# 5．データマネジメント

https://www.kkaneko.jp/cc/enshu2/index.html

金子邦彦

①Pandasデータフレームの実用性

②外れ値の検出と処理

③線形回帰とモデルの評価

# アウトライン

1. イントロダクション
2. AIの基礎
3. データマネジメント

# Google Colaboratory



URL: https://colab.research.google.com/

- **オンラインで動く**
- **Python のノートブック**の機能を持つ
- Python や種々の機能が**インストール済み**
- **本格的な利用**には，**Google アカウントが必要**

# Google Colaboratory の全体画面

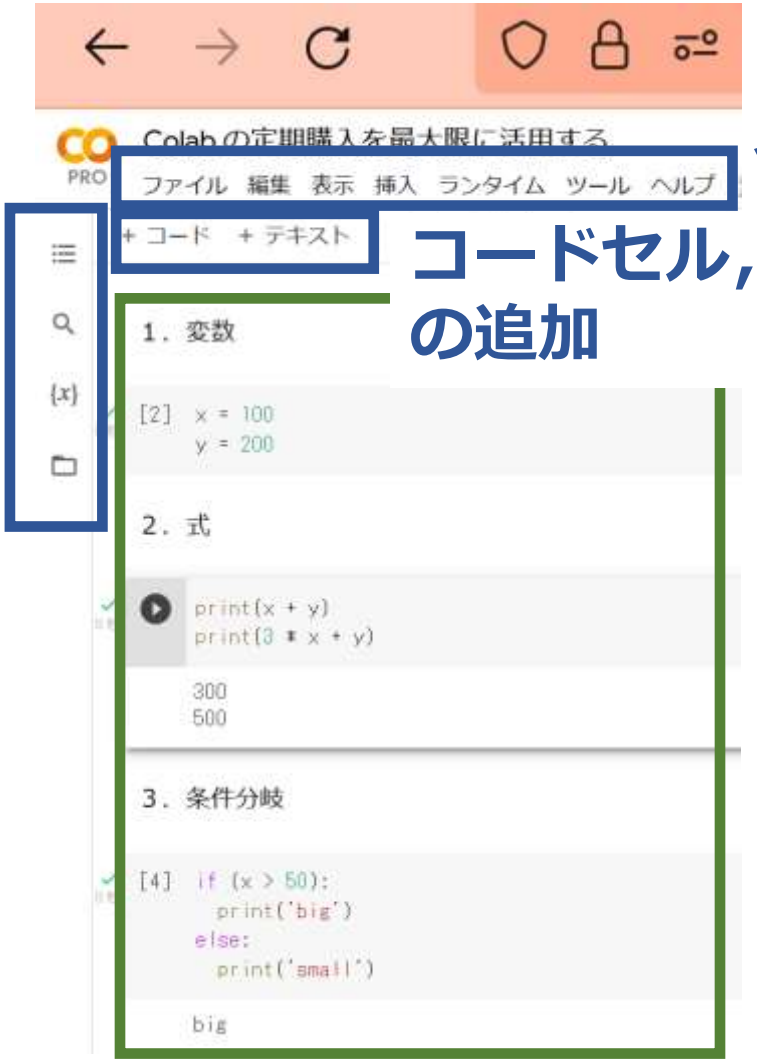


**メニュー**
（目次，検索と置換，変数，ファイル）

**メニュー**

**コードセル，テキストセルの追加**

**コードセル，テキストセルの並び**

Web ブラウザの画面

# Google Colaboratory のノートブック

## **コードセル**，**テキストセル**の２種類

- **コードセル**： Python プログラム，コマンド，実行結果
