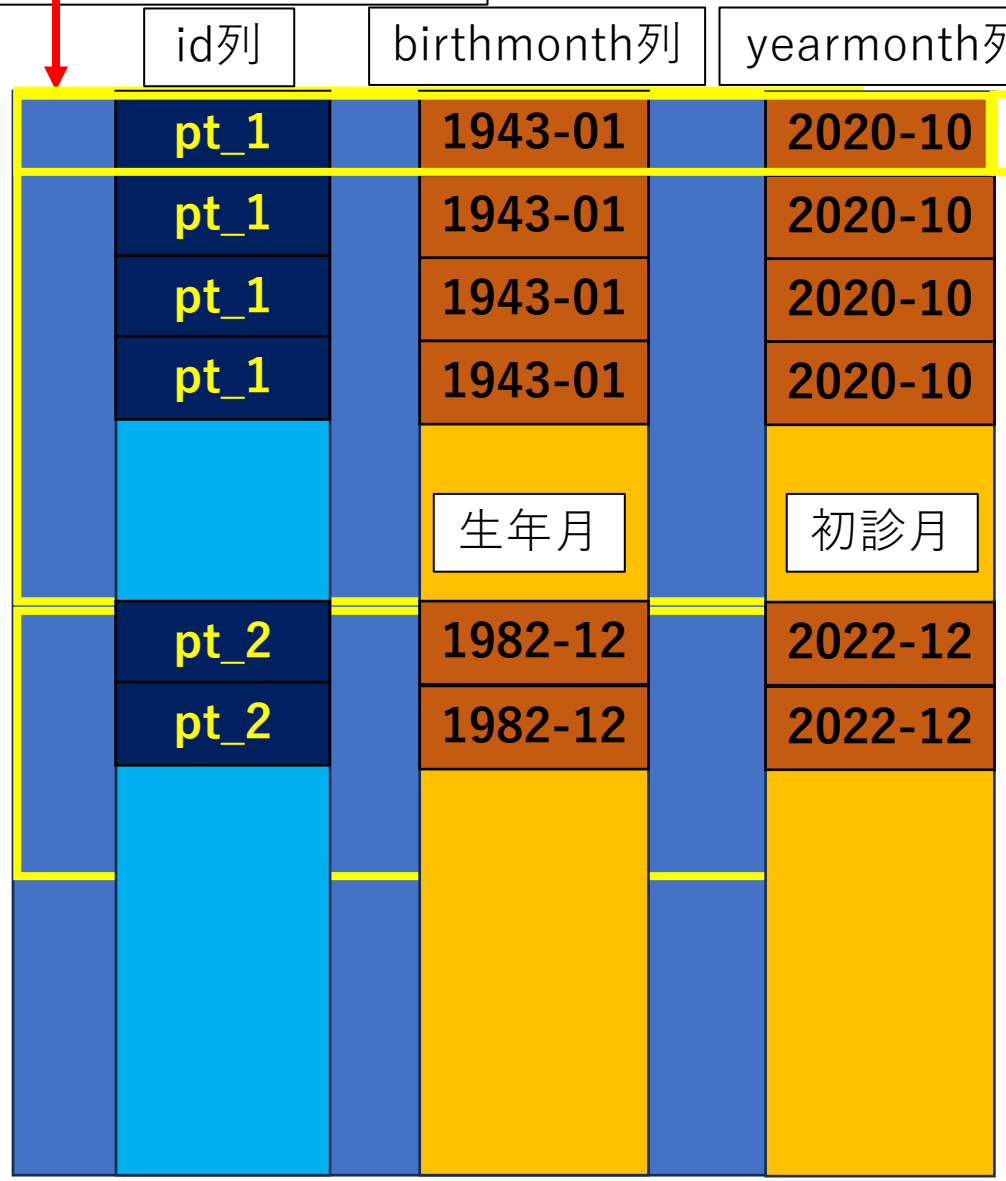

コード：

```
条件式で年齢を計算します
if 10 >= 01:
   age =2020-1943
else:
   age =初診の年-生まれた年-1
```

＝77歳

初診時の年齢

77歳
●歳
●歳
●歳
●歳
●歳

Colab

演習7データクレンジングとデータの可視化

患者年齢を求めましょう

Klistデータフレーム

id列	birthmonth列	yearmonth列
pt_1	1943-01	2020-10
pt_1	1943-01	2020-10
pt_1	1943-01	2020-10
pt_1	1943-01	2020-10
	生年月	初診月
pt_2	1982-12	2022-12
pt_2	1982-12	2022-12

インデックス番号0

コード：

```
条件式で年齢を計算します
if 初診月 >= 誕生月:
   age =初診の年-生まれた年
else:
   age =初診の年-生まれた年-1
```

初診時の年齢：age

77歳

●歳

●歳

●歳

●歳

●歳

演習7データクレンジングとデータの可視化

患者年齢を求めましょう

Klistデータフレーム

コード書き方：

新しいageという列を追加

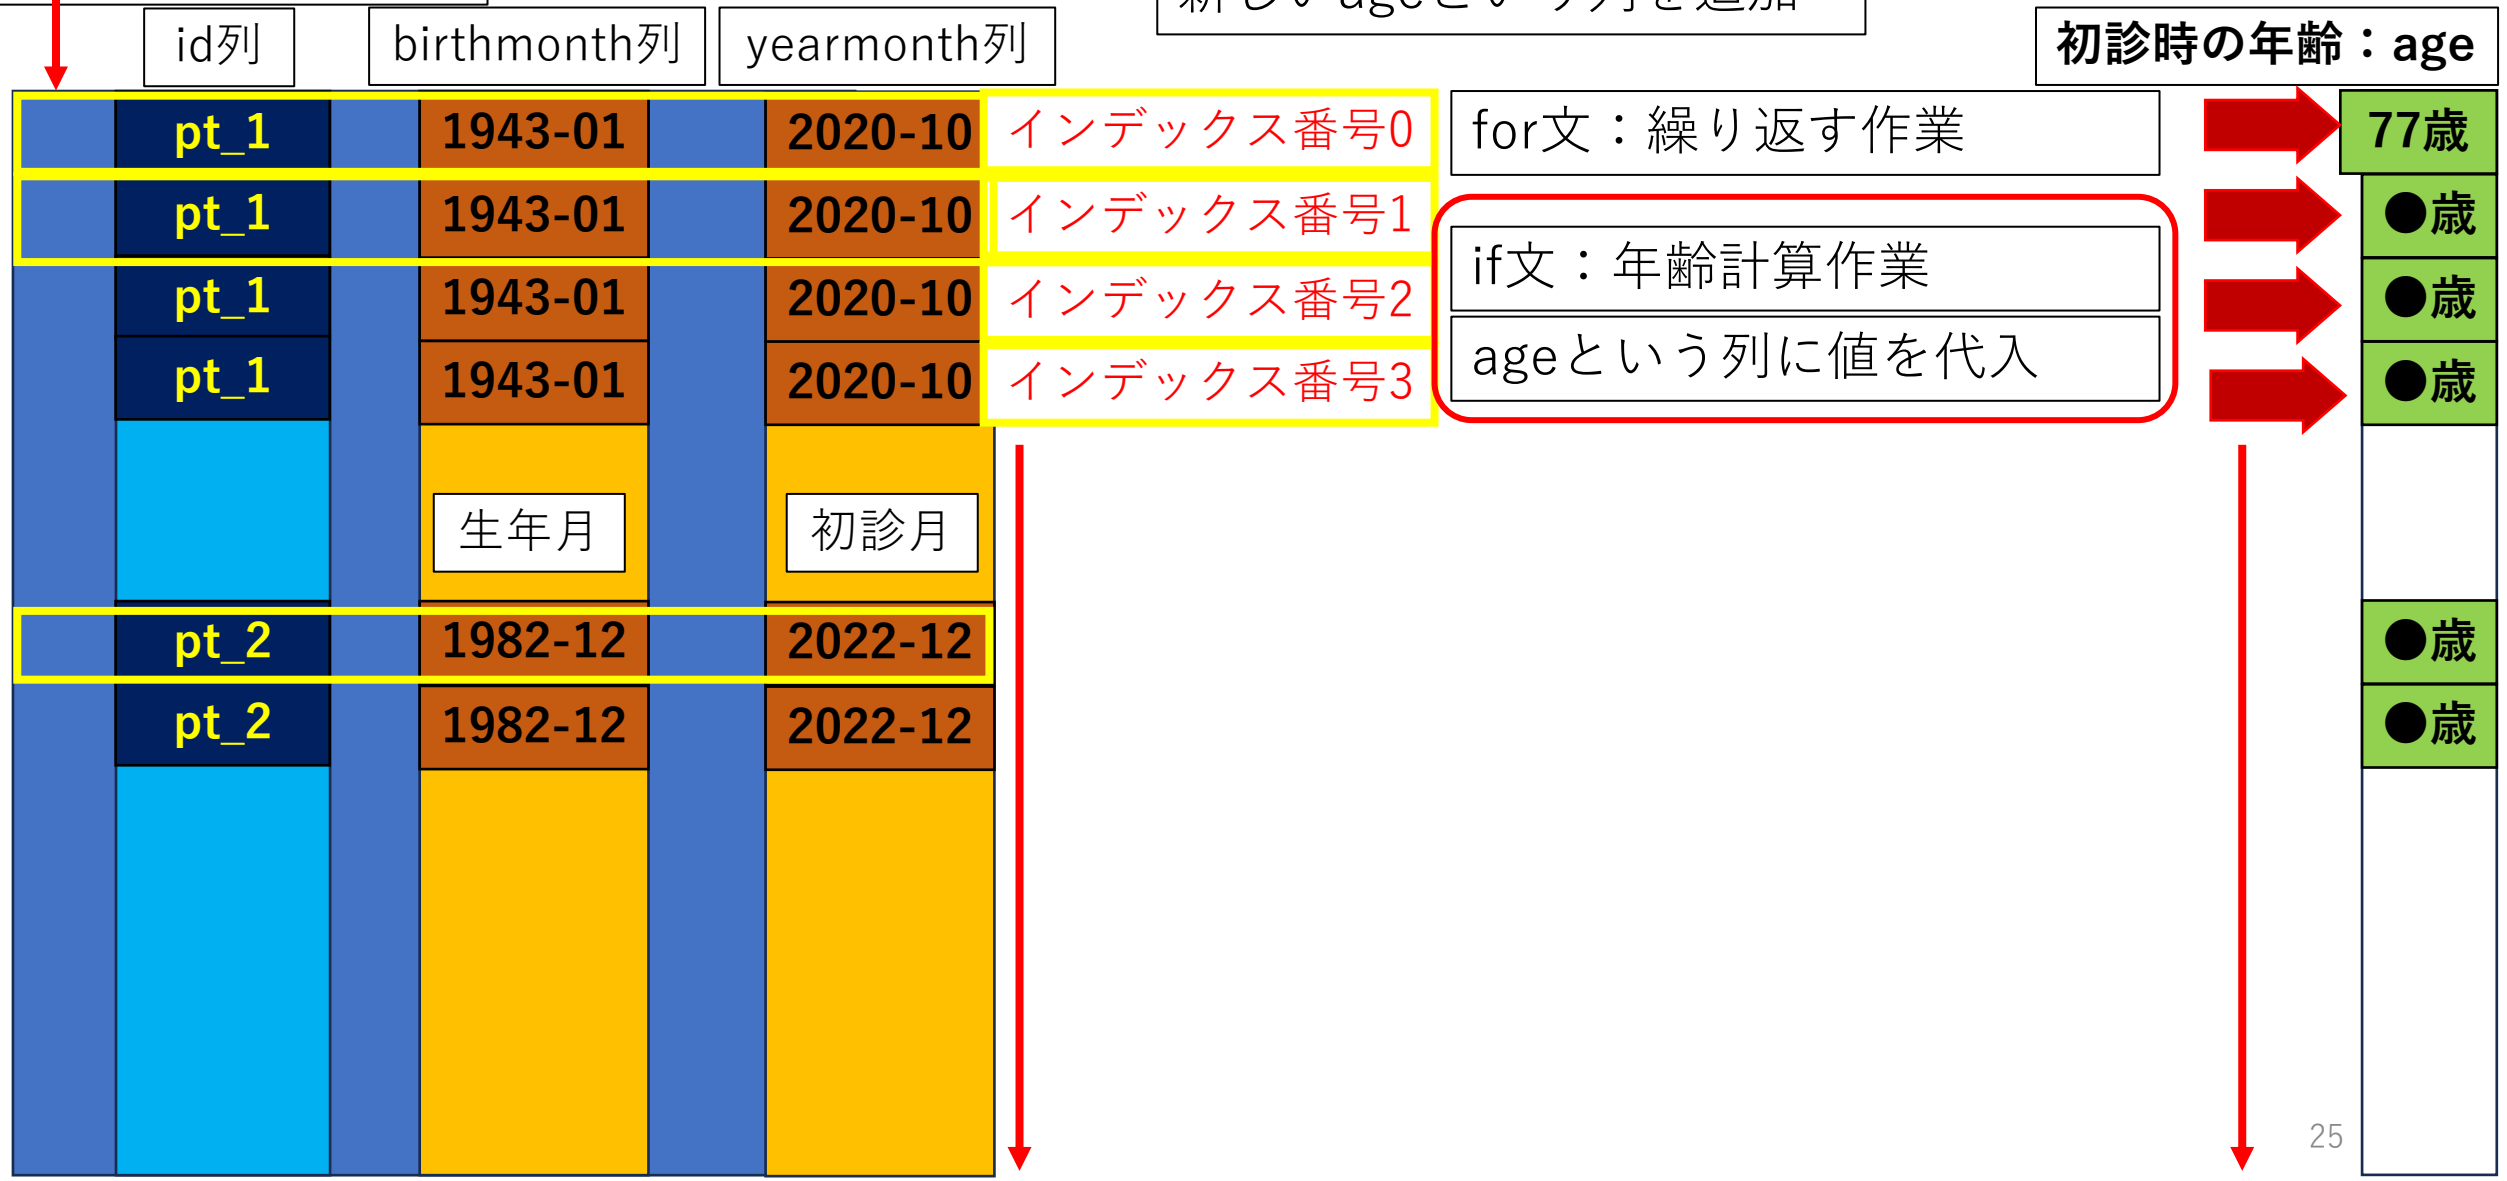

演習7データクレンジングとデータの可視化

患者年齢を求めましょう

Klistデータフレーム

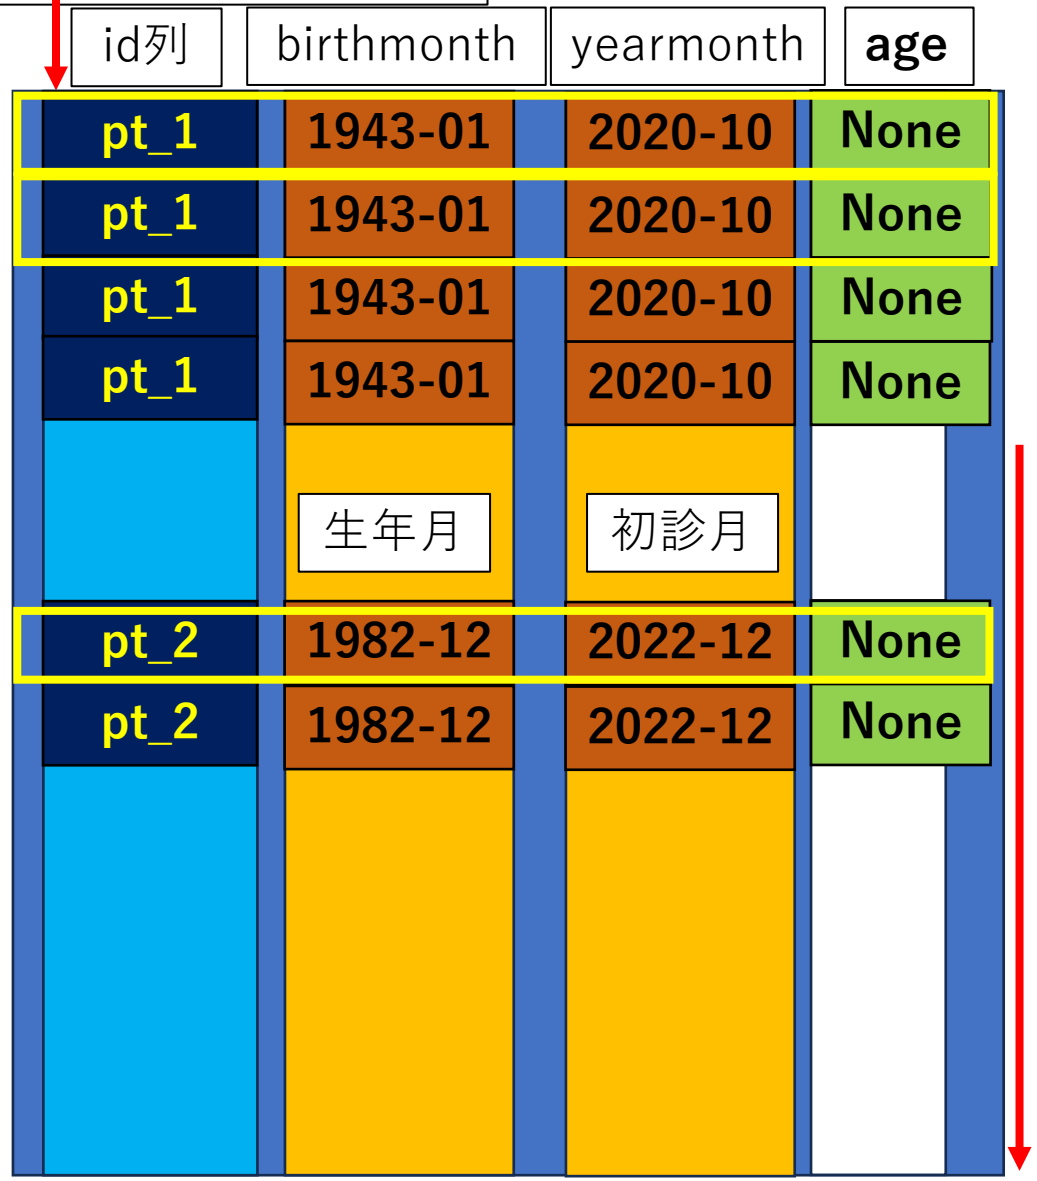

コード：

新しいageという列を追加

```
Klist["age"] = None
print(Klist)
```

演習7データクレンジングとデータの可視化

患者年齢を求めましょう

Klistデータフレーム

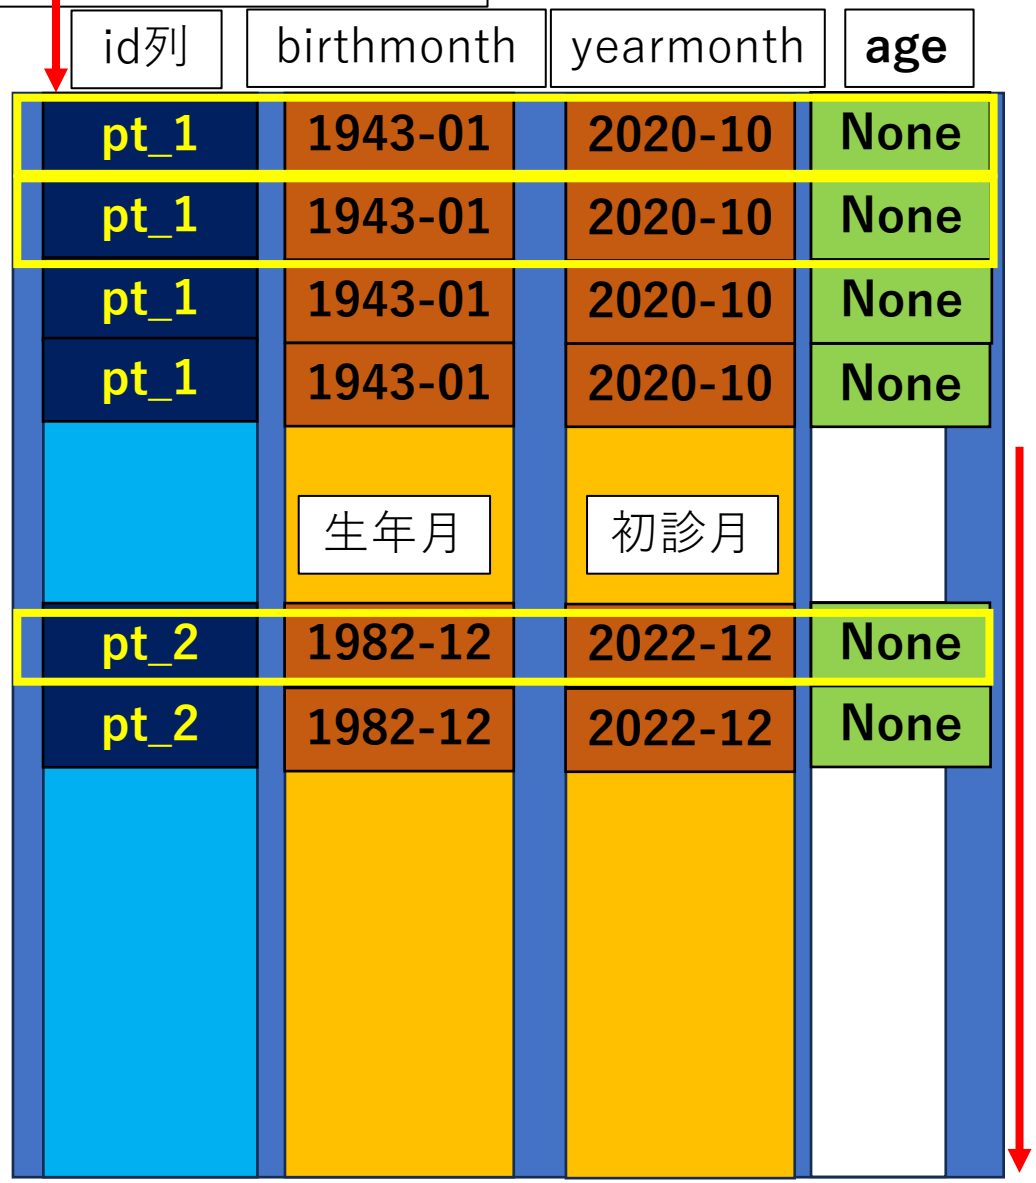

コード：

新しいageという列を追加

```
Klist["age"] = None
print(Klist)
```

for文：繰り返す作業

```
for i in range(len(Klist)):
```

演習7データクレンジングとデータの可視化

患者年齢を求めましょう

Klistデータフレーム

id列	birthmonth	yearmonth	age
pt_1	1943-01	2020-10	None
pt_1	1943-01	2020-10	None
pt_1	1943-01	2020-10	None
pt_1	1943-01	2020-10	None
	生年月	初診月	
pt_2	1982-12	2022-12	None
pt_2	1982-12	2022-12	None

コード：

新しいageという列を追加

```
Klist["age"] = None
print(Klist)
```

for文：繰り返す作業

```
for i in range(len(Klist)):
    birthmonth = int(Klist['birthmonth'][i].split('-')[1])
    birthyear = int(Klist['birthmonth'][i].split('-')[0])
    visitmonth = int(Klist["yearmonth"][i].split('-')[1])
    visityear = int(Klist["yearmonth"][i].split('-')[0])
    if visitmonth >= birthmonth:
      age = visityear - birthyear
    else:
      age = visityear - birthyear-1
```

演習7データクレンジングとデータの可視化

患者年齢を求めましょう

Klistデータフレーム

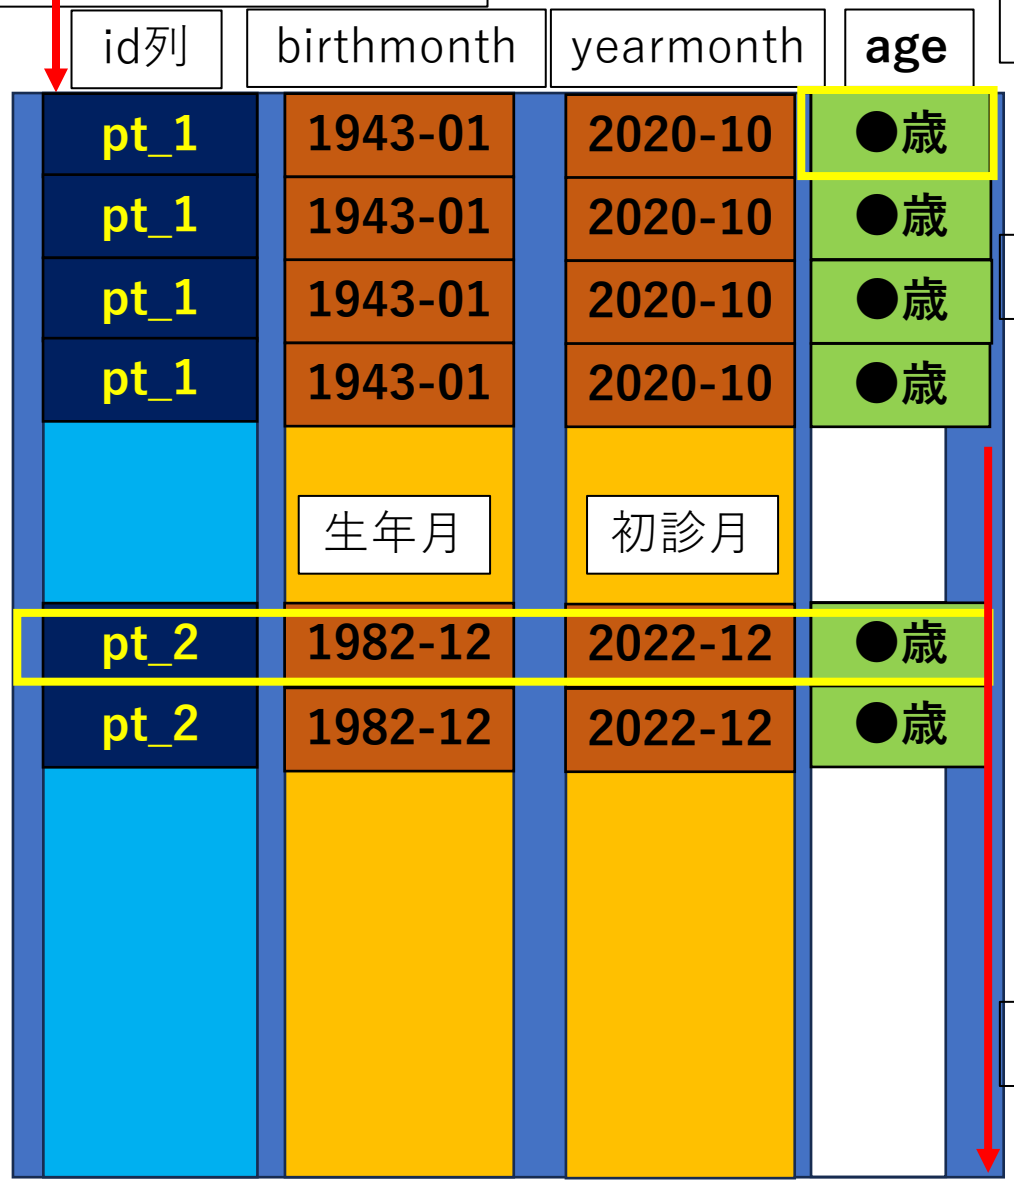

コード：

新しいageという列を追加

```
Klist["age"] = None
print(Klist)
```

for文：繰り返す作業

```
for i in range(len(Klist)):
    birthmonth = int(Klist['birthmonth'][i].split('-')[1])
    birthyear = int(Klist['birthmonth'][i].split('-')[0])
    visitmonth = int(Klist["yearmonth"][i].split('-')[1])
    visityear = int(Klist["yearmonth"][i].split('-')[0])
    if visitmonth >= birthmonth:
      age = visityear - birthyear
    else:
      age = visityear - birthyear-1
```

ageという列に値を代入

```
Klist["age"][i]=age
```

演習7データクレンジングとデータの可視化

患者年齢を求めましょう

```
print(Klist)
```

```
      tooth name tooth record gender       id birthmonth yearmonth  ¥
0            A1          残存歯      男     pt_1    1943-01   2020-10
1            A2          喪失歯      男     pt_1    1943-01   2020-10
2            A3          残存歯      男     pt_1    1943-01   2020-10
3            A4          残存歯      男     pt_1    1943-01   2020-10
4            A5          残存歯      男     pt_1    1943-01   2020-10
...         ...          ...    ...      ...        ...       ...
53019        D4          喪失歯      女  pt_1657    1982-12   2022-12
53020        D5          残存歯      女  pt_1657    1982-12   2022-12
53021        D6          残存歯      女  pt_1657    1982-12   2022-12
53022        D7          喪失歯      女  pt_1657    1982-12   2022-12
53023        D8          残存歯      女  pt_1657    1982-12   2022-12

      tooth exist age
0                1  77
1                0  77
2                1  77
3                1  77
4                1  77
...            ...  ..
53019            0  40
53020            1  40
53021            1  40
53022            0  40
53023            1  40

[53024 rows x 8 columns]
```

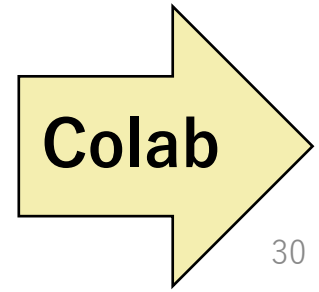

演習7データクレンジングとデータの可視化

散布図を作りましょう

患者年齢と歯の本数の関係

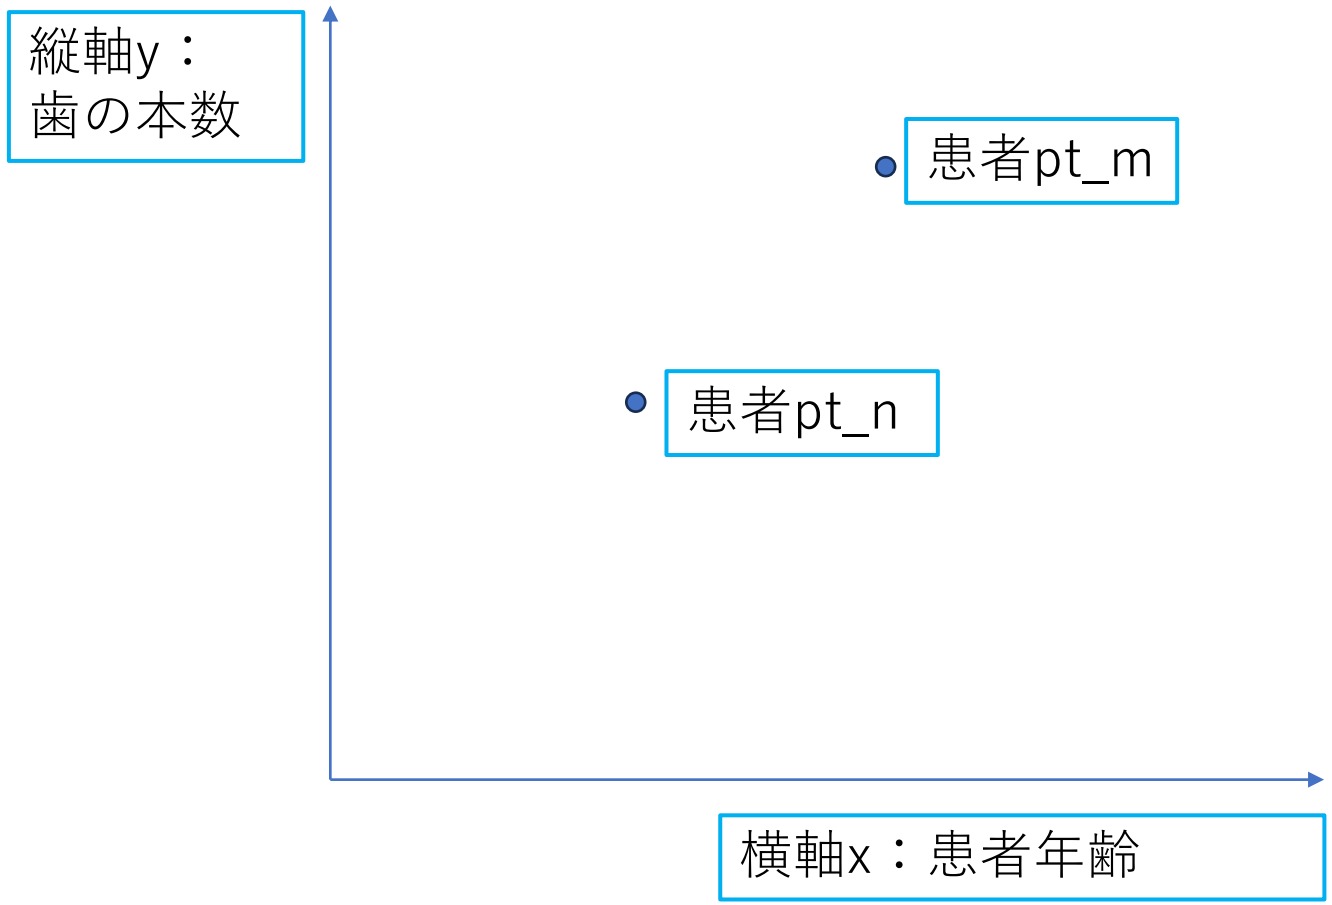

演習7データクレンジングとデータの可視化

散布図を作りましょう

患者年齢と歯の本数の関係

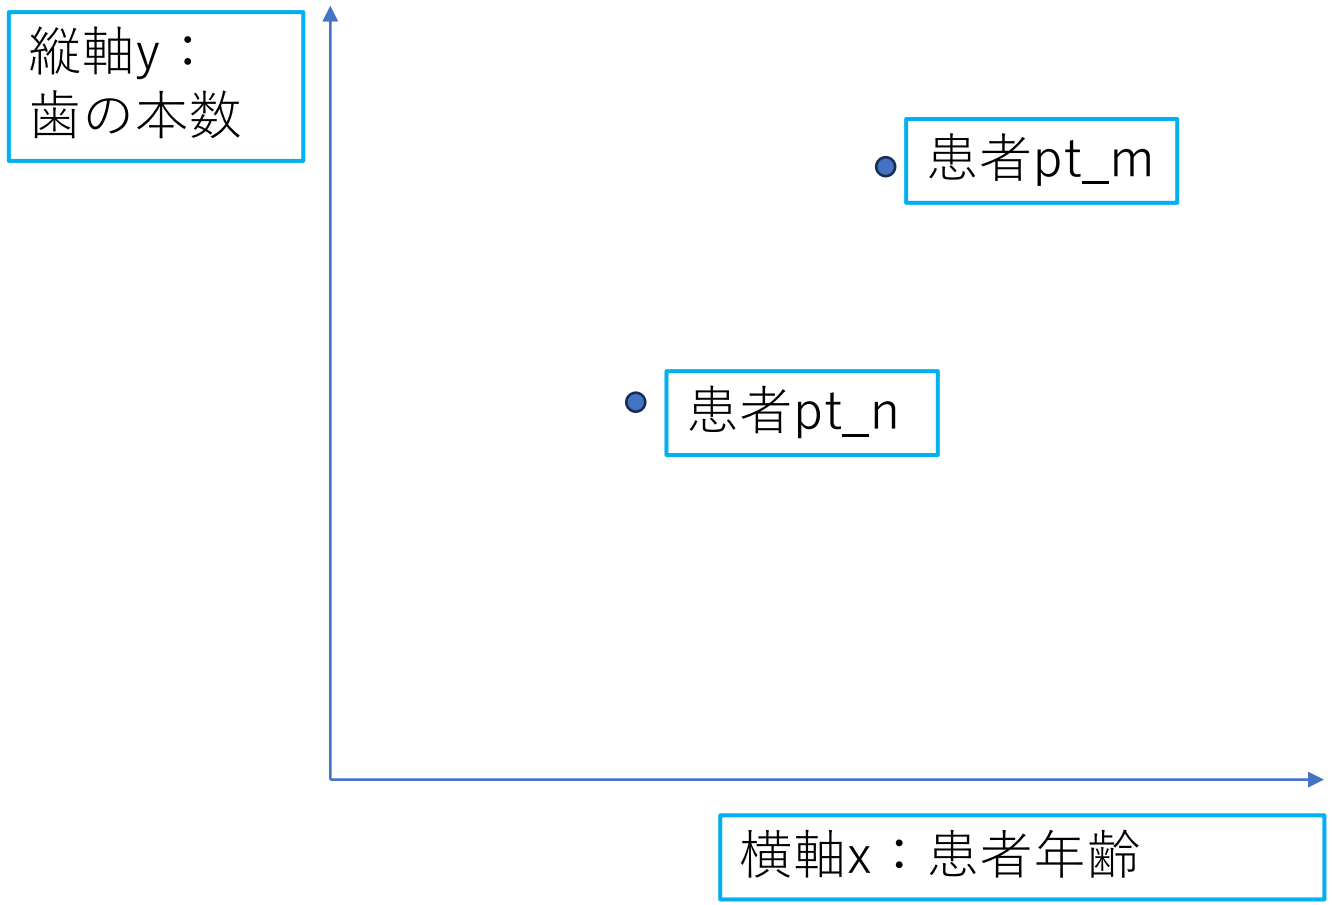

	横軸x	縦軸y
患者pt_n	●歳	●本
患者pt_m	●歳	●本
	numpy配列	numpy配列

演習7データクレンジングとデータの可視化

散布図を作りましょう

患者年齢と歯の本数の関係

	横軸x	縦軸y
患者pt_n	●歳	●本
患者pt_m	●歳	●本

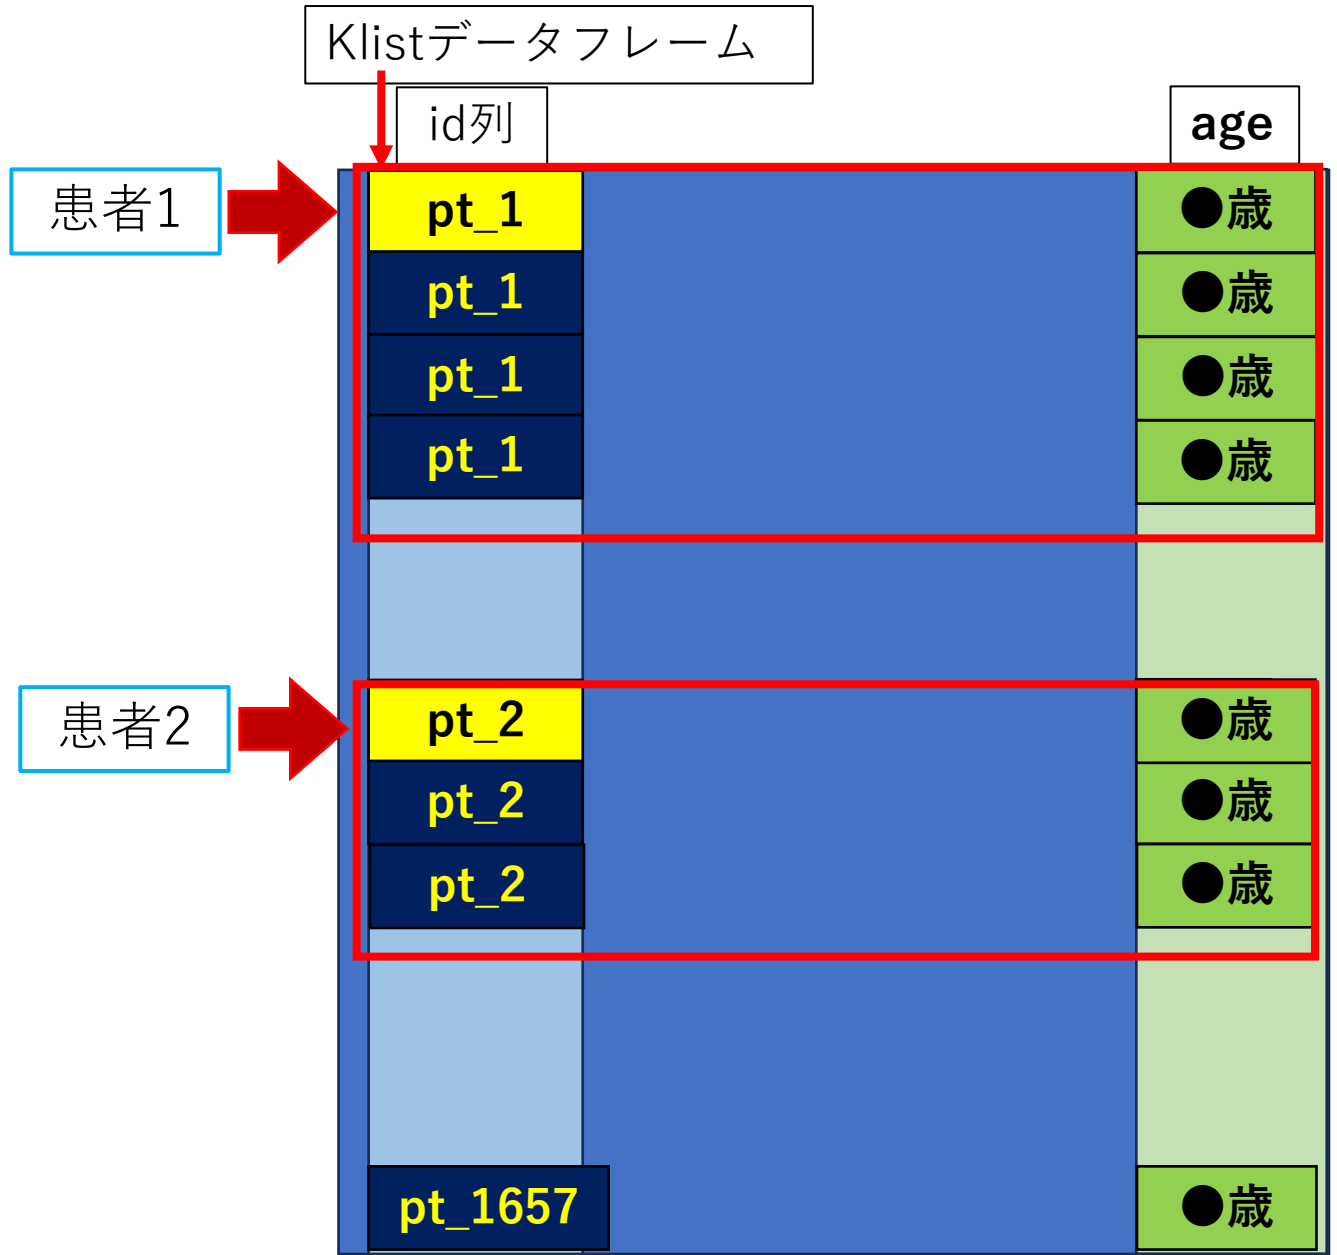

演習7データクレンジングとデータの可視化

散布図を作りましょう

患者年齢と歯の本数の関係

	横軸x	縦軸y
患者pt_n	●歳	●本
患者pt_m	●歳	●本

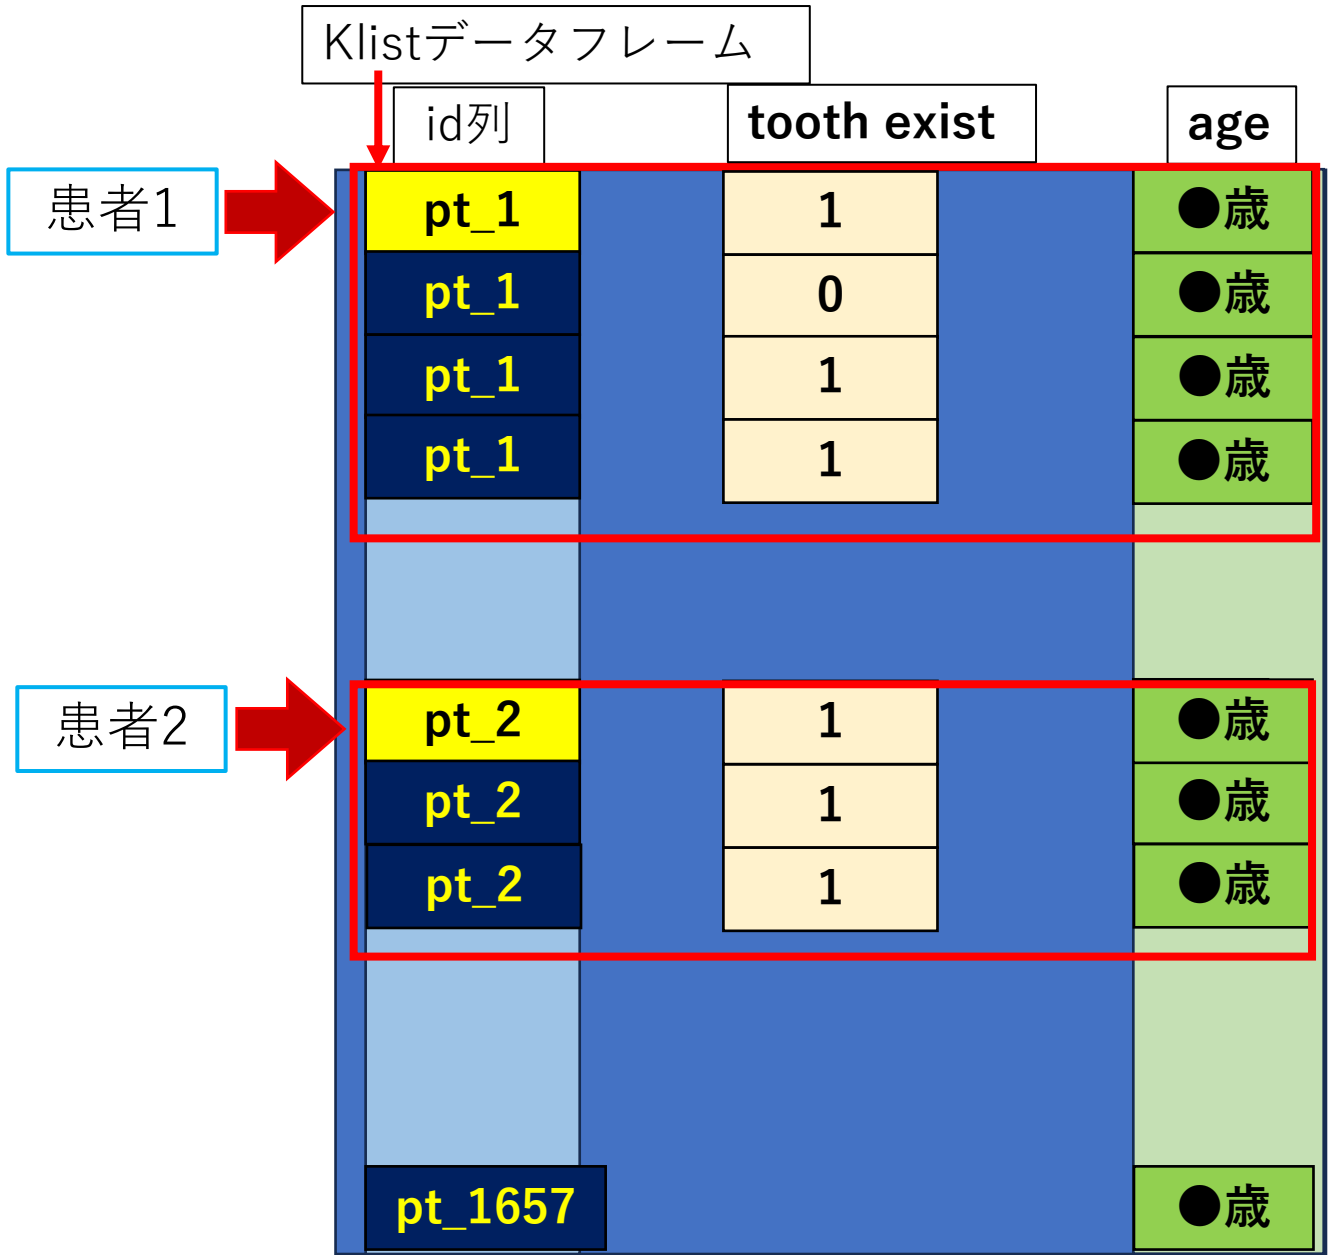

演習7データクレンジングとデータの可視化

散布図を作りましょう

患者年齢と歯の本数の関係

	横軸x	縦軸y
患者pt_n	●歳	●本
患者pt_m	●歳	●本
	numpy配列	numpy配列

横軸x　コード

```
x = Klist.groupby("id")["age"].mean()
print(x)
```

縦軸y　コード

```
y = Klist.groupby("id")["tooth exist"].sum()
print(y)
```

Pandasの**groupbyメソッド**は、
列を指定してデータをグループ化し、それぞれのグループに対して集計できます。

列Aでグループ化し、列Bを集計します。
DataFrame名.groupby("A")["B"].mean()