- **テキストセル**：説明文，図

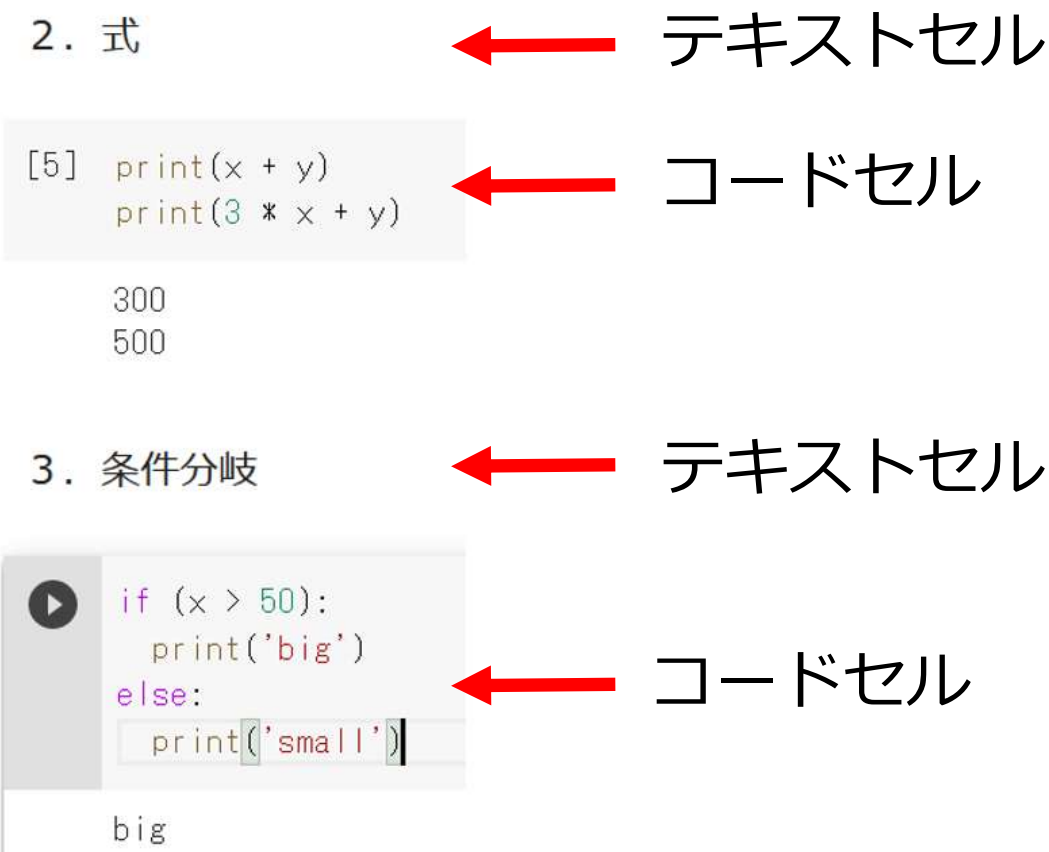

# Google Colaboratory の本格的な機能（使用には Google アカウントが必要）

- **ノートブック**の**新規作成，編集，保存，公開**（Google Drive との連携による）
- 公開により，**第三者がノートブックをダウンロードし，編集や実行なども可能**
- **Python プログラム**（コードセル内）の**編集，実行**
- 「!pip」や「%cd」などのシステム操作のための**コマンド**（コードセル内）の**編集，実行**
- **ファイル**の**アップロード，ダウンロード**
- ドキュメントの編集（図，リンク，添付ファイルを含めることができる）

# 5-1. イントロダクション

# Python の Pandas データフレーム

表形式のデータ

| | x | y |
|---|---|---|
| 0 | 1 | 4 |
| 1 | 1 | 2 |
| 2 | 1 | 5 |
| 3 | 2 | 4 |
| 4 | 3 | 5 |
| 5 | 3 | 3 |