列Aでグループ化し、列Bを集計します。
DataFrame名.groupby("A")["B"].sum()

演習7データクレンジングとデータの可視化

散布図を作りましょう

患者年齢と歯の本数の関係

	横軸x	縦軸y
患者pt_n	●歳	●本
患者pt_m	●歳	●本
	numpy 配列	numpy 配列

横軸x

コード

```
x = Klist.groupby("id")["age"].mean()
print(x)
```

```
id
pt_1       77.0
pt_10      76.0
pt_100     72.0
pt_1000    54.0
pt_1001    56.0
           ...
pt_995     55.0
pt_996     55.0
pt_997     55.0
pt_998     53.0
pt_999     55.0
Name: age, Length: 1657, dtype: float64
```

演習7データクレンジングとデータの可視化

散布図を作りましょう

患者年齢と歯の本数の関係

	横軸x	縦軸y
患者pt_n	●歳	●本
患者pt_m	●歳	●本
	numpy 配列	numpy 配列

縦軸y

コード

```
y = Klist.groupby("id")["tooth exist"].sum()
print(y)
```

```
id
pt_1       24
pt_10      25
pt_100     26
pt_1000    25
pt_1001    29
           ..
pt_995     30
pt_996     24
pt_997     24
pt_998     26
pt_999     24
Name: tooth exist, Length: 1657, dtype: object
```

Colab

演習7データクレンジングとデータの可視化

散布図を作りましょう

患者年齢と歯の本数の関係

	横軸x	縦軸y
患者pt_n	●歳	●本
患者pt_m	●歳	●本
	numpy配列	numpy配列

コード

```
import numpy as np

x = np.array(x)
y = np.array(y)
```

演習7データクレンジングとデータの可視化

散布図を作りましょう　患者年齢と歯の本数の関係

コード

matplotlibライブラリと日本語入力方法をインポートします。

```
import matplotlib.pyplot as plt
!pip install japanize-matplotlib
import japanize_matplotlib
```

matplotlibライブラリで散布図を作成します。

```
plt.figure()
plt.title('散布図：年齢と歯の本数')
plt.xlabel('年齢')
plt.ylabel('歯の本数')
plt.grid()
plt.scatter(x,y)
plt.show()
```

演習7データクレンジングとデータの可視化

散布図を作りましょう

患者年齢と歯の本数の関係

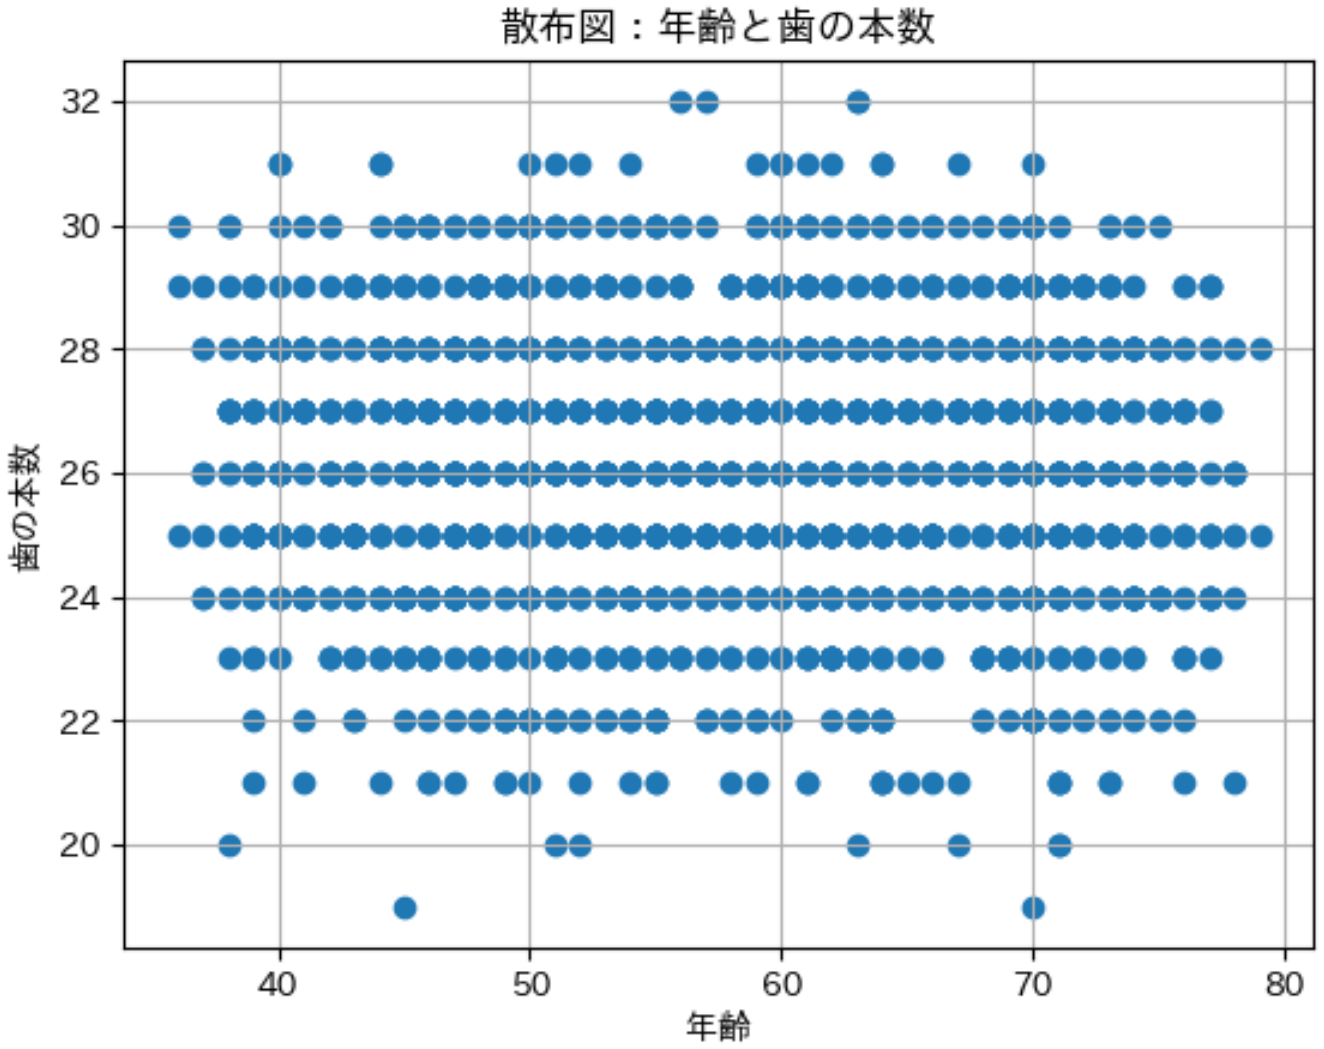

Colab

WebClassで課題を提出してください、締め切りは1月11日23:59までです。

課題1：print関数を使って、コードを1行に書いてください。
Klistデータフレームのid列のインデックス番号1行の文字データ（pt_1）をsplit()メソッドを使って、アルファベットと数字の部分を分解し、また数字の部分を整数に変換してください。
データフレーム名：Klist
列名："id"
インデックス番号：1
文字データ： "pt_1"
区切り文字：_

課題2：matplotlibのpyplotモジュールをインポートするコードを書いてください。略称は、pltとします。

演習授業中の質問対応について

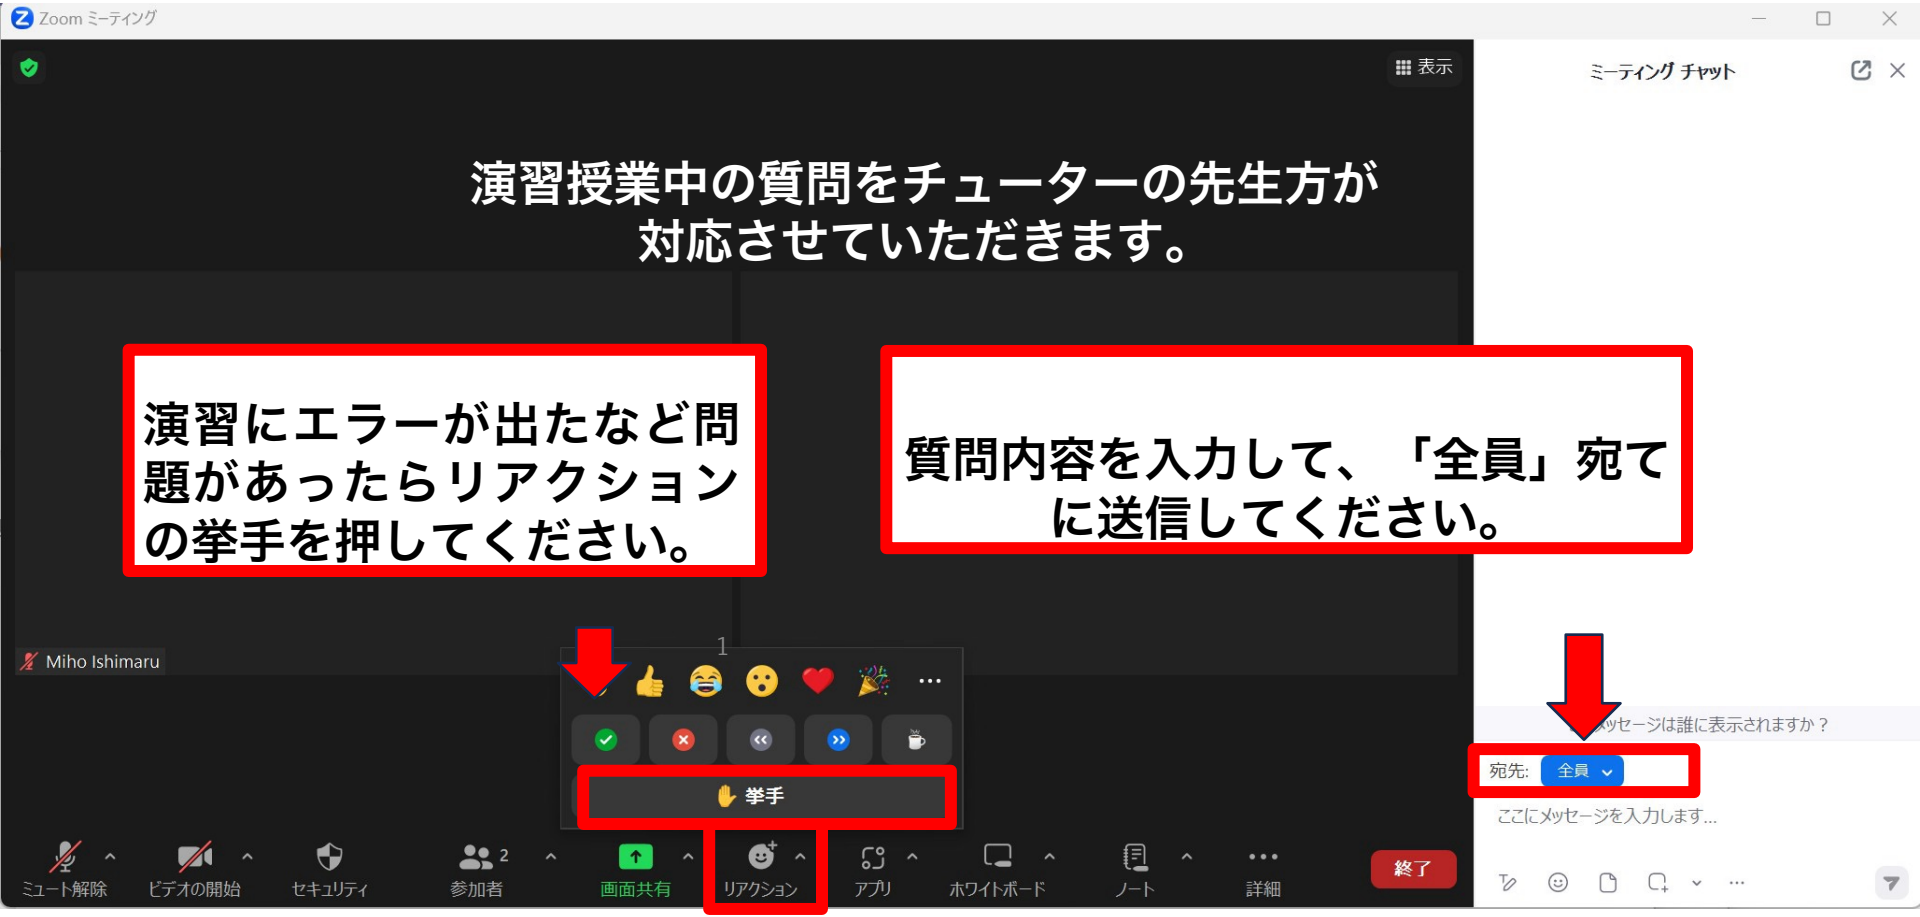

2024/1/11 11:35-12:20

医療とAI・ビッグデータ入門

演習8

回帰

統合教育機構
石丸美穂

演習8-20の概要

- 今までの演習1~7ではGoogle ColaboratoryでPythonの基礎的な概念の説明や診療情報データのデータクレンジングを実施した
  Numpy, Pandasの基礎的な使い方について習得
- 演習8~20ではGoogle Colaboratoryで機械学習・深層学習を行います
- 今回からは、Pythonで利用できるサンプルデータを利用します

演習8-20の概要

機械学習の分類

教師あり学習	教師なし学習	深層学習 (Deep Learning)
▲	▲	▲
演習8~演習14	医療とAI・ビッグデータ応用で取り扱い予定	演習15~演習20

教師あり機械学習

教師あり機械学習は特徴のデータ(絵や色など）と「正解」をセットで学習させて識別器を作る

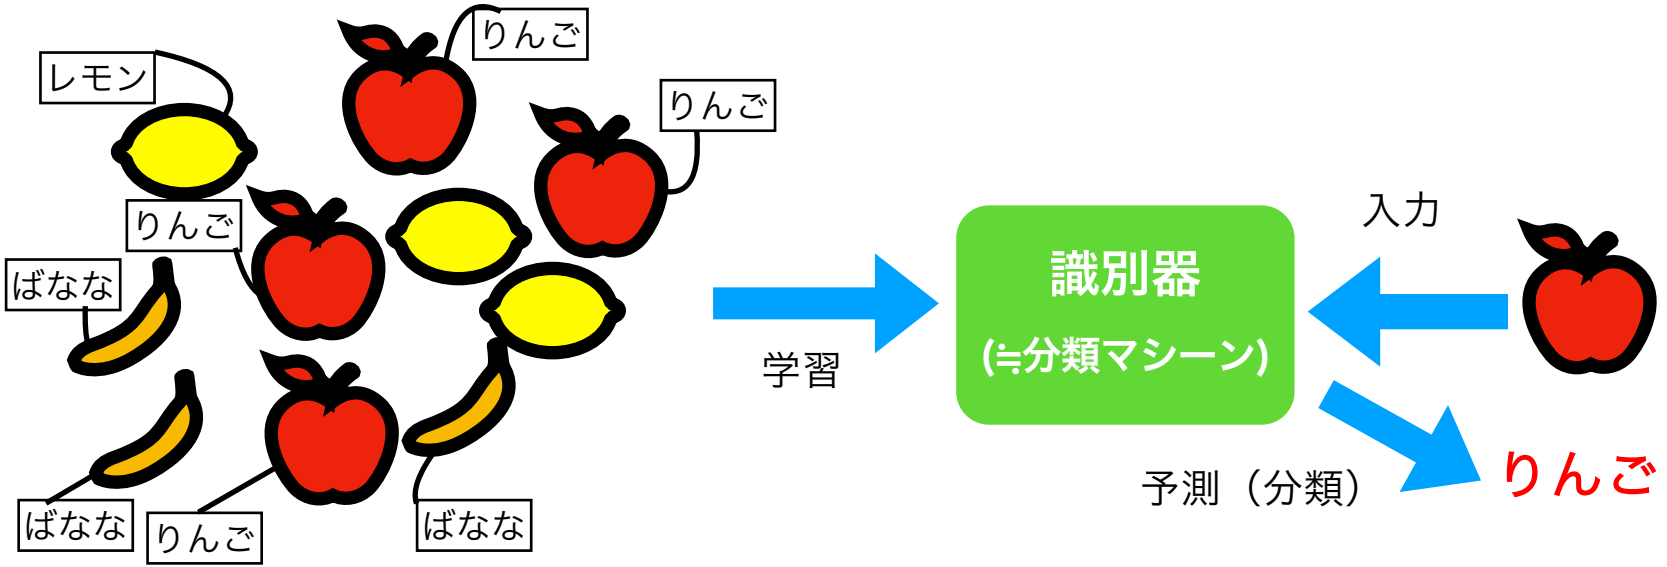

機械学習

医療とAI・ビッグデータ入門の演習8~14では、医療分野でよく使われている「教師あり機械学習」について実践していきます

教師あり機械学習のアルゴリズム（方法）はたくさんある

最初に回帰分析のアルゴリズムを実践

回帰分析

回帰は与えられたデータを関数（式）に当てはめる方法

線形回帰式

$$y = b_0 + b_1x_1 + b_2x_2 + \cdots + b_nx_n$$

(y：目的変数、x_n：説明変数、b_0：切片、b_n：傾き)

説明変数とは、機械学習でいう「特徴量」（特徴のデータ）
目的変数とは、「正解の値」

特徴量が1つ(n=1)の時、単回帰と呼ぶ

$$y = b_0 + b_1x_1$$

単回帰の基礎

単回帰で演習7で取り扱った
y＝現在歯数、x=年齢 の二つの変数の関連を調べる

5人の患者の年齢と現在歯数のデータ

被験者	年齢	歯の本数
1	21	32
2	45	22
3	62	14
4	77	9
5	88	4

散布図

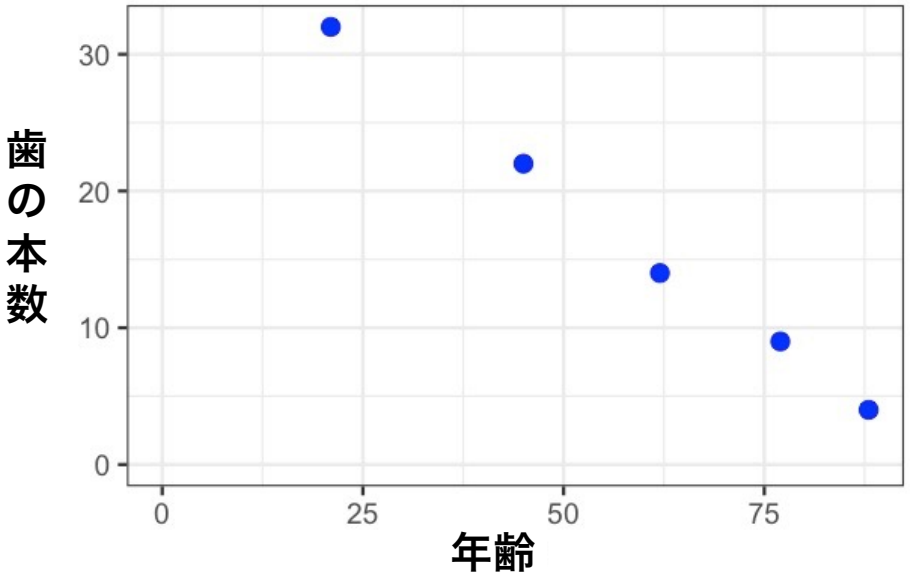

単回帰の基礎

5人の年齢と歯数の散布図を描出した

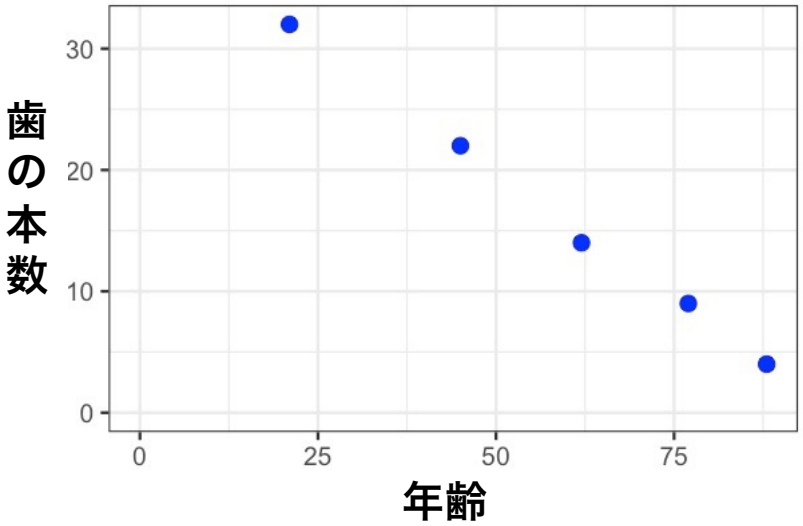

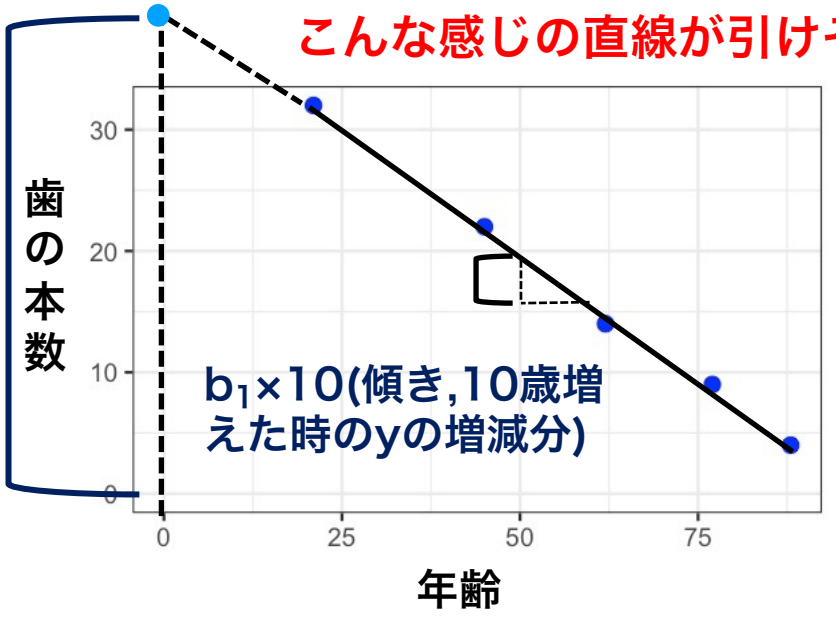

$y = b_0 + b_1 x_1$ → b_0は40ぐらい？ b_1は-0.4ぐらい？

このようにデータを直線の式に当てはめる回帰を線形回帰と呼ぶ

回帰の基礎

特徴量(x)と正解値(y)の関係を線形モデルやロジスティックモデルに近似して予測することを回帰分析と呼ぶ

*モデルとはデータに内在する構造的な関係

医学系では生物統計（医療統計）の文脈でオッズ比や偏回帰係数を求めることを目的として使うことが多いが、今回は機械学習（yを予測することを目的）で用いる

回帰の基礎

回帰式を使って「予測」をしてみよう

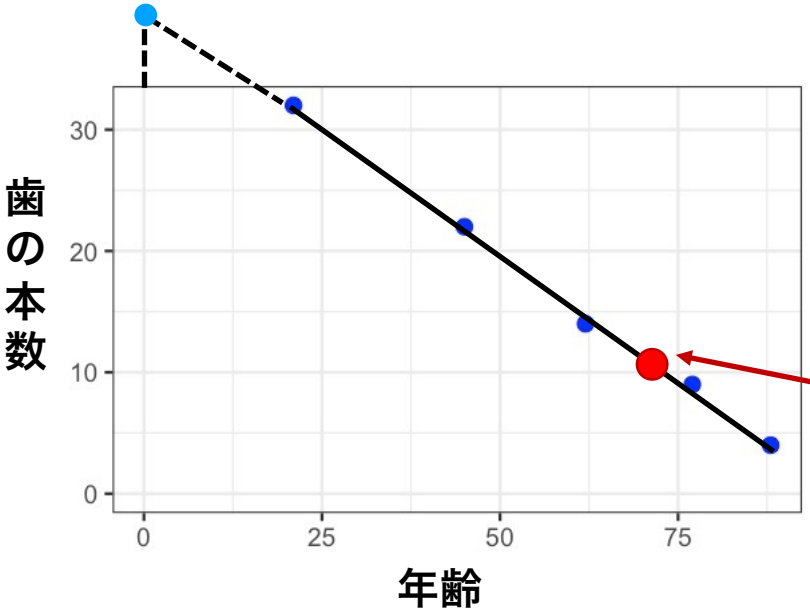

←単回帰モデルの切片と傾きを計算して求める

切片 = 40.6　　傾き = -0.42

$$y = 40.6 + (-0.42) \times age$$

age =70（70歳の時）

⇩

$$y = 40.6 + (-0.42) \times 70 = 11.5本$$

⬆

これを求めるのが「予測」である

教師あり機械学習の流れ

①データの準備

No.	年齢	歯の本数
1	21	32
2	45	22
3	62	14
4	77	9
5	88	4

②学習モデルの決定

線形回帰 →

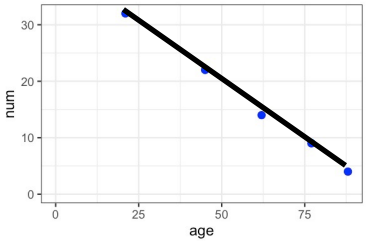

③学習

④予測・分類

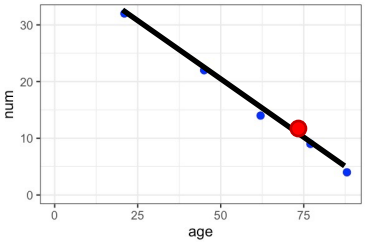

機械学習ではいずれかの**学習モデル**を

適用して学習させ、予測や分類を行う

演習

線形回帰

Pythonで回帰を使って予測を行う

scikit-learn （サイキットラーン）

Python で利用できるデータ分析や機械学習のためのライブラリの一つ

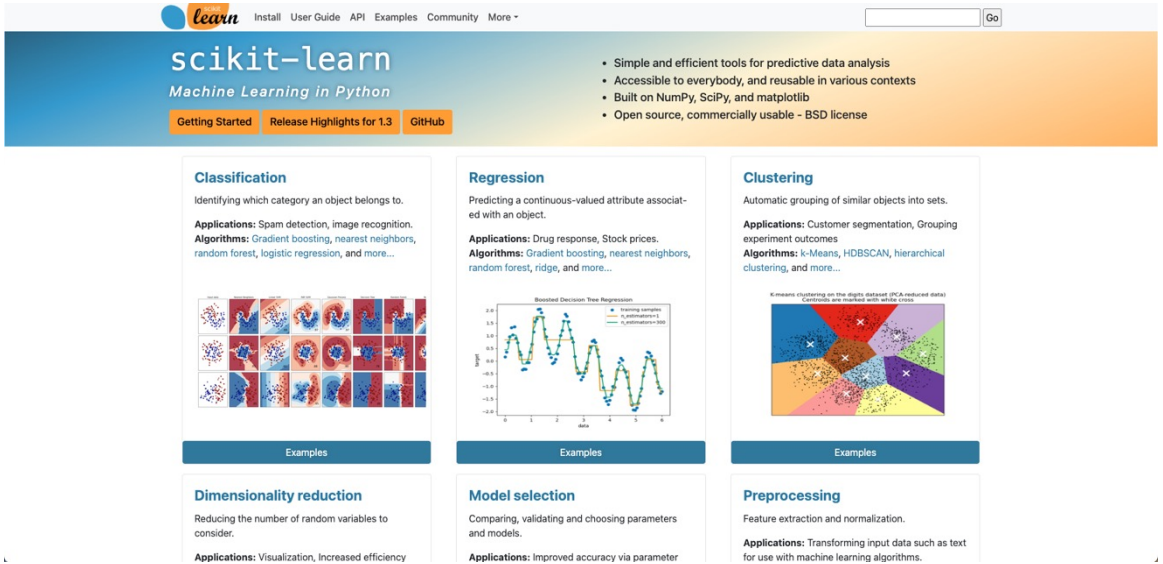

今後の演習ではこのライブラリを用いて機械学習を行う

Pythonで回帰を使って予測を行う

scikit-learnを使い、予測を行う演習の流れ

STEP0：事前準備

STEP1：データの用意

STEP2：学習モデルの選択

STEP3：データを入れて学習させる

STEP4：傾き（偏回帰係数）と切片（定数項)を求める

STEP5：予測を行う

STEP6：モデルの評価

機械学習の流れのまとめ

STEP1:データの用意

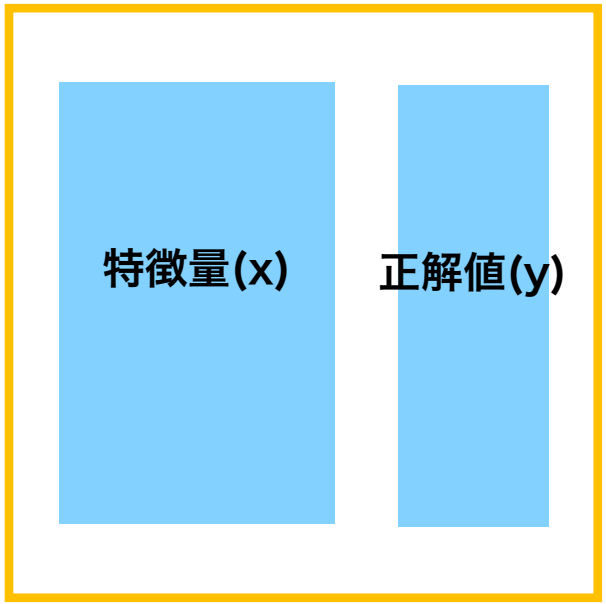

機械学習の流れのまとめ

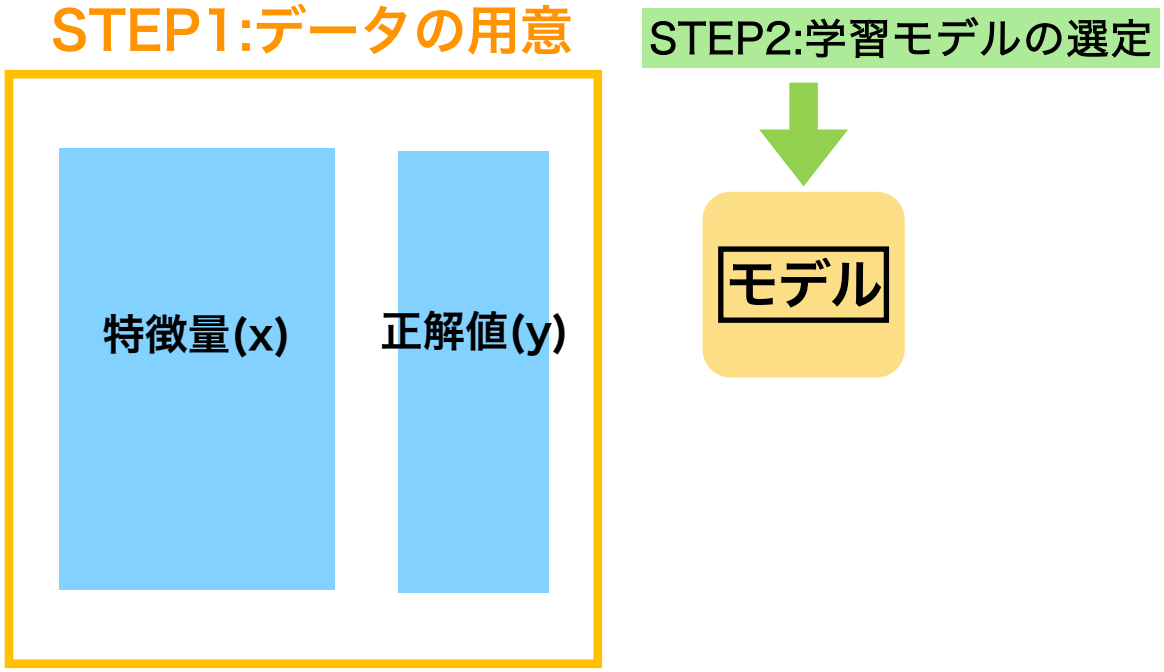

機械学習の流れのまとめ

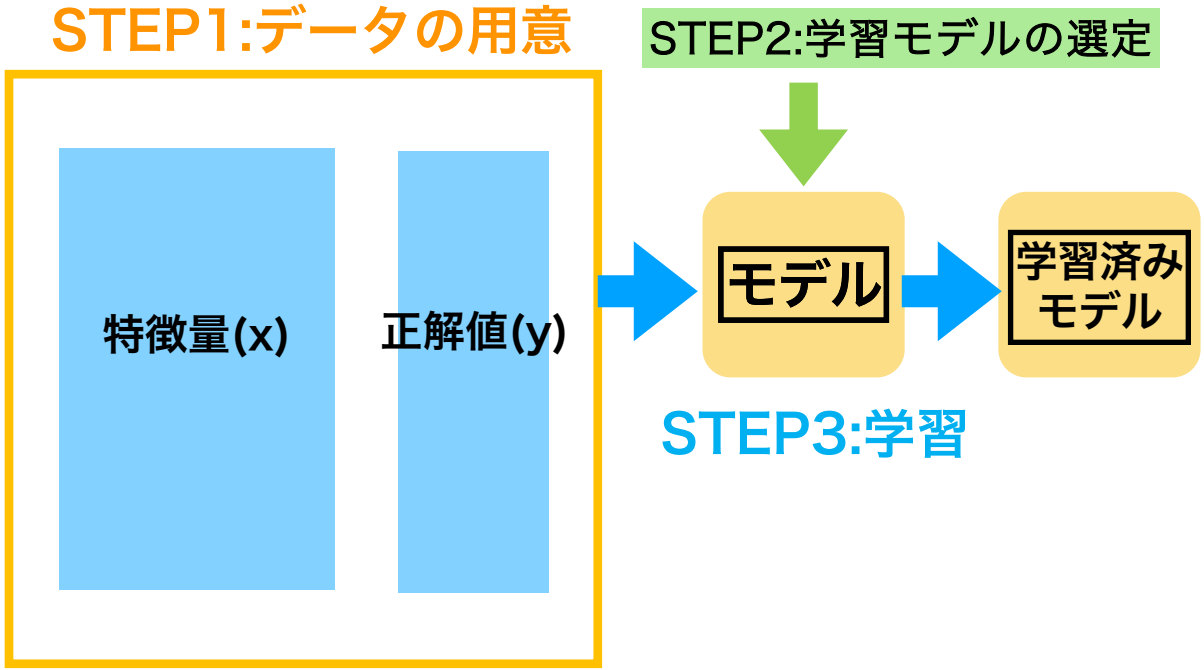

機械学習の流れのまとめ

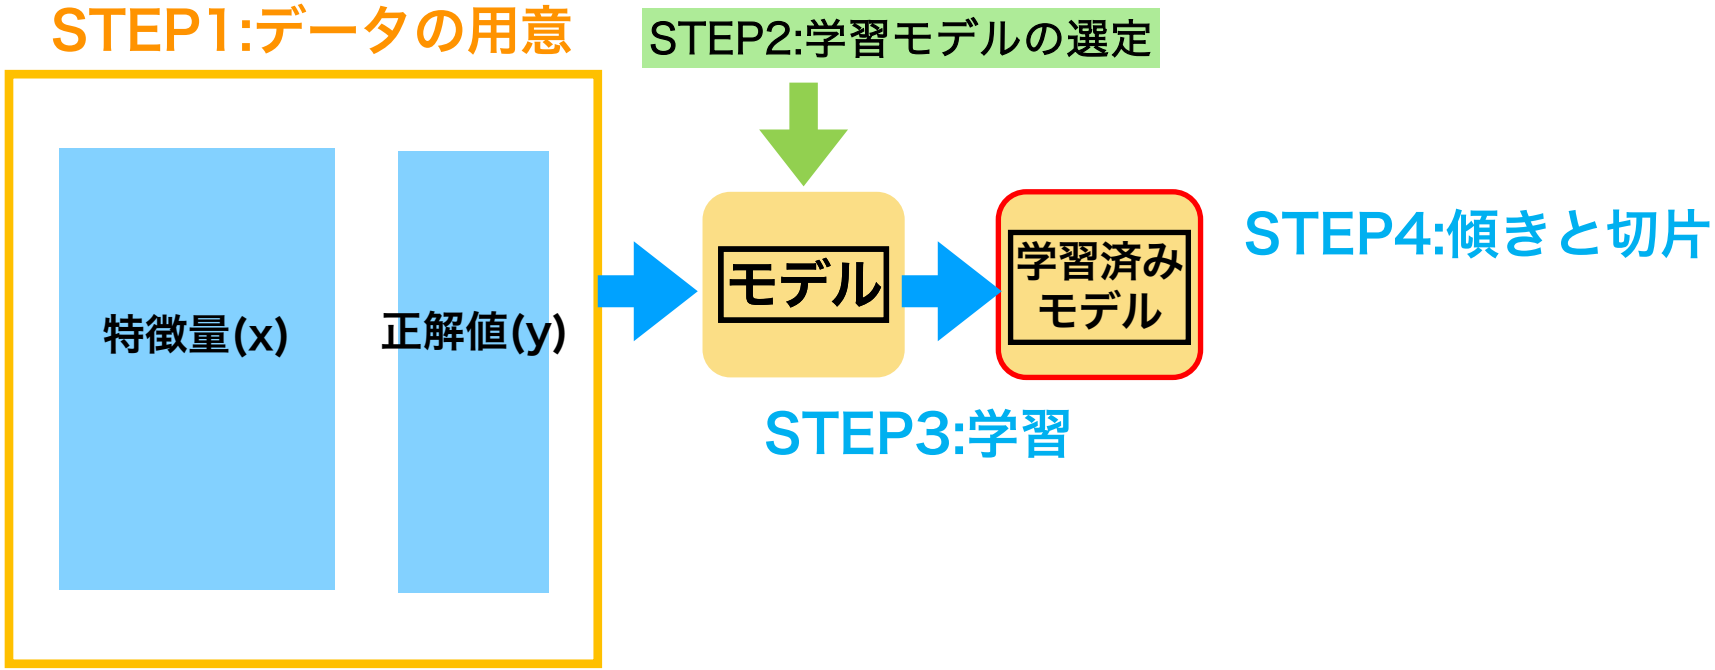

機械学習の流れのまとめ

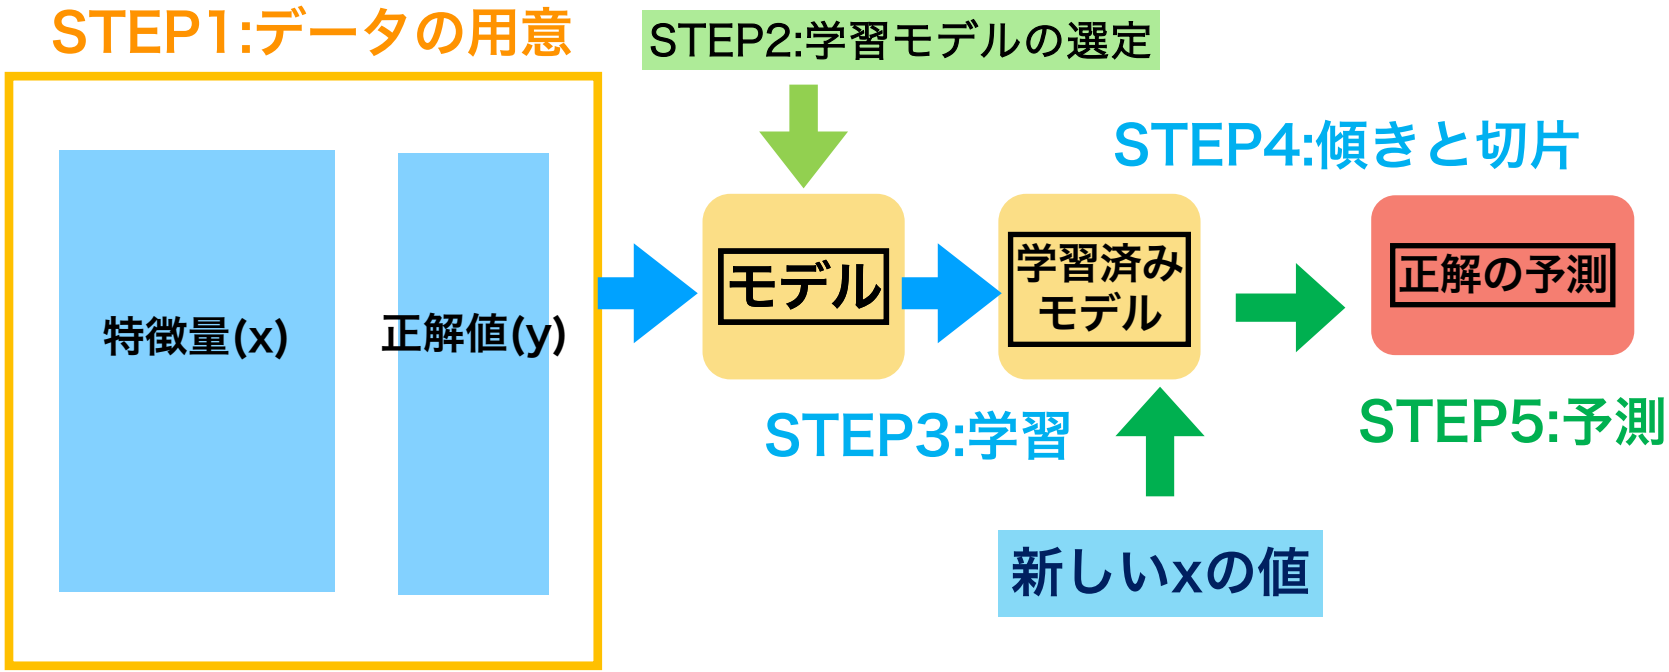

機械学習の流れのまとめ

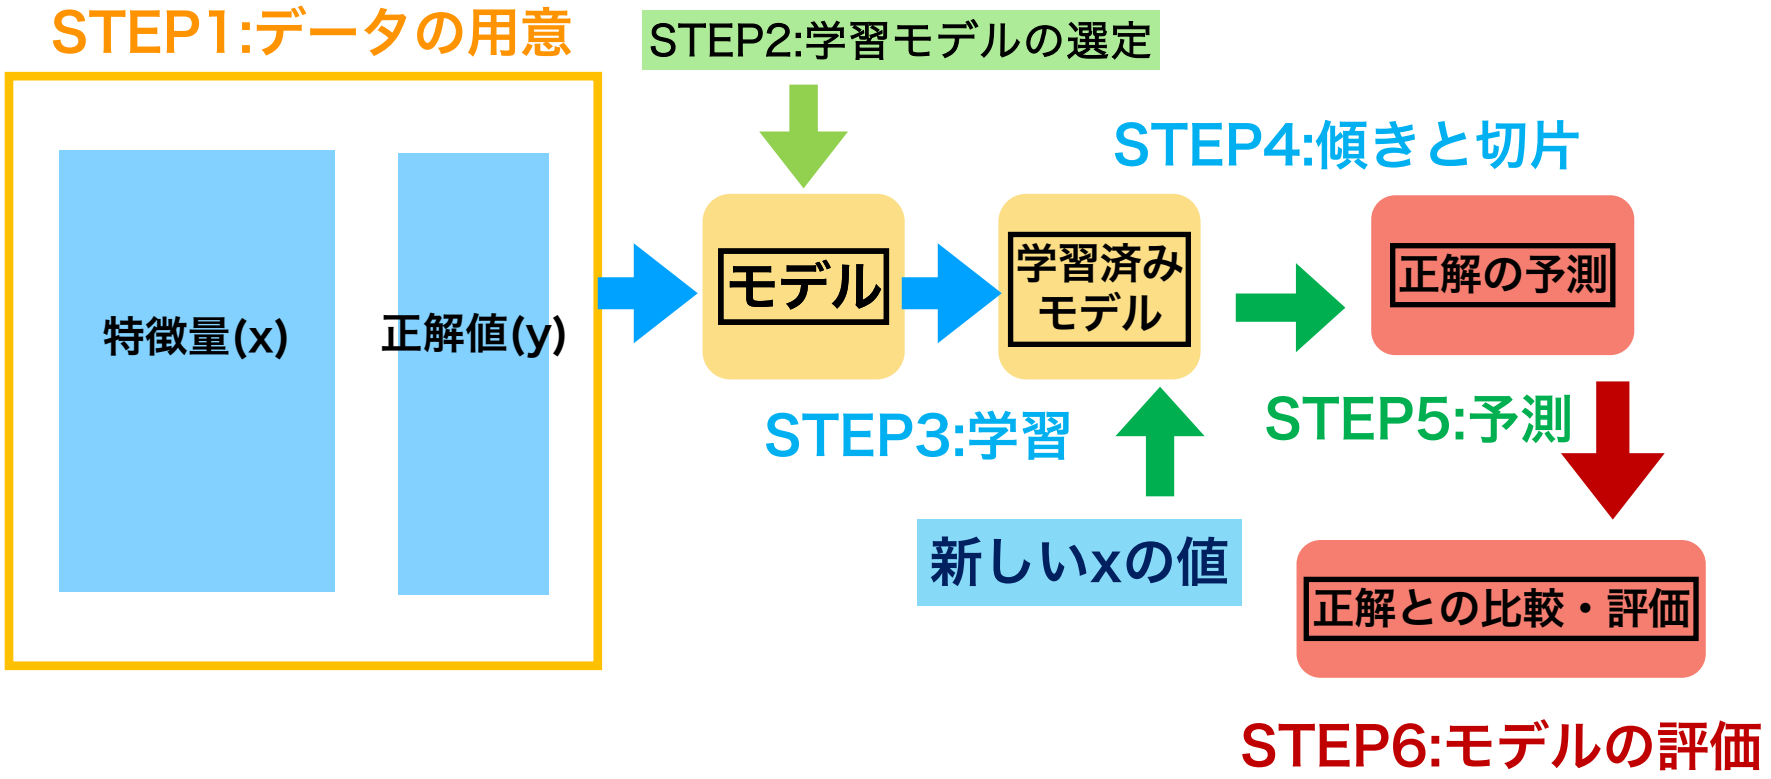

機械学習のコードのまとめ

STEP1　データの用意：特徴量のデータと正解値のデータ

STEP2　学習モデルの選択(今回は線形回帰)