データ本体

# 5-2. AI の基礎

# 機械学習と訓練データとプログラム

## 機械学習のプログラム

**学習に使用する訓練データ**
（抜粋）

41078
12716
64773
37991
06699

画像 60000枚
（うち一部）

正解 60000個
（うち一部）

プログラム

データを用いて学習を行う
学習ののち，画像分類を行う

学習の結果、文字認識の能力を獲得

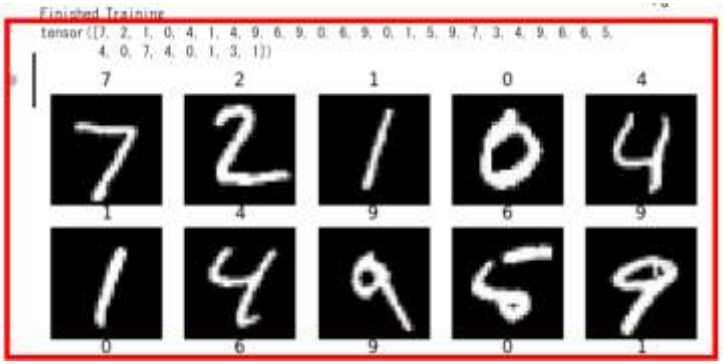

# 機械学習と訓練データ

**機械学習**は，**コンピュータ**が**データ**を使用して**学習**することより**知的能力を向上**させる技術

**訓練データ**

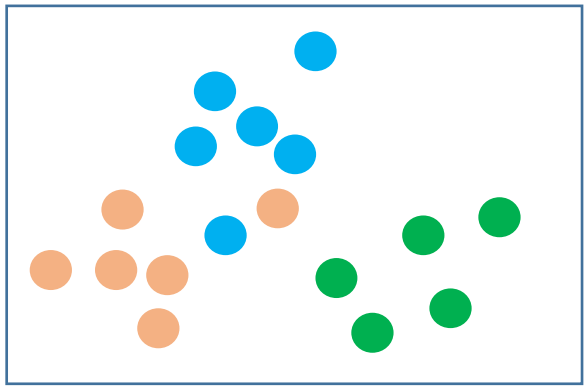

3 種類に分類済み

**学習**

学習者

大量の訓練データを用いて
学習を行う

# Iris データセットのロードと散布図（Pandas データフレームを使用）

```python
# 必要なライブラリをインポート
from sklearn.datasets import load_iris
import matplotlib.pyplot as plt
import pandas as pd

# irisデータセットをロード（pandas を使用）
iris = load_iris()
df = pd.DataFrame(iris.data, columns=iris.feature_names)

# データの先頭と末尾を確認
print("データの先頭:")
print(df.head())
print("データの末尾:")
print(df.tail())

# 必要な列だけを選択（DataFrame形式でスライス）
X = df[['sepal length (cm)']]
y = df['sepal width (cm)']

# Matplotlibを用いて結果をプロット
plt.scatter(X, y, color='blue')

# 軸ラベルとタイトルを追加
plt.xlabel('Sepal Length')
plt.ylabel('Sepal Width')
plt.title('Iris Dataset')

# グラフを表示
plt.show()
```