(モデル名) = `LinearRegression`()

STEP3　データを入れて学習させる

(モデル名).`fit`(特徴量,正解値)

STEP4　傾き(偏回帰係数)と切片(定数項)を求める

(モデル名).`coef_`

(モデル名).`intercept_`

STEP5　予測を行う：(モデル名).`predict`(新たなインスタンス)

STEP6　モデルの評価：(モデル名).`score`(特徴量, 正解値)

機械学習のコードのまとめ

```
import numpy as np
import pandas as pd
import matplotlib.pyplot as plt
```

STEP0： ライブラリの読み込み

```
from sklearn.datasets import load_diabetes
dm = load_diabetes(as_frame = True, scaled = False)
y_dm = dm.target
x_dm = dm.data
x_bmi = x_dm[['bmi']]
```

STEP1：データの準備

```
plt.scatter(x_bmi, y_dm)
```

```
from sklearn.linear_model import LinearRegression
model_bmi = LinearRegression()
```

STEP2：学習モデルの選択

```
model_bmi.fit(x_bmi, y_dm)
```

STEP3：データを入れて学習させる

```
print(model_bmi.coef_)
print(model_bmi.intercept_)
```

STEP4：傾きと切片を求める

```
pre = pd.DataFrame([[20]], columns=['bmi'])
print(model_bmi.predict(pre))
```

STEP5： 予測を行う

```
print(model_bmi.score(x_bmi, y_dm))
```

STEP6：モデルの評価

線形回帰分析

STEP0：Google Colaboratoryの立ち上げ

STEP0：事前準備
STEP1：データの用意
STEP2：学習モデルの選択
STEP3：データを入れて学習させる
STEP4：傾きと切片を求める
STEP5：予測を行う
STEP6：モデルの評価

検索google colab　Colaboratory へようこそ - Colaboratory - Google

演習8コード.ipynb

検索google colab　　Colaboratory へようこそ - Colaboratory - Google

線形回帰分析

STEP0：事前準備
STEP1：データの用意
STEP2：学習モデルの選択
STEP3：データを入れて学習させる
STEP4：傾きと切片を求める
STEP5：予測を行う
STEP6：モデルの評価

STEP0：ライブラリのインポート

コード8-1 前回までの演習で使ったnumpy，pandas，matplotlib.pyplotをインポートする

```
import numpy as np
import pandas as pd
import matplotlib.pyplot as plt
```

ライブラリをインポート：import （ライブラリ名） as 省略形

numpyとpandas

モジュールをインポート：import （ライブラリ名）.（モジュール名） as 省略形

matplotlib　pyplot

colab

線形回帰分析

STEP0：事前準備
STEP1：データの用意
STEP2：学習モデルの選択
STEP3：データを入れて学習させる
STEP4：傾きと切片を求める
STEP5：予測を行う
STEP6：モデルの評価

STEP1：糖尿病データの読み込み

コード8-2　diabetes(糖尿病）のデータセットを読み込む

```
from sklearn.datasets import load_diabete
```

sklearnはscikit-learnのライブラリ名

関数だけをインポート　`from sklearn.datasets import load_diabetes`

ライブラリ名　モジュール名　関数名

●load_diabetes()はsklearnに含まれているデータセットの中から、diabetesデータを読み込むための関数

線形回帰分析

STEP0：事前準備
STEP1：データの用意
STEP2：学習モデルの選択
STEP3：データを入れて学習させる
STEP4：傾きと切片を求める
STEP5：予測を行う
STEP6：モデルの評価

STEP1：糖尿病データの読み込み

コード8-2　diabetes(糖尿病）のデータセットを読み込む

```
dm = load_diabetes(as_frame = True, scaled = False)
```

- load_diabetes()関数を実行し、機械学習用のサンプルデータである diabetesデータセットを読み込みdm(糖尿病の省略形)の変数に入れる

- load_diabetes(as_frame = True/False, scaled = True/False)と二つの引数で、True(真)かFalse(偽)を選択する

読み込むデータの形式を指定
True → pdのデータフレーム型
False→ numpy配列

読み込むデータのスケールを指定
True → 正規化された値(全て1~0に変換)
False→ 正規化されていない値（生データ）

線形回帰分析

STEP0：事前準備
STEP1：データの用意
STEP2：学習モデルの選択
STEP3：データを入れて学習させる
STEP4：傾きと切片を求める
STEP5：予測を行う
STEP6：モデルの評価

STEP1：糖尿病データの内容確認

コード8-3 dmの内容を調べる①

```
dm                    #データ自体を出力
```

```
type(dm)              #データの型を出力
```

→ `sklearn.utils._bunch.Bunch`

Bunch型はdictionary(辞書)型の一種

dataset = {“key1”:”a”, “key2”:”b”, “key3”:”c”}
辞書名　キー1　値1　キー2　値2　キー3　値3
要素1　要素2　要素3

辞書型は順序づけたキーと値の集まりで、(データ名).(キー)　で格納したデータ(値)を呼び出す

キー

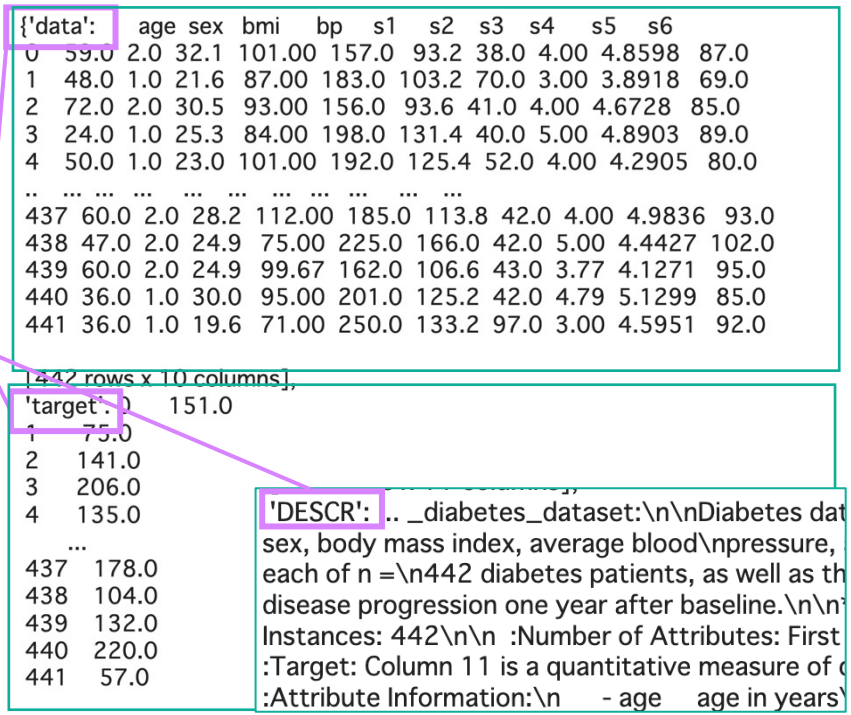

線形回帰分析

STEP0：事前準備
STEP1：データの用意
STEP2：学習モデルの選択
STEP3：データを入れて学習させる
STEP4：傾きと切片を求める
STEP5：予測を行う
STEP6：モデルの評価

STEP1：糖尿病データの内容確認

コード8-4 dmの内容を調べる②

```
print(dm.DESCR)
```

辞書型は順序づけられたキーと値の集まりで、(データ名).(キー) で格納した
データ(値)を呼び出す

dmのキーの一つであるDESCRはデータセットの中身の定義について記載されている部分

線形回帰分析

STEP1：糖尿病データの内容確認

STEP0：事前準備
STEP1：データの用意
STEP2：学習モデルの選択
STEP3：データを入れて学習させる
STEP4：傾きと切片を求める
STEP5：予測を行う
STEP6：モデルの評価

```
.. _diabetes_dataset:

Diabetes dataset
----------------

Ten baseline variables, age, sex, body mass index, average blood
pressure, and six blood serum measurements were obtained for each of n =
442 diabetes patients, as well as the response of interest, a
quantitative measure of disease progression one year after baseline.

**Data Set Characteristics:**

  :Number of Instances: 442

  :Number of Attributes: First 10 columns are numeric predictive values

  :Target: Column 11 is a quantitative measure of disease progression one year after baseline

  :Attribute Information:
      - age     age in years
      - sex
      - bmi     body mass index
      - bp      average blood pressure
      - s1      tc, total serum cholesterol
      - s2      ldl, low-density lipoproteins
      - s3      hdl, high-density lipoproteins
      - s4      tch, total cholesterol / HDL
      - s5      ltg, possibly log of serum triglycerides level
      - s6      glu, blood sugar level
```

行は442人

10個のベースライン変数(年齢、性別、BMI、平均血圧、6個の血清測定値)が442人の糖尿病患者についてそれぞれ取得

興味がある応答変数は、ベースラインの1年後の糖尿病の進行度を「量的」に示したもの

カラム（列）の定義
s1:血清コレステロール値
s2:LDLコレステロール
s3:HDLコレステロール
s4:総コレステロール/HDL
s5:log(血清トリグリセミド)
s6:血糖値

線形回帰分析

STEP0：事前準備
STEP1：データの用意
STEP2：学習モデルの選択
STEP3：データを入れて学習させる
STEP4：傾きと切片を求める
STEP5：予測を行う
STEP6：モデルの評価

STEP1：糖尿病データの内容確認

年齢：59歳
性別：女性
BMI：32
・・・

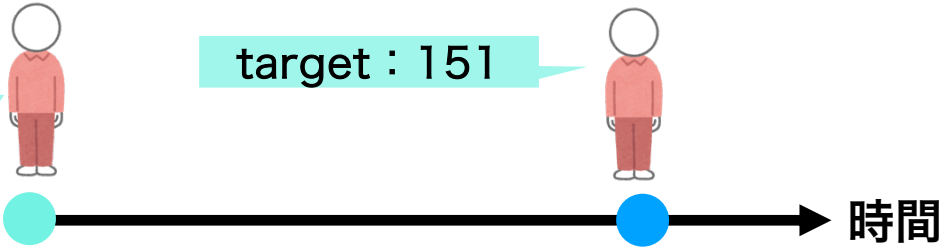

ベースライン(基準)時点
→10個の特徴量の測定時点

1年後
正解値（target：
糖尿病の進行度を量的に示したもの)の測定時点

ベースライン時点のx(特徴量)で1年後のtargetをy(正解値）との関連を調べる、学習モデルの作成を行う

colab

線形回帰分析

STEP0：事前準備
STEP1：データの用意
STEP2：学習モデルの選択
STEP3：データを入れて学習させる
STEP4：傾きと切片を求める
STEP5：予測を行う
STEP6：モデルの評価

STEP1：正解データを作成

コード8-5 正解値データを作成

```
y_dm = dm.target
y_dm.head()
```

- dmのtargetキーで格納されている値を呼び出し、y_dmに格納する
- (データフレーム名).head()で最初の5行を出力する(見るだけ)

```
y_dm.shape  #データの配列構造を出力
```

➡ (442,)　442個の1次元配列(ベクトル)

```
type(y_dm)  #データの型を出力
```

➡ pandas.core.series.Series

```
0    151.0
1     75.0
2    141.0
3    206.0
4    135.0
Name: target, dtype: float64
```

線形回帰分析

STEP0：事前準備
STEP1：データの用意
STEP2：学習モデルの選択
STEP3：データを入れて学習させる
STEP4：傾きと切片を求める
STEP5：予測を行う
STEP6：モデルの評価

STEP1：正解データの記述

コード8-6 y_dmの記述統計値を調べる

```
y_dm.describe()
```

```
count    442.000000
mean     152.133484
std       77.093005
min       25.000000
25%       87.000000
50%      140.500000
75%      211.500000
max      346.000000
Name: target, dtype: float64
```

pandasのDataFrameやSeriesには describe()メソッドがあり、(データフレーム名).describe()で各列の記述統計値（平均値(mean)や最小(min)、最大値(max)など）を出力できる

進行度の数値と言ってもピンとこないため、どのような数値を取るのか記述統計を出力

平均(mean)は152.13、最小値は25、最大値は346の値をとる

大きいほど1年後の糖尿病が悪化している

colab

線形回帰分析

STEP0：事前準備
STEP1：データの用意
STEP2：学習モデルの選択
STEP3：データを入れて学習させる
STEP4：傾きと切片を求める
STEP5：予測を行う
STEP6：モデルの評価

STEP1：特徴量データの整形

コード8-7 x(特徴量データ）のデータを作成

```
x_dm = dm.data
x_dm.head()  #最初の5行を出力
```

dmのdataキーで格納された値を呼び出し、x_dmに格納する

```
x_dm.shape  #データの配列構造を出力
```

(442,10) 442行×10列の2次元配列(行列)

```
type(x_dm)  #データの型を出力
```

pandas.core.frame.DataFrame

	age	sex	bmi	bp	s1	s2	s3	s4	s5	s6
0	59.0	2.0	32.1	101.0	157.0	93.2	38.0	4.0	4.8598	87.0
1	48.0	1.0	21.6	87.0	183.0	103.2	70.0	3.0	3.8918	69.0
2	72.0	2.0	30.5	93.0	156.0	93.6	41.0	4.0	4.6728	85.0
3	24.0	1.0	25.3	84.0	198.0	131.4	40.0	5.0	4.8903	89.0
4	50.0	1.0	23.0	101.0	192.0	125.4	52.0	4.0	4.2905	80.0

age~s6までの10変数

線形回帰分析

STEP0：事前準備
STEP1：データの用意
STEP2：学習モデルの選択
STEP3：データを入れて学習させる
STEP4：傾きと切片を求める
STEP5：予測を行う
STEP6：モデルの評価

STEP1：x(特徴量データ）の記述

コード8-8 x_dmの記述統計値を調べる

```
x_dm.describe()
```

	年齢	性別	BMI	平均血圧	TC (総コレステロール値)	LDL (悪玉コレステロール)	HDL (悪玉コレステロール)	TCH (TC/HDL)	LTG (血液中の中性脂肪値の対数)	GLU (血糖値)
	age	sex	bmi	bp	s1	s2	s3	s4	s5	s6
count	442.000000	442.000000	442.000000	442.000000	442.000000	442.000000	442.000000	442.000000	442.000000	442.000000
mean	48.518100	1.468326	26.375792	94.647014	189.140271	115.439140	49.788462	4.070249	4.641411	91.260181
std	13.109028	0.499561	4.418122	13.831283	34.608052	30.413081	12.934202	1.290450	0.522391	11.496335
min	19.000000	1.000000	18.000000	62.000000	97.000000	41.600000	22.000000	2.000000	3.258100	58.000000
25%	38.250000	1.000000	23.200000	84.000000	164.250000	96.050000	40.250000	3.000000	4.276700	83.250000
50%	50.000000	1.000000	25.700000	93.000000	186.000000	113.000000	48.000000	4.000000	4.620050	91.000000
75%	59.000000	2.000000	29.275000	105.000000	209.750000	134.500000	57.750000	5.000000	4.997200	98.000000
max	79.000000	2.000000	42.200000	133.000000	301.000000	242.400000	99.000000	9.090000	6.107000	124.000000

線形回帰分析

STEP0：事前準備
STEP1：データの用意
STEP2：学習モデルの選択
STEP3：データを入れて学習させる
STEP4：傾きと切片を求める
STEP5：予測を行う
STEP6：モデルの評価

STEP1：x(特徴量データ）の整形

コード8-9 x_dmからbmi列だけを抽出

```
x_bmi = x_dm[['bmi']]
x_bmi
```

	bmi
0	32.1
1	21.6
2	30.5
3	25.3
4	23.0
...	...
437	28.2
438	24.9
439	24.9
440	30.0
441	19.6

442 rows × 1 columns

特徴量を一つだけにして単回帰を行いたいので、x_dmのbmiを回帰に入れる変数に選択し、bmiだけのデータを作成する

二重カッコ[[]]で列名を指定する

	age	sex	bmi	bp	s1	s2	s3	s4	s5	s6
count	442.000000	442.000000	442.000000	442.000000	442.000000	442.000000	442.000000	442.000000	442.000000	442.000000
mean	48.518100	1.468326	26.375792	94.647014	189.140271	115.439140	49.788462	4.070249	4.641411	91.260181
std	13.109028	0.499561	4.418122	13.831283	34.608052	30.413081	12.934202	1.290450	0.522391	11.496335
min	19.000000	1.000000	18.000000	62.000000	97.000000	41.600000	22.000000	2.000000	3.258100	58.000000
25%	38.250000	1.000000	23.200000	84.000000	164.250000	96.050000	40.250000	3.000000	4.276700	83.250000
50%	50.000000	1.000000	25.700000	93.000000	186.000000	113.000000	48.000000	4.000000	4.620050	91.000000
75%	59.000000	2.000000	29.275000	105.000000	209.750000	134.500000	57.750000	5.000000	4.997200	98.000000
max	79.000000	2.000000	42.200000	133.000000	301.000000	242.400000	99.000000	9.090000	6.107000	124.000000

データフレーム型から列を取り出す方法

二重の角括弧[[]]

```
x_bmi = x_dm[['bmi']]
```

一重の角括弧[]

```
x_bmi1 = x_dm['bmi']
```

コード8-10

```
x_bmi.shape  #データの配列構造を出力
```

➡ (442,1) 442行×1列の2次元配列(行列)

```
type(x_bmi)  #データの型を出力
```

➡ pandas.core.frame.DataFrame

```
x_bmi1.shape  #データの配列構造を出力
```

➡ (442,) 442個の1次元配列(ベクトル)

```
type(x_bmi1)  #データの型を出力
```

➡ pandas.core.series.Series

回帰で学習を行うには、xとyの配列がPythonでは指定されている

`x_bmi, y_dm`

xは2次元配列（行列の形）

yは1次元配列（ベクトルの形）

151.0, 75.0, 141.0…

	BMI
0	32.1
1	21.6
2	30.5

442 rows × 1 columns

配列を間違うとエラーになりコードが動かないので、
作成したデータの配列を確認するように気を付ける

colab

線形回帰分析

STEP0：事前準備
STEP1：データの用意
STEP2：学習モデルの選択
STEP3：データを入れて学習させる
STEP4：傾きと切片を求める
STEP5：予測を行う
STEP6：モデルの評価

STEP1：用意したデータのプロット

コード8-11 正解値と特徴量で散布図を描出

```
plt.scatter(x_bmi, y_dm)
```

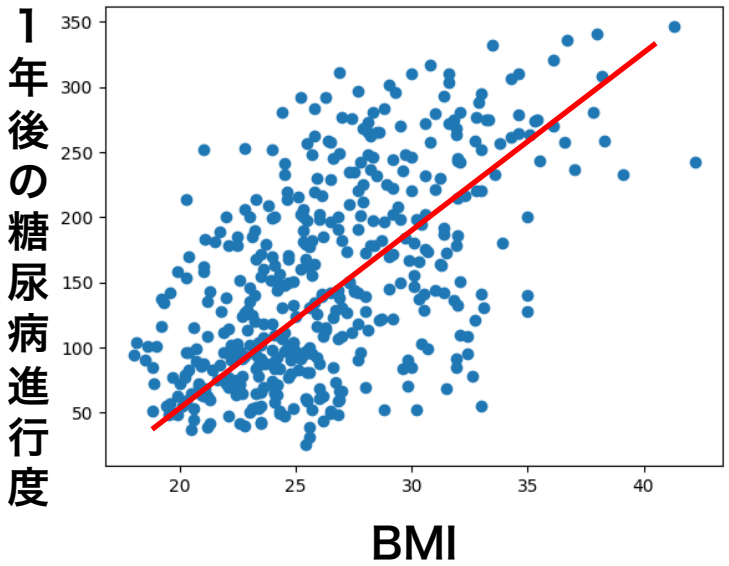

散布図はplt.scatter(x,y)で描出 (演習7の復習)

この後の回帰では、
回帰式： $y=b_0+b_1x_1$
のb_0とb_1を決定する

決定する方法は、最小二乗法(Ordinary Least Square, OLS)を用いる

b_0とb_1が決まると赤い線が引ける

colab

機械学習の流れのまとめ

STEP1:データの用意

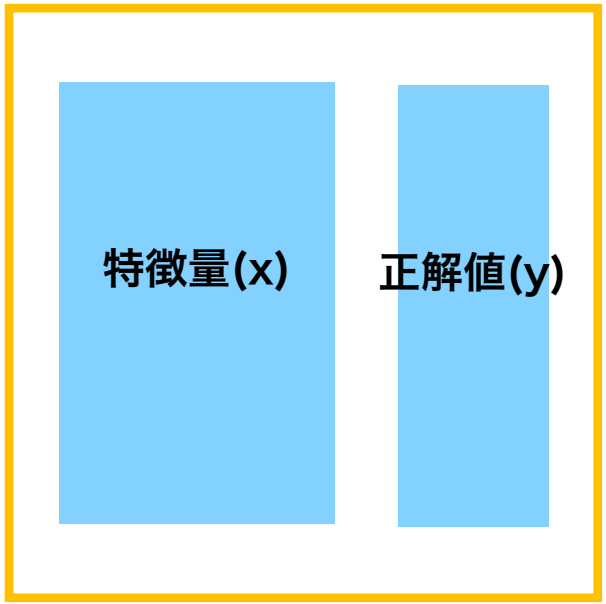

機械学習の流れのまとめ

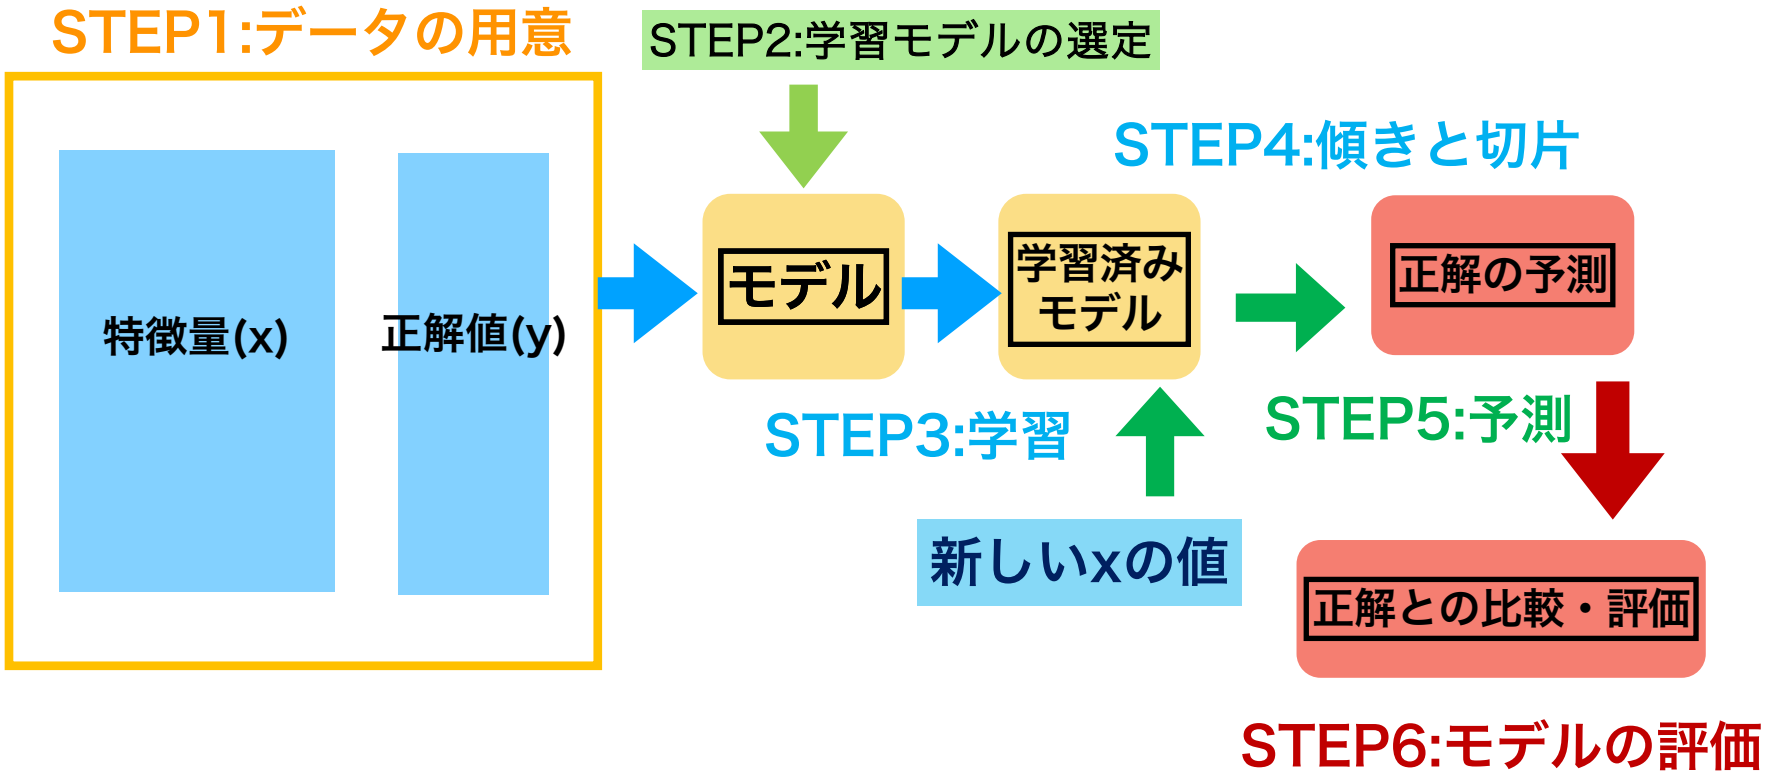

演習8：課題

Webclassで課題を提出してください。締め切りは2024/01/25 23:59まで

(1)今回使用した糖尿病のデータの特徴量データからageだけのx_ageを作成するコードを記載してください

(2)x_ageの先頭5行を出力するコードを記載してください

(3)x_ageの配列構造を記載してください(コードではなく出力結果)

(4)x_ageの型を記載してください(コードではなく出力結果)

来週から水曜日・木曜日で授業あるので注意

授業準備：Webclassからコードをダウンロードし、Google colaboratoryで開いておいてください

演習授業中の質問対応について

2024/1/17 10:40-11:25

演習9
回帰2

統合教育機構
石丸美穂

線形回帰のコードのまとめ

```
import numpy as np
import pandas as pd
import matplotlib.pyplot as plt
```

STEP0： ライブラリの読み込み

```
from sklearn.datasets import load_diabetes
dm = load_diabetes(as_frame = True, scaled = False)
y_dm = dm.target
x_dm = dm.data
x_bmi = x_dm[['bmi']]
```

STEP1：データの準備

```
plt.scatter(x_bmi, y_dm)
```

```
from sklearn.linear_model import LinearRegression
model_bmi = LinearRegression()
```

STEP2：学習モデルの選択

```
model_bmi.fit(x_bmi, y_dm)
```

STEP3：データを入れて学習させる

```
print(model_bmi.coef_)
print(model_bmi.intercept_)
```

STEP4：傾きと切片を求める

```
pre = pd.DataFrame([[20]], columns=['bmi'])
print(model_bmi.predict(pre))
```

STEP5： 予測を行う

```
print(model_bmi.score(x_bmi, y_dm))
```

STEP6：モデルの評価

線形回帰分析

前回の復習

STEP0：事前準備
STEP1：データの用意
STEP2：学習モデルの選択
STEP3：データを入れて学習させる
STEP4：傾きと切片を求める
STEP5：予測を行う
STEP6：モデルの評価

STEP1：糖尿病データの内容確認

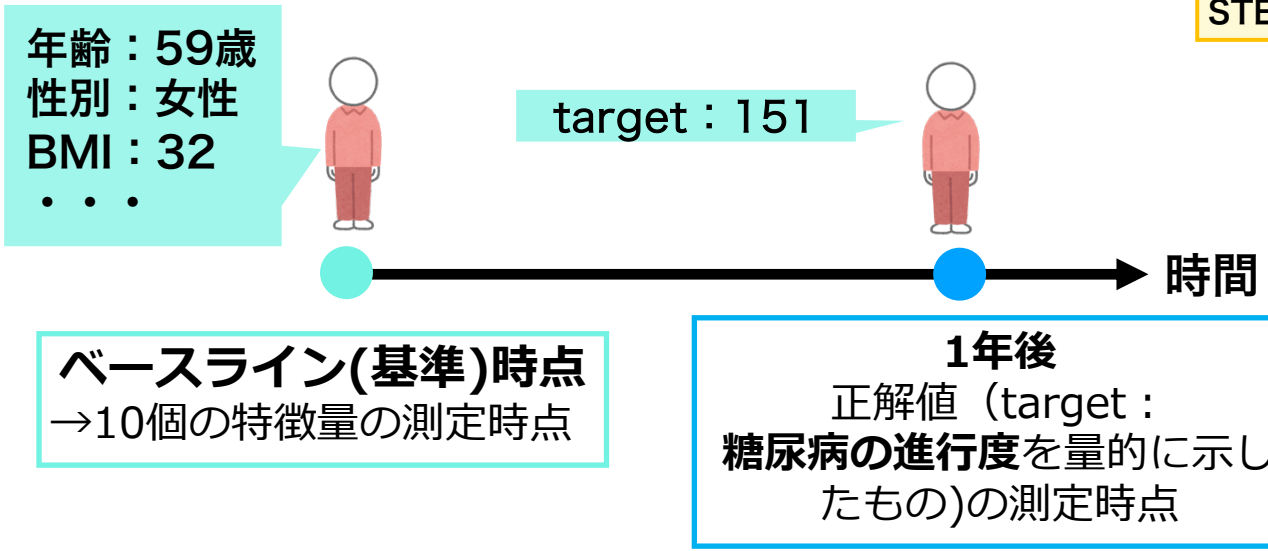

ベースライン時点のx(特徴量)で1年後のtargetをy(正解値）との関連を調べる、学習モデルの作成を行う

回帰で学習を行うには、xとyの配列がPythonでは指定されている

`x_bmi, y_dm`

xは2次元配列（行列の形）

yは1次元配列（ベクトルの形）

151.0, 75.0, 141.0…

	BMI
0	32.1
1	21.6
2	30.5

442 rows × 1 columns

配列を間違うとエラーになりコードが動かないので、
作成したデータの配列を確認するように気を付ける

機械学習の流れのまとめ

STEP1:データの用意

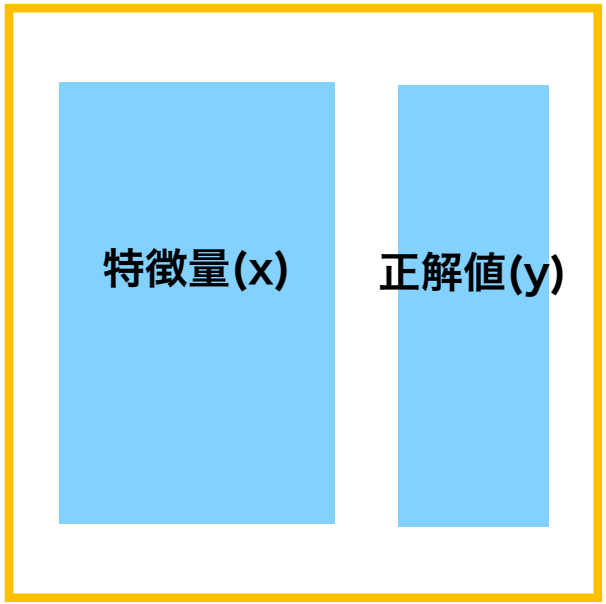

機械学習の流れのまとめ

STEP1:データの用意

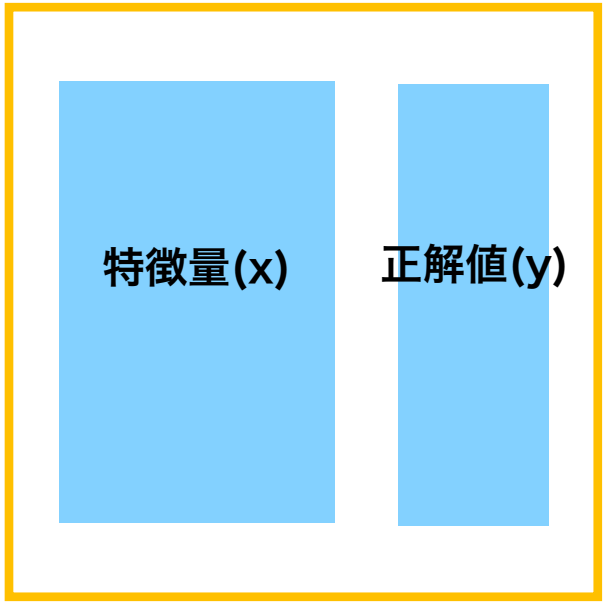

STEP2:学習モデルの選定

機械学習の流れのまとめ

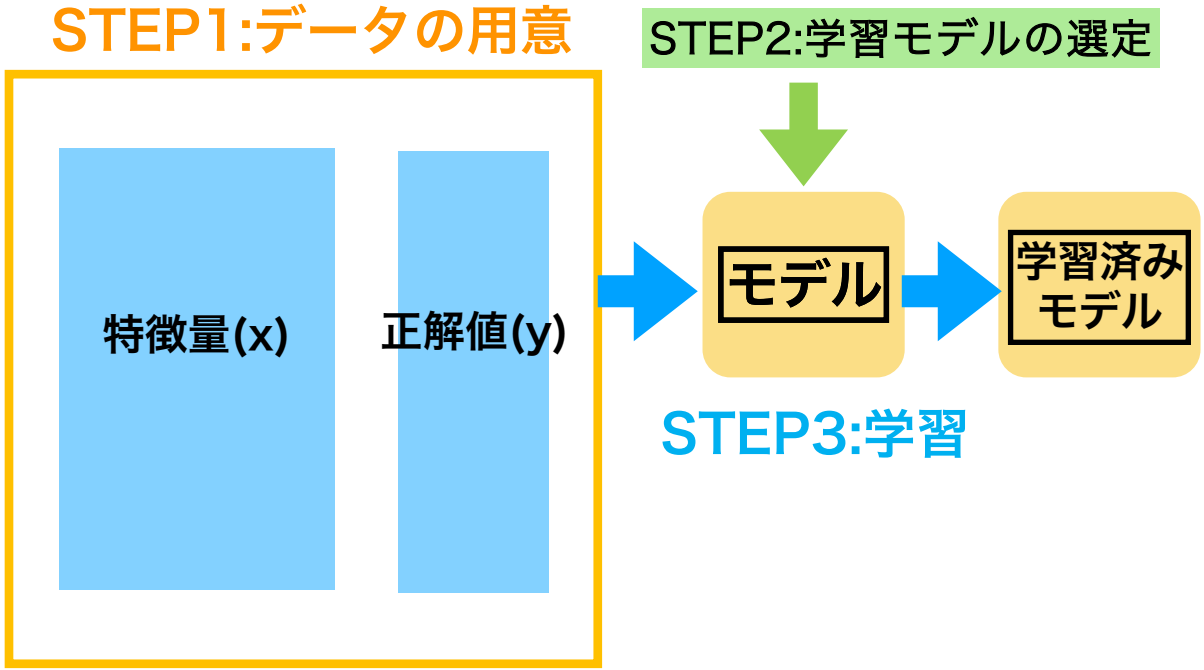

機械学習の流れのまとめ

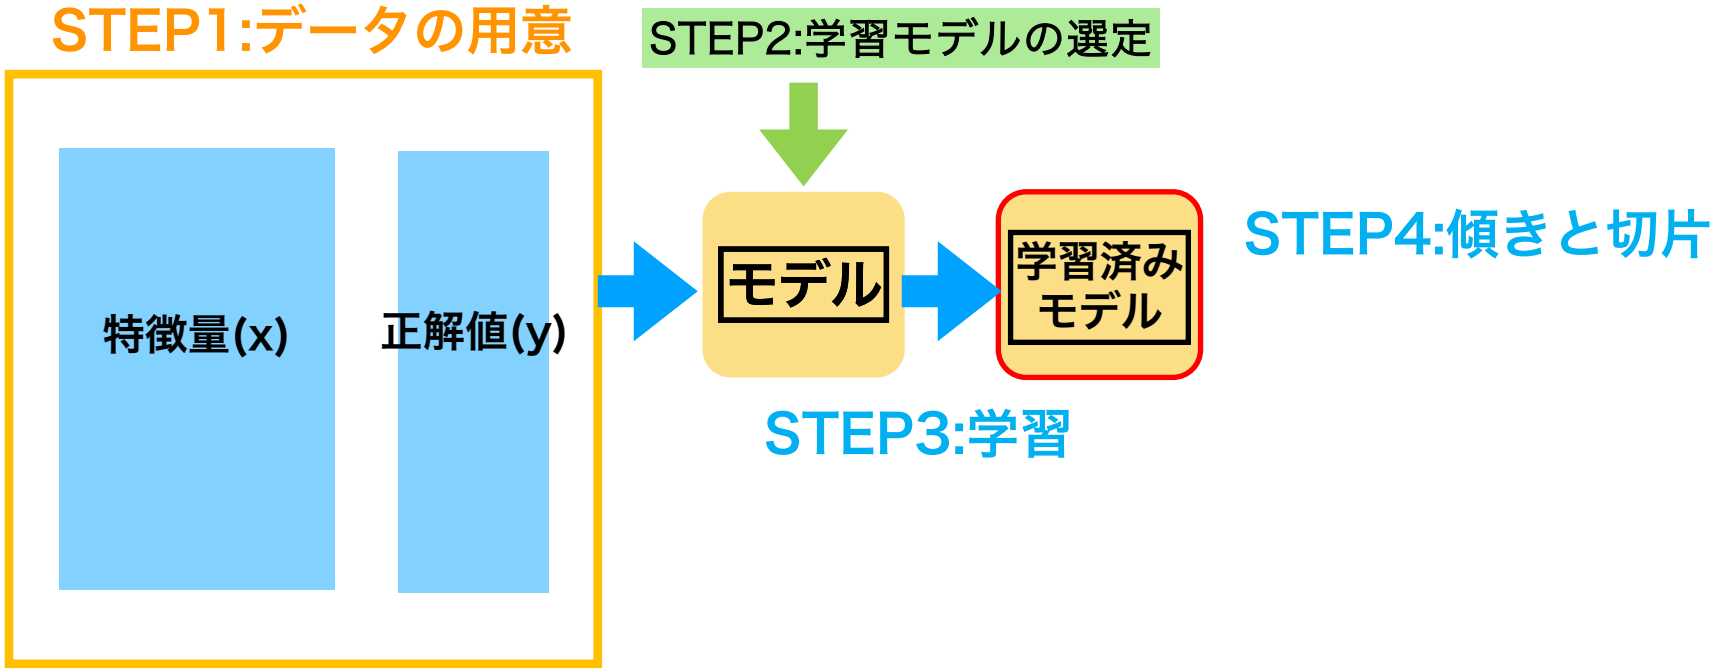

機械学習の流れのまとめ

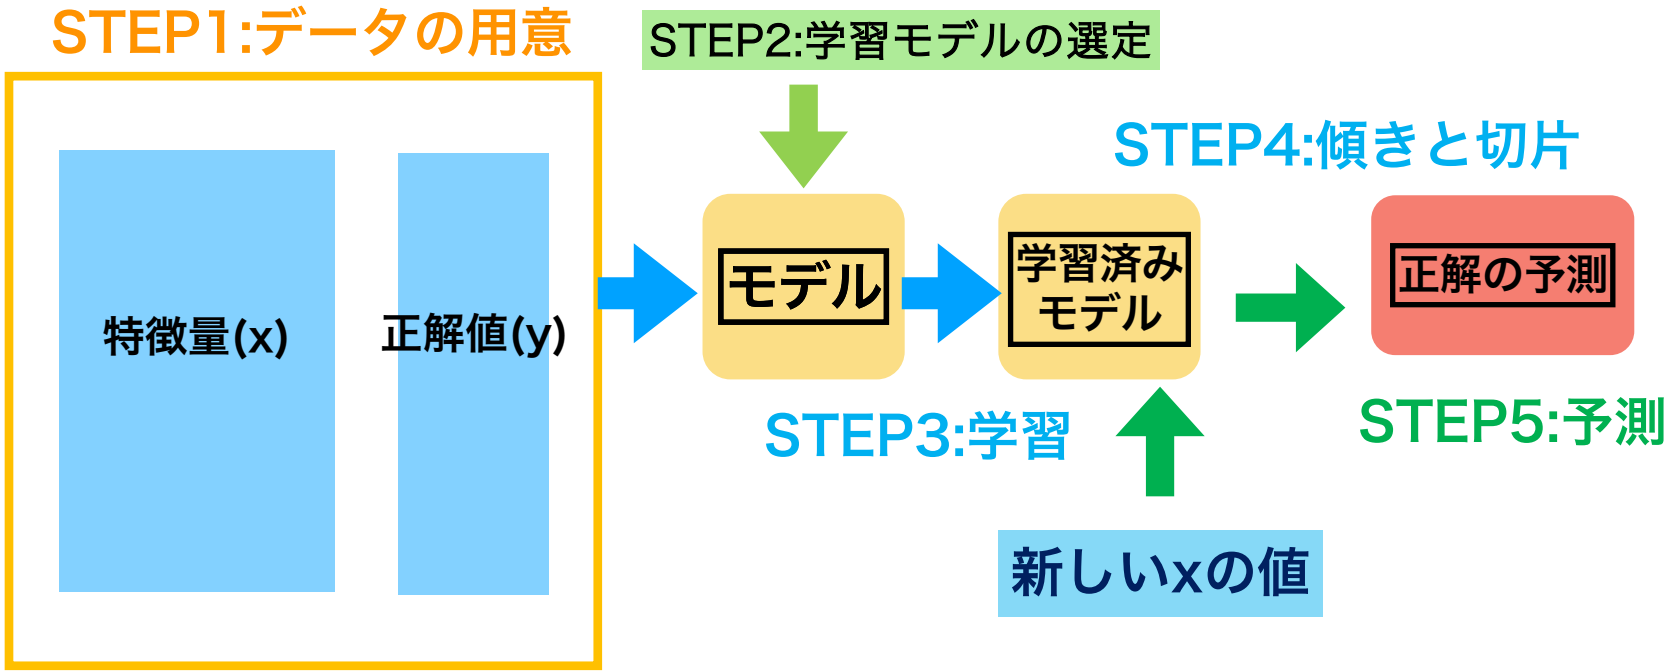

機械学習の流れのまとめ

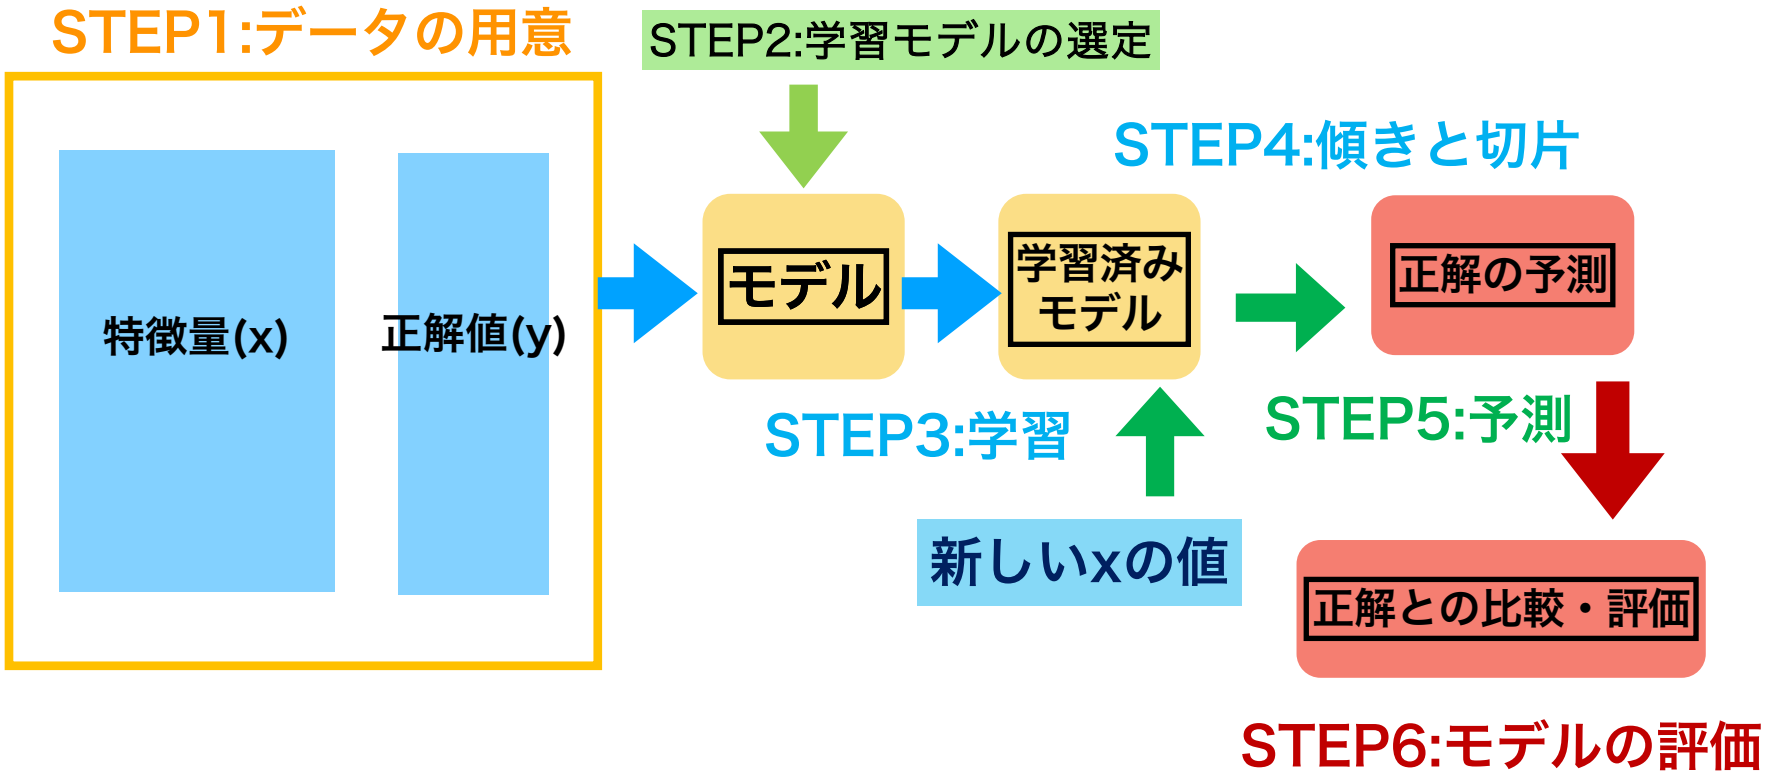

線形回帰分析

STEP0：Google Colaboratoryの立ち上げ

STEP0：事前準備
STEP1：データの用意
STEP2：学習モデルの選択
STEP3：データを入れて学習させる
STEP4：傾きと切片を求める
STEP5：予測を行う
STEP6：モデルの評価

検索google colab　Colaboratory へようこそ - Colaboratory - Google

演習9コード.ipynb

検索google colab　　Colaboratory へようこそ - Colaboratory - Google

線形回帰分析

STEP1：データの用意

STEP0：事前準備
STEP1：データの用意
STEP2：学習モデルの選択
STEP3：データを入れて学習させる
STEP4：傾きと切片を求める
STEP5：予測を行う
STEP6：モデルの評価