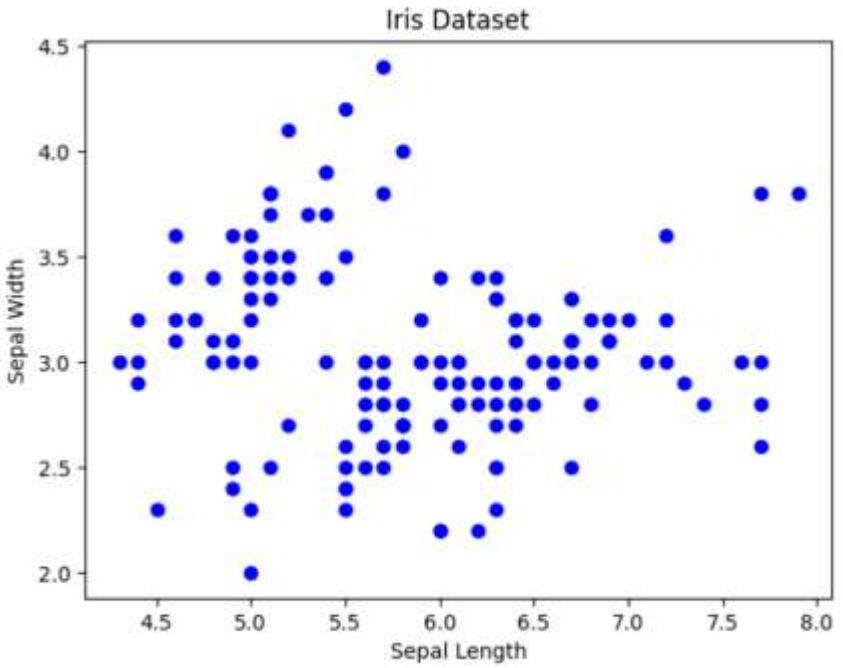

# 機械学習の例（線形回帰）

機械学習のうち１つ「**線形回帰**」を行う。**線形回帰**は**データに最もよく適合する線を見つけること**である。

```python
# 必要なライブラリをインポート
from sklearn.linear_model import LinearRegression
from sklearn.datasets import load_iris
import matplotlib.pyplot as plt
import pandas as pd

# irisデータセットをロード（pandas を使用）
iris = load_iris()
df = pd.DataFrame(iris.data, columns=iris.feature_names)

# データの先頭と末尾を確認
print("データの先頭:")
print(df.head())
print("データの末尾:")
print(df.tail())

# 必要な列だけを選択（DataFrame形式でスライス）
X = df[['sepal length (cm)']]
y = df['sepal width (cm)']

# 線形回帰モデル
model = LinearRegression()

# 学習
model.fit(X, y)

# 予測を行う
y_pred = model.predict(X)

# Matplotlibを用いて結果をプロット
plt.scatter(X, y, color='blue')
plt.plot(X, y_pred, color='red')

# 軸ラベルとタイトルを追加
plt.xlabel('Sepal Length')
plt.ylabel('Sepal Width')
plt.title('Linear Regression on Iris Dataset')

# グラフを表示
plt.show()
```