前回の続きのため、配布した演習9.ipynbの
コード9-1~コード9-2を実行してください

colab

機械学習の流れのまとめ

STEP1:データの用意

特徴量(x)

`x_bmi`

正解値(y)

`y_dm`

STEP2:学習モデルの選択

線形回帰分析

STEP2：学習モデルの選択

STEP0：事前準備
STEP1：データの用意
STEP2：学習モデルの選択
STEP3：データを入れて学習させる
STEP4：傾きと切片を求める
STEP5：予測を行う
STEP6：モデルの評価

コード9-3　線形回帰を学習モデルに選択

```
from sklearn.linear_model import LinearRegression
```

クラスだけをインポート　`from sklearn.linear_model import LinearRegression`

- `sklearn`：ライブラリ名
- `linear_model`：モジュール名
- `LinearRegression`：クラス名

クラス（Class）

属性（引数、データ）と　メソッド（処理）を一つにまとめた設計図のようなもの

クラス（設計図)に実際のデータを入れたものをインスタンスと呼ぶ

class BMI(weight, height)

属性
体重 (weight)
身長 (height)

メソッド
bmi_calc():
Weight /Height/ Height

Aさん

体重 70kg
身長 1.7m

Bさん

体重 45kg
身長 1.5m

```
Asan = BMI(70,1.7)
```

```
Bsan = BMI(45,1.5)
```

BMIクラスからインスタンス(Asan, Bsan)を作成

```
Asan.weight
```
➡ 70

```
Bsan.weight
```
➡ 45

```
Asan.bmi_calc()
```
➡ 24.2

```
Bsan.bmi_calc()
```
➡ 20

線形回帰分析

STEP0：事前準備
STEP1：データの用意
STEP2：学習モデルの選択
STEP3：データを入れて学習させる
STEP4：傾きと切片を求める
STEP5：予測を行う
STEP6：モデルの評価

STEP2：学習モデルの選択

コード9-3　線形回帰を学習モデルに選択

```
model_bmi = LinearRegression()
```

- `LinearRegression()`クラスから`model_bmi`インスタンスを作成する

（この時点ではモデル構造のみが指定されている）

モデル名は何でも良い　→ 今回は `model_bmi`

* model1,mode2…と作ると何を入れたものか忘れるので、
何のモデルなのか明示しておく方が便利

colab

機械学習の流れのまとめ

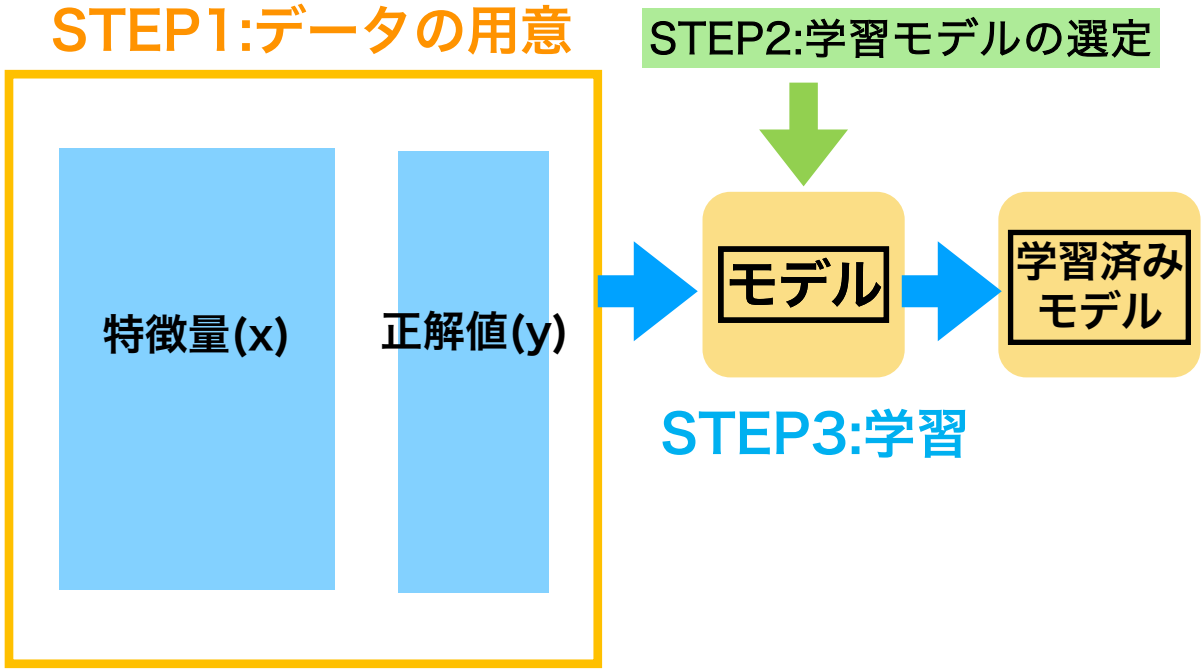

線形回帰分析

STEP0：事前準備
STEP1：データの用意
STEP2：学習モデルの選択
STEP3：データを入れて学習させる
STEP4：傾きと切片を求める
STEP5：予測を行う
STEP6：モデルの評価

STEP3：データを入れて学習させる

コード9-4　データを入れて学習させる

```
model_bmi.fit(x_bmi, y_dm)
```

- （モデル名）.fit(x,y)メソッドで学習できる
- 今回の特徴量はx_bmi，正解値はy_dmのデータ

これだけで「学習」は完了!

この後からはmodel_bmiは学習済みモデルになる

colab

機械学習の流れのまとめ

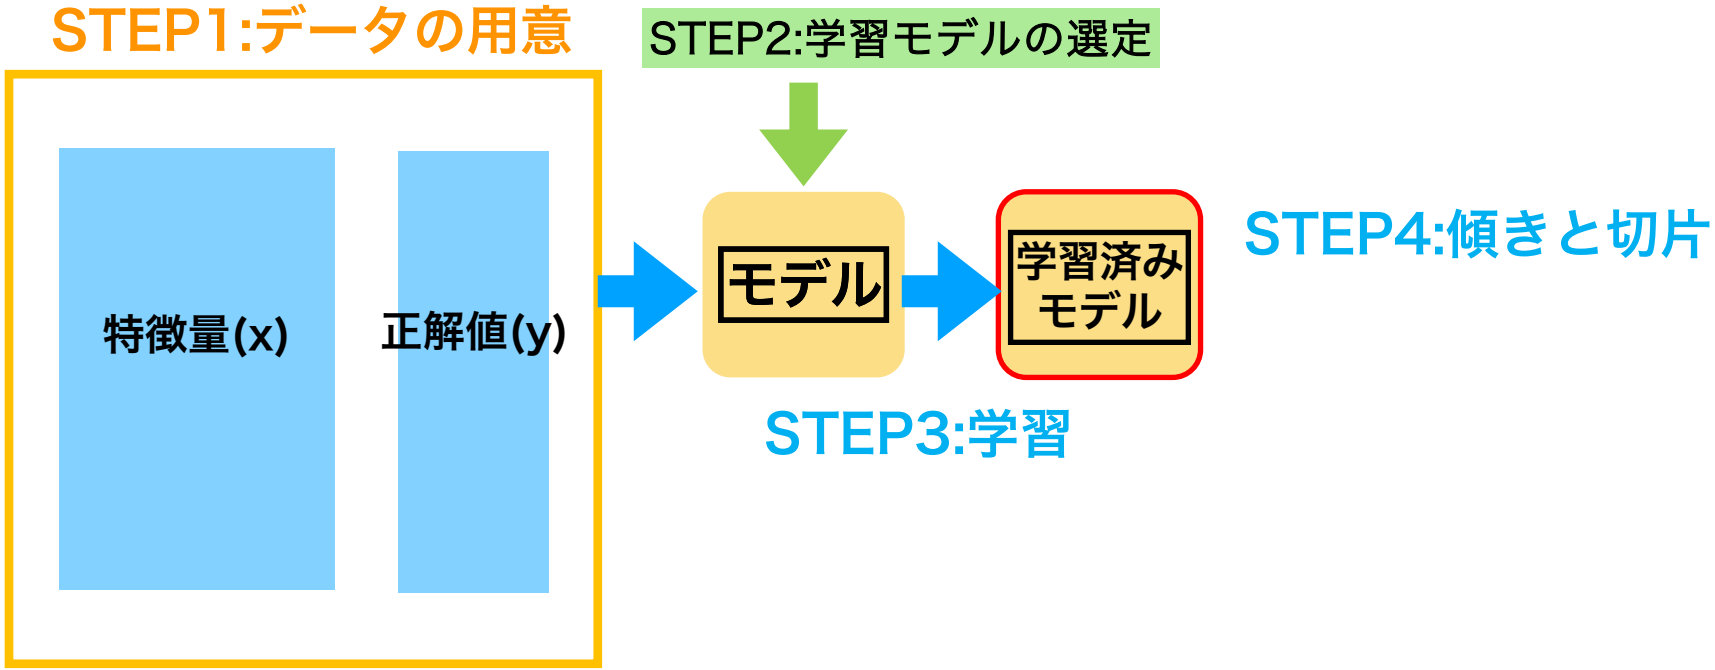

線形回帰分析

STEP0：事前準備
STEP1：データの用意
STEP2：学習モデルの選択
STEP3：データを入れて学習させる
STEP4：傾きと切片を求める
STEP5：予測を行う
STEP6：モデルの評価

STEP4：傾きと切片を求める

コード9-5　学習済みモデルの傾きと切片を求める

```
print(model_bmi.coef_)

print(model_bmi.intercept_)
```

```
[[10.23312787]]
[-117.77336657]
```

（モデル名）.coef_：係数（coefficient）
（モデル名）.intercept_：切片（intercept）

model_bmiの回帰式の完成！！

$$y = -117.77 + (10.23 \times BMI)$$

colab

機械学習の流れのまとめ

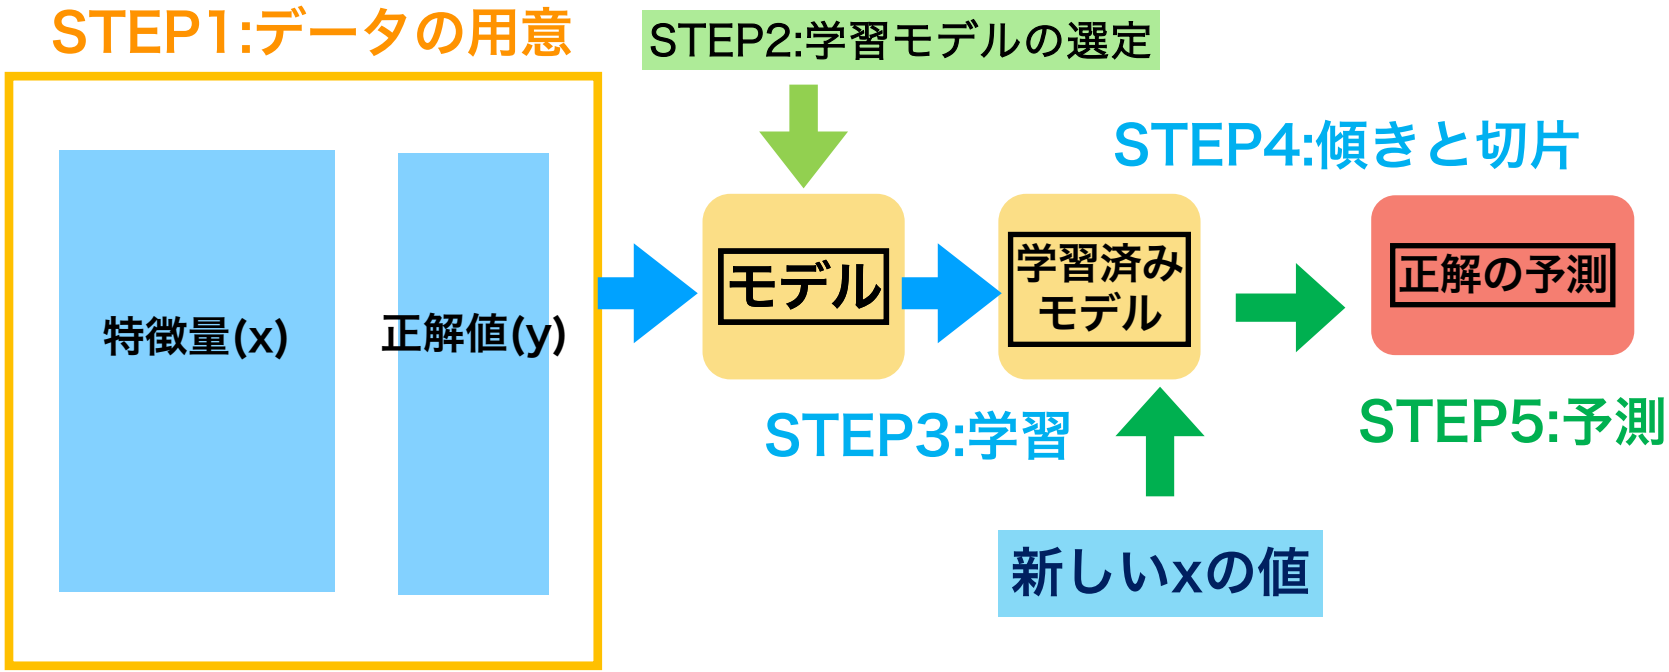

線形回帰分析

STEP5：正解値の予測

STEP0：事前準備
STEP1：データの用意
STEP2：学習モデルの選択
STEP3：データを入れて学習させる
STEP4：傾きと切片を求める
STEP5：予測を行う
STEP6：モデルの評価

コード9-6　新しいxの値（bmi=20の人）データ作成

```
pre = pd.DataFrame([[20]], columns=['bmi'])
```

- preという変数に、bmi=20の1行1列のデータを作成する
- x(特徴量データ）は2次元配列である必要がある

➡ そのため、今回はpd.DataFrame型にして、column名に'bmi'をつける

線形回帰分析

STEP0：事前準備
STEP1：データの用意
STEP2：学習モデルの選択
STEP3：データを入れて学習させる
STEP4：傾きと切片を求める
STEP5：予測を行う
STEP6：モデルの評価

STEP5：正解値の予測

コード9-7　作成したpreのデータを確認

```
pre  #データを出力
```

	bmi
0	20

```
pre.shape  #データの配列構造を出力
```

(1,1)

1行1列の2次元配列(行列)

```
type(pre) #データの型を出力
```

pandas.core.frame.DataFrame

線形回帰分析

STEP0：事前準備
STEP1：データの用意
STEP2：学習モデルの選択
STEP3：データを入れて学習させる
STEP4：傾きと切片を求める
STEP5：予測を行う
STEP6：モデルの評価

STEP5：正解値の予測

コード9-8　新しいxの値(pre)で正解値の予測

```
print(model_bmi.predict(pre))
```

➡ [86.88919084]

- （モデル名）.predict(pre)でmodel_bmiの学習済みモデルのxにpreを代入し、yの値を求める
- print()で結果を出力する

STEP4で求めた回帰式にbmi=20を代入する

y = -117.77336657 + (10.2331787 × 20) = 86.88919084

colab

線形回帰分析

STEP0：事前準備
STEP1：データの用意
STEP2：学習モデルの選択
STEP3：データを入れて学習させる
STEP4：傾きと切片を求める
STEP5：予測を行う
STEP6：モデルの評価

STEP5：プロット

コード9-9　散布図と回帰線を描出する

```
plt.scatter(x_bmi, y_dm, color='black')

plt.plot(x_bmi, model_bmi.predict(x_bmi))
```

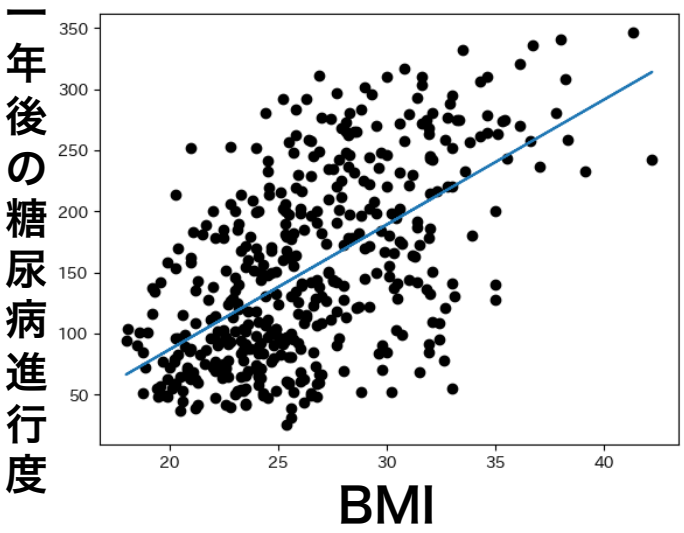

y = -117.77 + (10.23 × BMI)

- `plt.plot(x,y)` で各点を実線で結ぶ線が描出できる
- 回帰線のyは実測値ではなく、モデルで予測されたyの値であるため、`(モデル名).predict(x_bmi)` となる

線形回帰分析

STEP5：プロット

STEP0：事前準備
STEP1：データの用意
STEP2：学習モデルの選択
STEP3：データを入れて学習させる
STEP4：傾きと切片を求める
STEP5：予測を行う
STEP6：モデルの評価

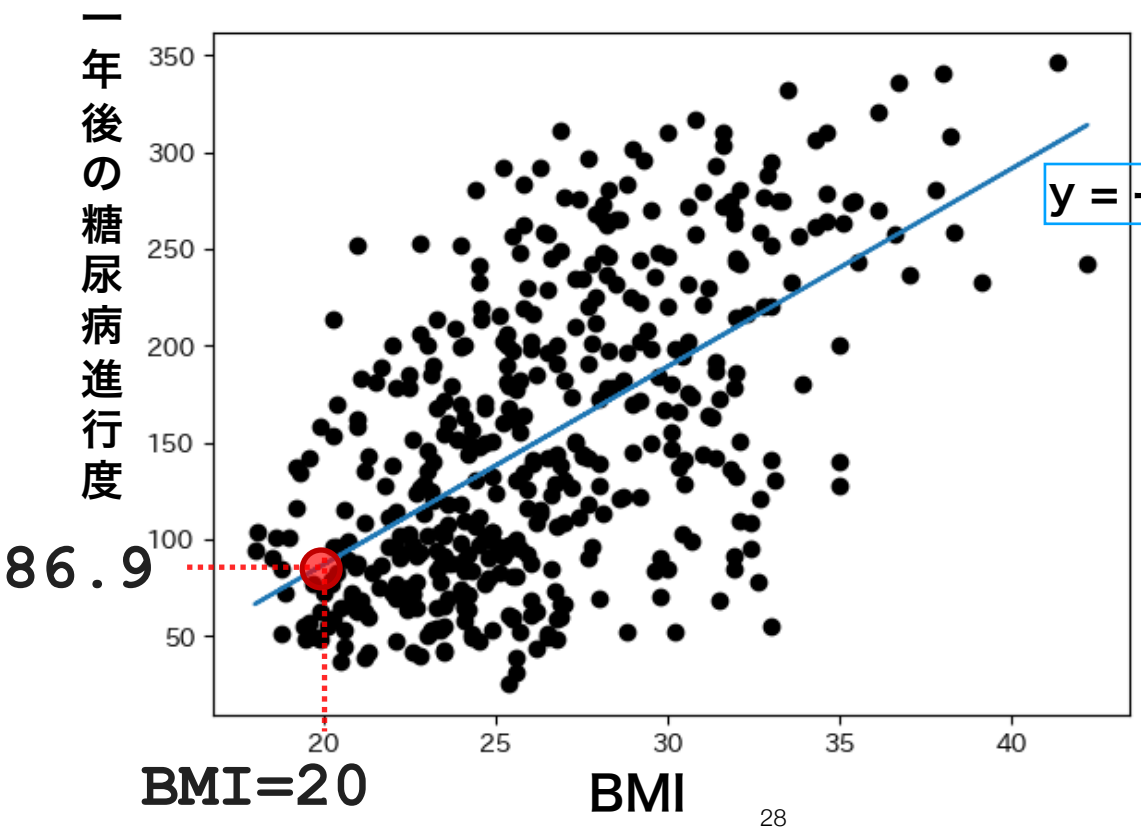

y = -117.77 + (10.23 × BMI)

colab

機械学習の流れのまとめ

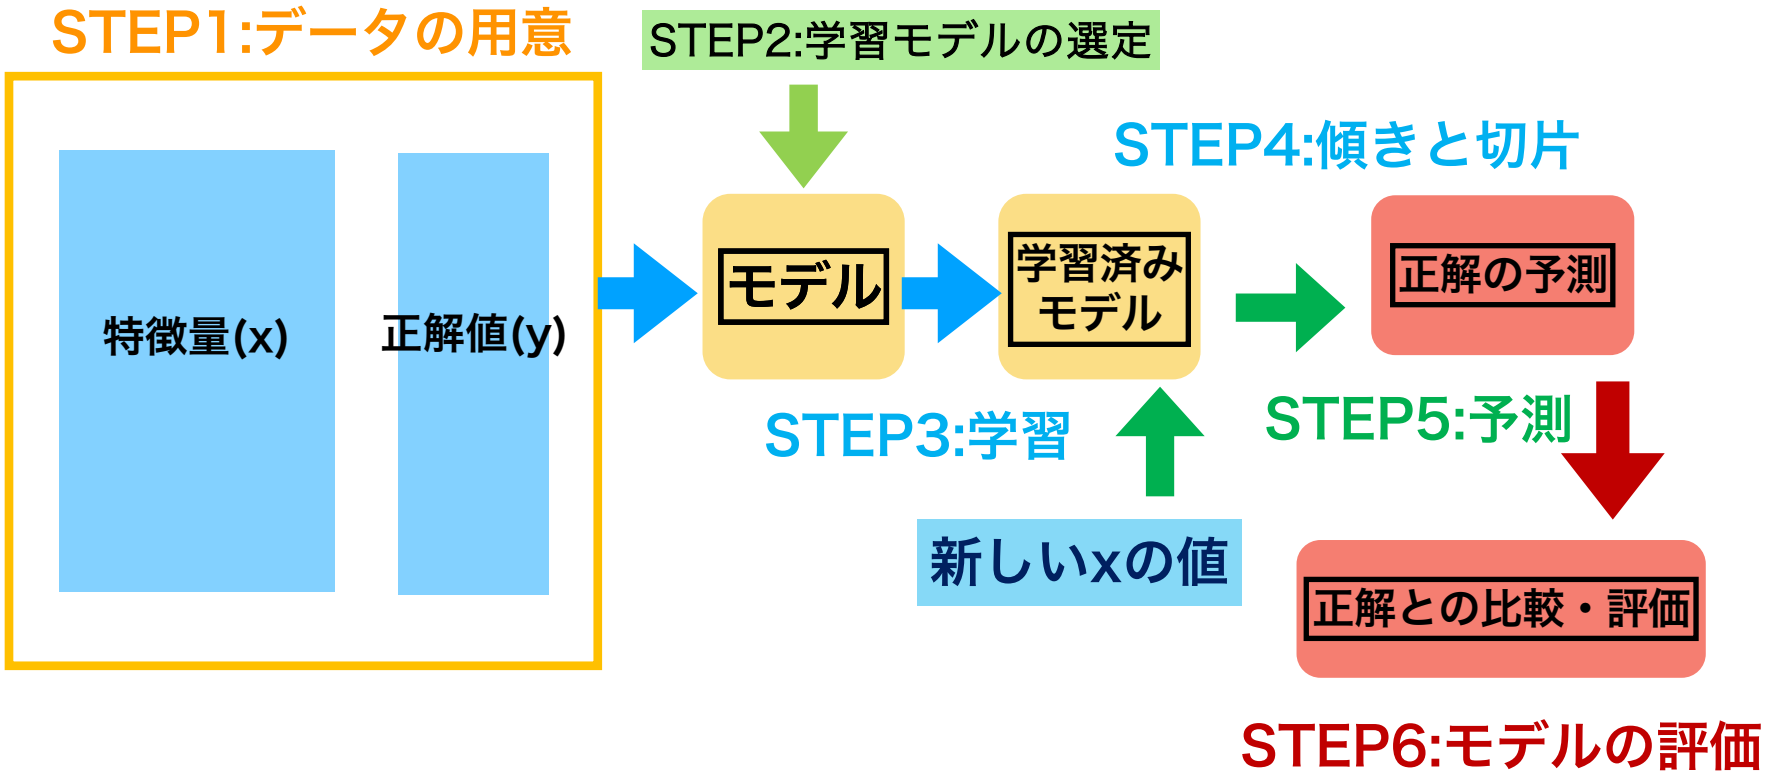

線形回帰分析

STEP0：事前準備
STEP1：データの用意
STEP2：学習モデルの選択
STEP3：データを入れて学習させる
STEP4：傾きと切片を求める
STEP5：予測を行う
STEP6：モデルの評価