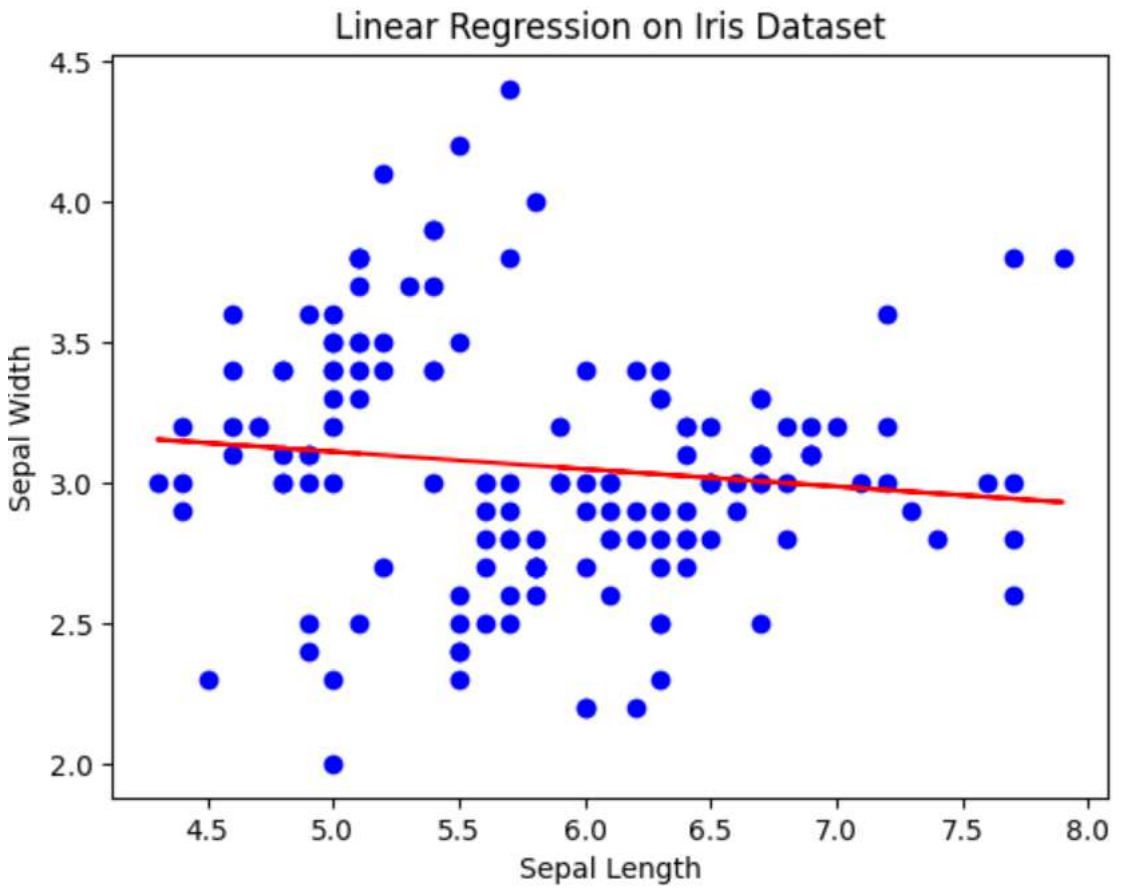

# 5-3. データマネジメント

# 外れ値

**外れ値とは**

- データ集合の中で、他のデータから**顕著に異なるデータ**

例: 年齢データにおいて、通常 0 から 120 程度の範囲が考えられる。1000 や -5 などの値が現れる場合は外れ値。

**外れ値を取り扱うことのメリット**

- **分析の精度向上**：平均、分散など統計的指標がより正確に反映されるようになる
- **機械学習モデルの性能向上**：外れ値を適切に処理することで、機械学習モデルが、外れ値にも適応するのを防ぐ

# 外れ値の主な検出方法と対処方法

**外れ値の検出方法**

- 統計的手法

  平均値からの偏差（Zスコア）

  データの分布を示す IQR（四分位範囲）

- 可視化による確認

  散布図、ボックスプロットを用いてデータの分布を

  視覚的に確認し、外れ値を特定

**外れ値の対処方法**

- 削除：外れ値を取り除く
- 置換：外れ値を中央値、平均値などの代表的な値で置換

# 欠損値と Python の NaN

欠損値

- データセット内で「**存在しない**」、「**測定されていない値**」、「**未知**」のものを欠損値という
- 欠損値の原因: データ収集のミス、調査の未回答などが考えられる

Python の NaN

- NaN は “Not a Number” の略語で、「**数値として定義されない値**」という意味
- Python では、欠損値や計算上のエラー（例： 0での除算）を表現するために NaN を使用

# 線形回帰

- **線形回帰**は**データに最もよく適合する線を見つけること**である。

例：家の大きさから、家の価格を予測

線形回帰モデル

価格 = β0 + β1 × 家の大きさ

# Auto MPG データセット

車の性能や特性に関する情報を提供しており、これを基に燃料効率（mpg）の予測モデルを構築することができる

- 作成: 1993年
- Python の CMU StatLib ライブラリ内
- 行数 398
- 属性
  - displacement: 排気量
  - mpg: 燃料消費（ガロンあたりのマイル数）
  - cylinders: シリンダー数
  - horsepower: 馬力（欠損値あり）
  - weight: 重量
  - acceleration: 加速
  - model_year: モデル年
  - origin: 産地または原点
  - car_name: 車名
- mpg 以外の全属性を「特徴」
- mpg を「ターゲット」

# 演習
# データマネジメントの
# プラクティス

**トピックス】**

- **Pandas データフレーム**
- **欠損値の処理**
- **外れ値の処理**
- **データの分割（訓練データ、テストデータへの分割）**
- **線形回帰モデルの評価**

# データマネジメントのプラクティス

- データセットの確認
  - データの先頭と末尾を表示して確認
  - 平均、分散、標準偏差の確認
- 欠損値の処理
  - ここでは、欠損値を含む行は除去している。
- 外れ値の処理
  - 平均値からの偏差（Zスコア）を使用して外れ値を検出
  - ここでは、外れ値を含む行は除去している。
- データの分割
  - 訓練データとテストデータに分ける。
- モデルの学習と評価
  - 訓練データで線形回帰モデルを学習し、テストデータを用いて「うまく学習できたか」を評価。

## ①Pandasデータフレームの実用性

Pandasのデータフレームは、データ分析のための強力なツールとして知られており、実世界のデータの操作や解析に役立ちます。データフレームには、様々なデータ操作や分析を支援する機能が組み込まれており、これを習得することで、多様な課題への取り組みが可能になります。

## ②外れ値の検出と処理

データサイエンスや機械学習の分野では、外れ値が分析結果に大きな影響を及ぼすことがあります。外れ値の正確な検出と適切な処理方法を学ぶことは、データの質を高め、より正確な予測や分析につながります。

## ③線形回帰とモデルの評価

線形回帰は、データの予測に関する基本的な手法の一つであり、特徴とターゲットの関係を明確にする上で重要です。モデルの正確さを評価する際、まず、データを訓練データとテストデータに分けることが必要です。そして、訓練データで学習したモデルの性能は、必ず、テストデータを用いて評価されるべきです。