STEP6：モデルの予測性能評価

コード9-10 モデルがどれぐらい予測できているかを調べる

```
print(model_bmi.score(x_bmi, y_dm))
```

➡ 0.3439237602253802

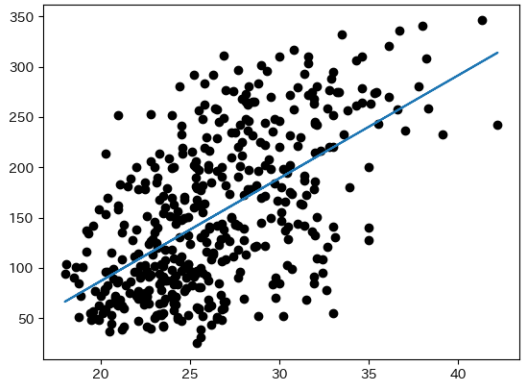

（モデル名）.score(x,y) で決定係数（R^2）を計算する

*決定係数：xとyの相関係数の二乗の値

1~0の範囲をとる

1に近いほどxでyを予測していると言える

線形回帰分析

STEP0：事前準備
STEP1：データの用意
STEP2：学習モデルの選択
STEP3：データを入れて学習させる
STEP4：傾きと切片を求める
STEP5：予測を行う
STEP6：モデルの評価

STEP6：モデルの予測性能評価

決定係数R^2

高い → 低い

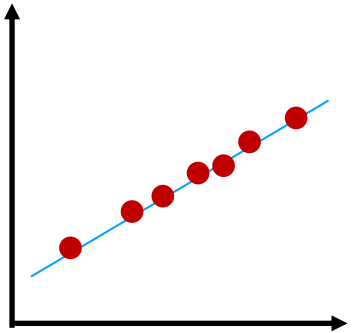

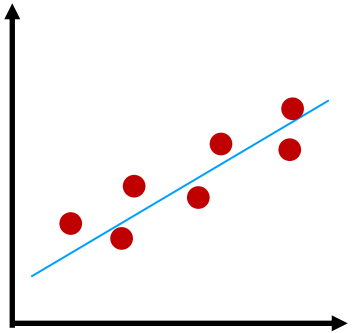

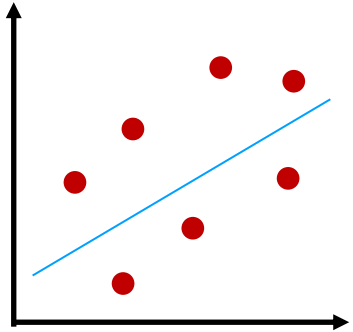

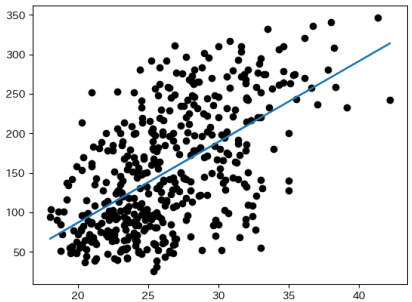

$R^2=0.34$

今回のモデルはそれほど
予測性能は高くない

colab

機械学習の流れのまとめ

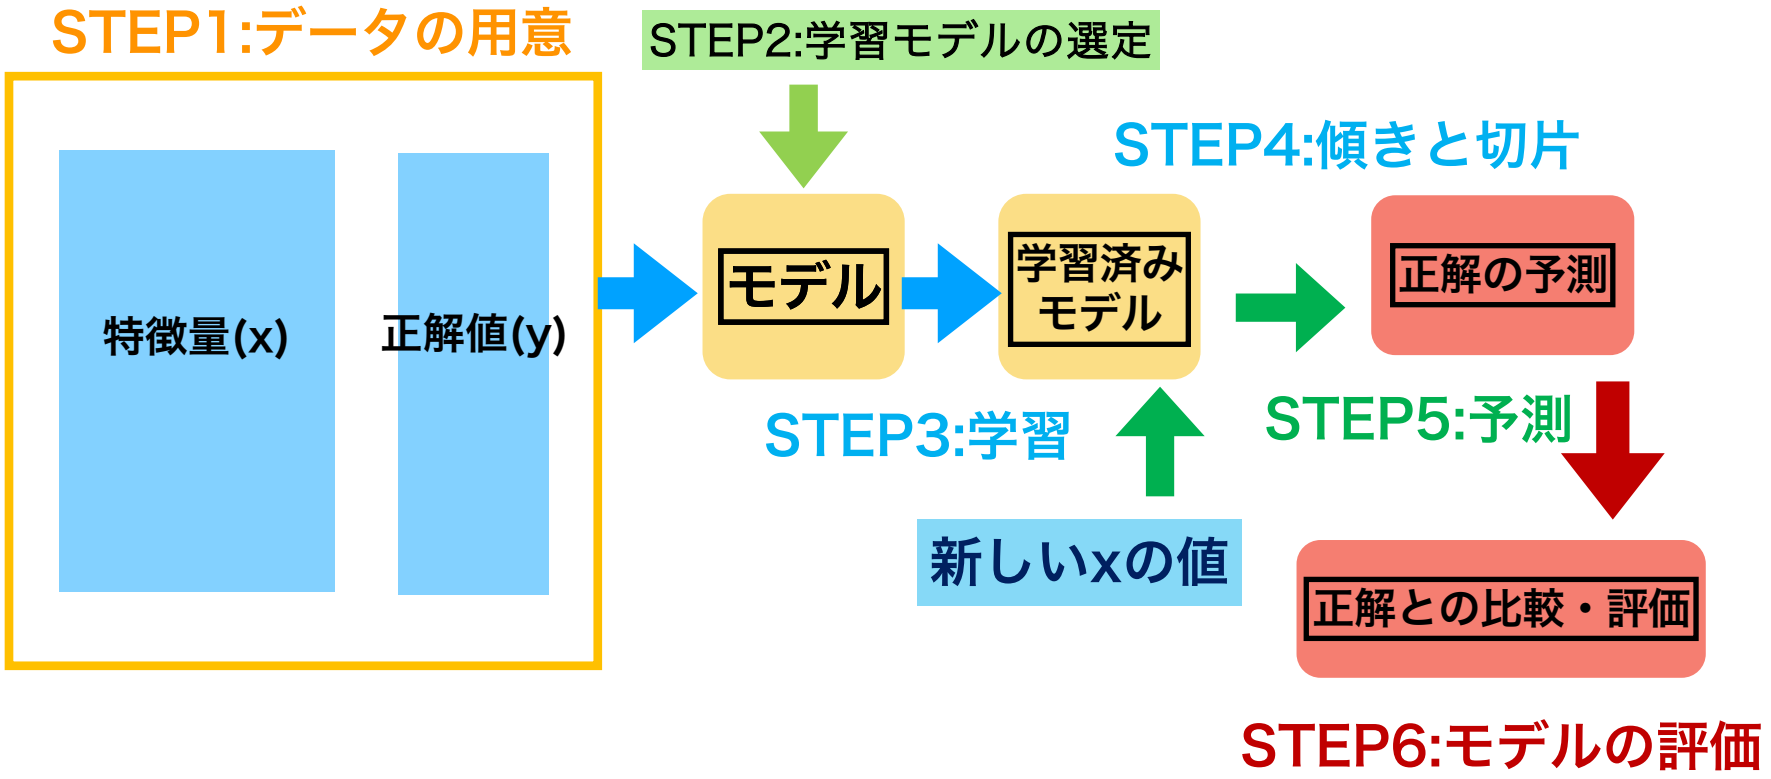

新しくmodel_dm10で10個の特徴量で線形回帰を行う

機械学習の流れのまとめ

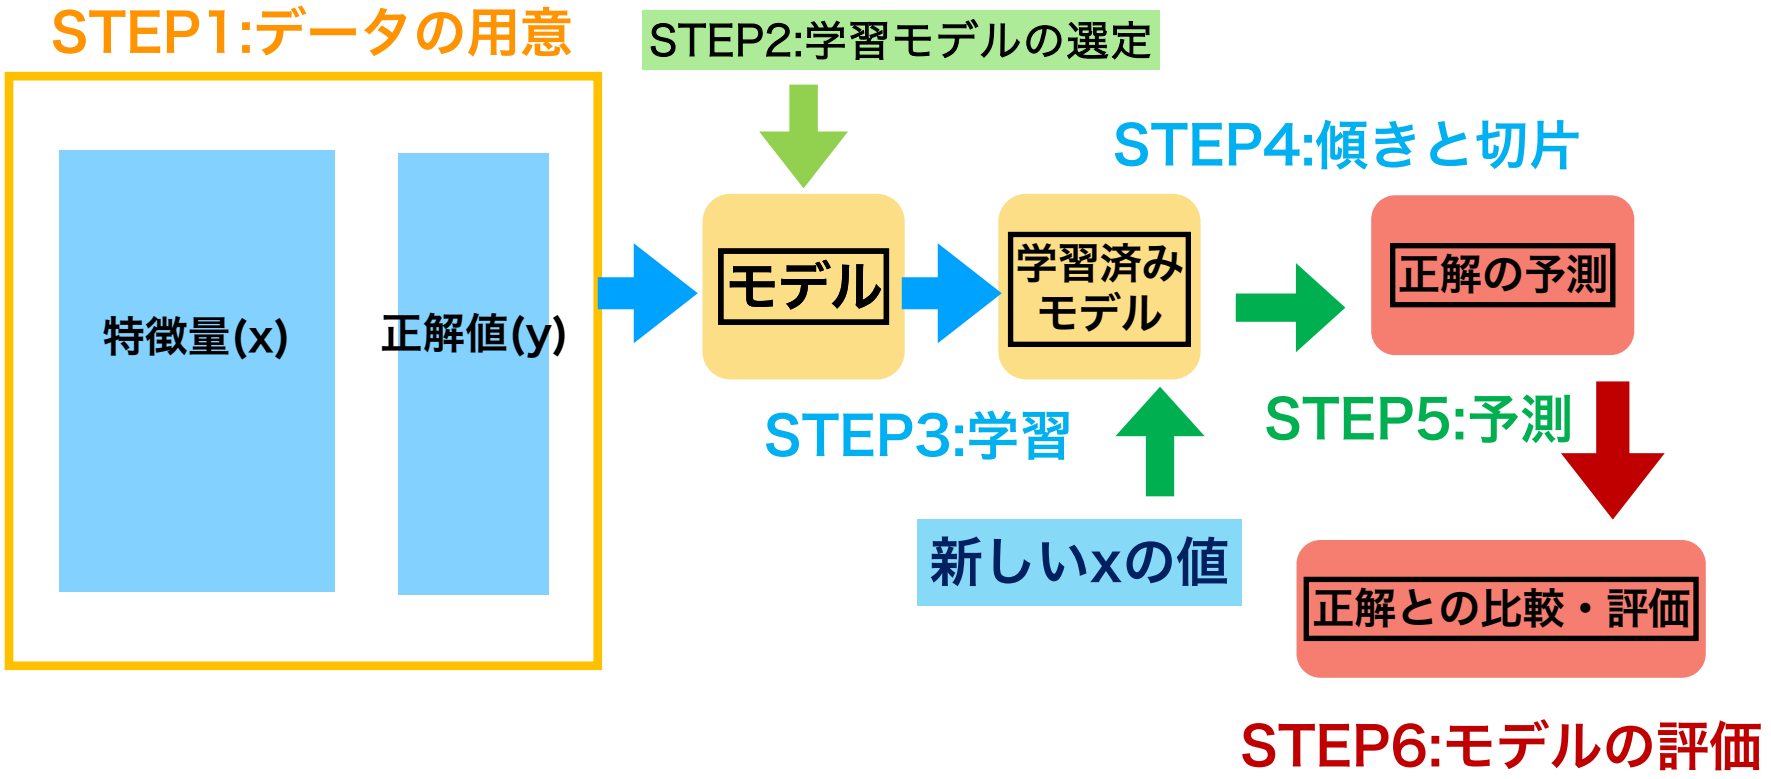

機械学習の流れのまとめ

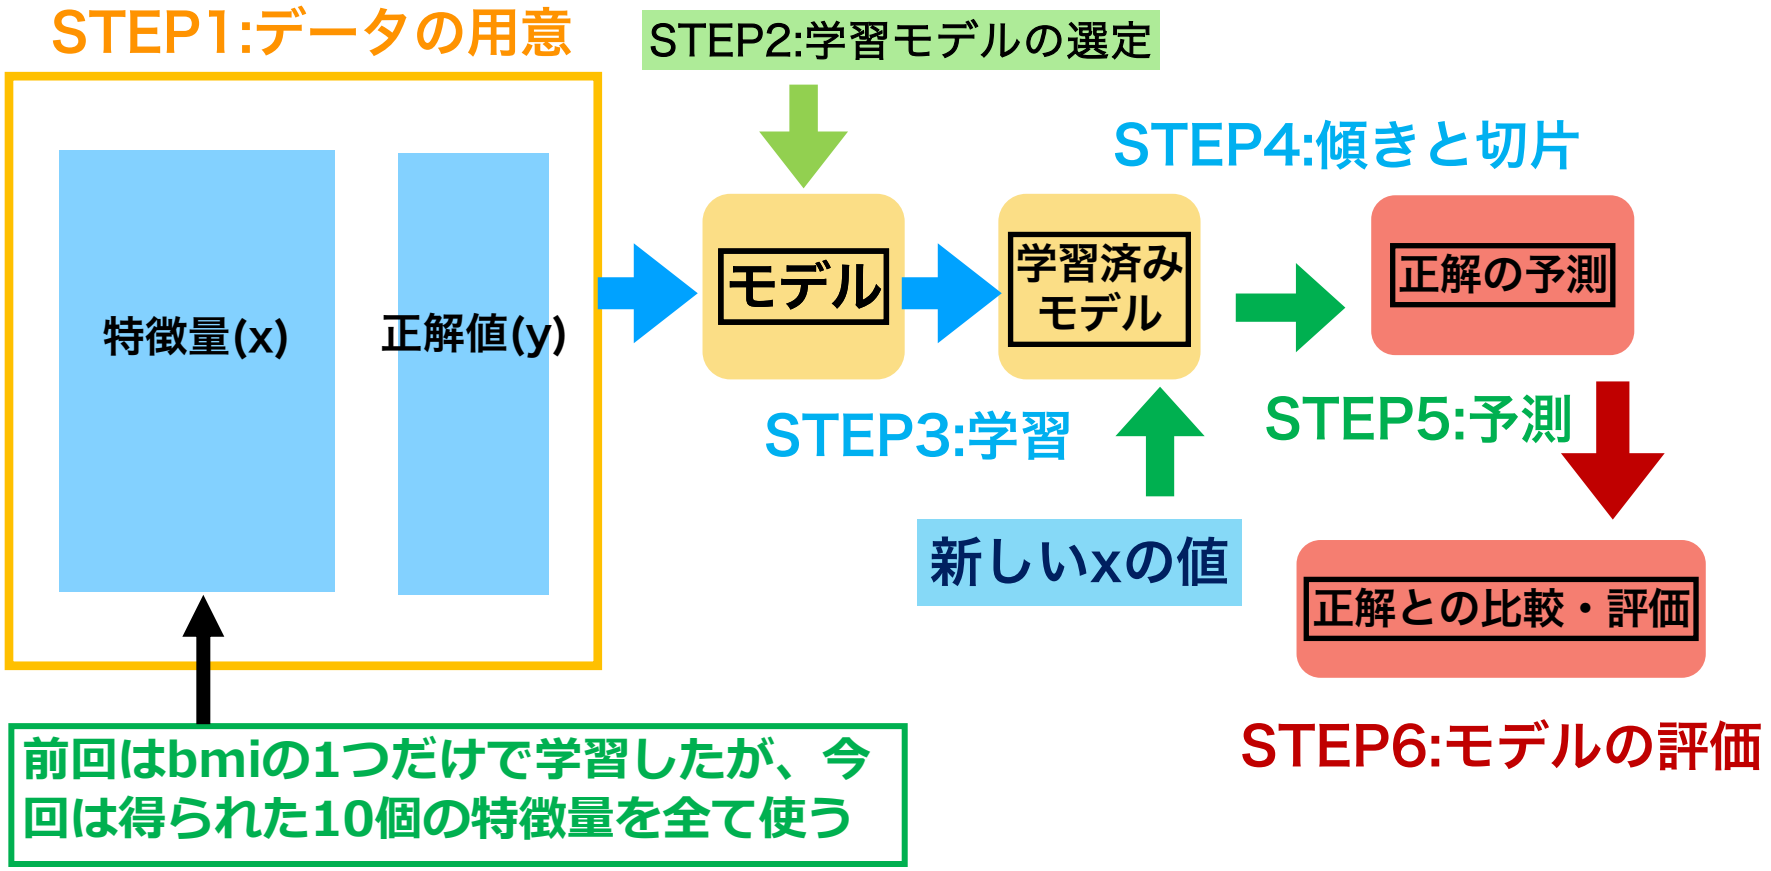

重回帰分析

単回帰に対して、複数の変数で回帰することを多変量回帰や重回帰と呼ぶ

重回帰式

$$y = b_0 + b_1x_1 + b_2x_2 + b_3x_3 + b_4x_4 + b_5x_5 + b_6x_6 + b_7x_7 + b_8x_8 + b_9x_9 + b_{10}x_{10}$$

(y：予測値、x_n：特徴量、b_0：切片、b_n：傾き)

重回帰分析

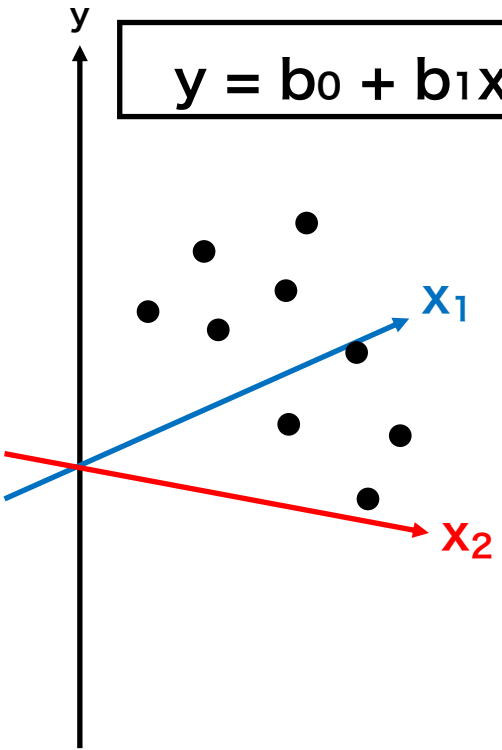

複数のxがあるときは多次元になる

10個の変数があるときは10次元のデータになる

線形回帰分析：複数の特徴量で予測

STEP0：事前準備
STEP1：データの用意
STEP2：学習モデルの選択
STEP3：データを入れて学習させる
STEP4：傾きと切片を求める
STEP5：予測を行う
STEP6：モデルの評価

コード9-11 新しくmodel_dm10インスタンスを作成し、10個の特徴量(x_dm)でy_dmを予測する

```
model_dm10 = LinearRegression()
model_dm10.fit(x_dm, y_dm)
```

```
model_bmi.fit(x_bmi, y_dm)
```

x_dmの内容（再掲）

	年齢	性別	BMI	平均血圧	TC (総コレステロール値)	LDL コレステロール	HDL コレステロール	TCH (TC/HDL)	LTG (血液中の中性脂肪値の対数)	GLU (血糖値)
	age	sex	bmi	bp	s1	s2	s3	s4	s5	s6
count	442.000000	442.000000	442.000000	442.000000	442.000000	442.000000	442.000000	442.000000	442.000000	442.000000
mean	48.518100	1.468326	26.375792	94.647014	189.140271	115.439140	49.788462	4.070249	4.641411	91.260181
std	13.109028	0.499561	4.418122	13.831283	34.608052	30.413081	12.934202	1.290450	0.522391	11.496335
min	19.000000	1.000000	18.000000	62.000000	97.000000	41.600000	22.000000	2.000000	3.258100	58.000000
25%	38.250000	1.000000	23.200000	84.000000	164.250000	96.050000	40.250000	3.000000	4.276700	83.250000
50%	50.000000	1.000000	25.700000	93.000000	186.000000	113.000000	48.000000	4.000000	4.620050	91.000000
75%	59.000000	2.000000	29.275000	105.000000	209.750000	134.500000	57.750000	5.000000	4.997200	98.000000
max	79.000000	2.000000	42.200000	133.000000	301.000000	242.400000	99.000000	9.090000	6.107000	124.000000

colab

線形回帰分析：複数の特徴量で予測

STEP0：事前準備
STEP1：データの用意
STEP2：学習モデルの選択
STEP3：データを入れて学習させる
STEP4：傾きと切片を求める
STEP5：予測を行う
STEP6：モデルの評価

コード9-12 model_dm10の傾きと切片を求める

```
print(model_dm10.coef_)
print(model_dm10.intercept_)
```

e+00：$\times 10^{0}$
e+01：$\times 10^{1}$
e-01：$\times 10^{-1}$

```
[-3.63612242e-02 -2.28596481e+01  5.60296209e+00  1.11680799e+00
 -1.08999633e+00  7.46450456e-01  3.72004715e-01  6.53383194e+00
  6.84831250e+01  2.80116989e-01]
-334.5671385187877
```

傾きは特徴量ごとに出るので、10個出力

回帰式に当てはめる

$$y = -334.57 + (-0.036 \times Age) + (-22.85 \times Sex) + (5.60 \times BMI) + (1.12 \times BP) + (-1.09 \times TC) + (0.75 \times LDL) + (0.37 \times HDL) + (6.53 \times TCH) + (68.5 \times LTG) + (0.28 \times GLU)$$

colab

線形回帰分析：複数の特徴量で予測

STEP0：事前準備
STEP1：データの用意
STEP2：学習モデルの選択
STEP3：データを入れて学習させる
STEP4：傾きと切片を求める
STEP5：予測を行う
STEP6：モデルの評価

コード9-13 複数の特徴量を入れたモデルの評価を行う

```
print(model_dm10.score(x_dm, y_dm))
```

➡ 0.5177484222203498

(再掲) `print(model_bmi.score(x_bmi, y_dm))`
→0.3439237602253802

今回は一つの特徴量(bmi)より10個の特徴量を入れて予測する方が予測能が向上した（1に近いほど予測能が高いと言える）

➡ 特徴量が多いほどyを予測できる性能が高かった
一方、多ければ多いほど必ず予測性能が高くなるとも限らない

➡ 機械学習では予測性能を高めることが非常に重要な目的

colab

演習9：課題

Webclassで課題を提出してください。締め切りは2024/01/31 23:59まで

(1)dmデータの特徴量データからage, sex, bmi, s6(血糖値)の4つを抽出してx_dm4を作成してください(コードを記載してください)

(2)(1)の特徴量を使用して、線形回帰モデルをmodel_dm4と名前をつけて作成し、重回帰を行ってください。model_dm4の切片を求めて記載してください。　(出力結果)

(3)(2)の決定係数 R^2 を回答してください。　(出力結果)