

aa-4. 機械学習、ニューラル ネットワーク

(人工知能)

URL: <https://www.kkaneko.jp/ai/mi/index.html>

金子邦彦



アウトライン

1. 機械学習
2. 機械学習の現状
3. ニューラルネットワークの概要
4. ニューラルネットワークの種類, 応用分野
5. 線形近似 (学習の例)
6. 最適化

今日の授業では, **Office 365** のインストールを済ませておくことが便利です.

4-1 機械学習

機械学習の特徴



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

- **情報の抽出**：データの中からパターンや関係性を自動で見つけ出す能力
- **簡潔さ**：人間が設定しなければならなかったルールを、自動で生成できるようになる
- **限界の超越**：他の方法では難しかった課題でも、機械学習を用いることで解決策や視点を得られる可能性がある




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に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




学習者

大量の訓練データを用いて
学習を行う

機械学習のプログラム

学習に使用する訓練データ (抜粋)



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

```
[4] !pip install -U scikit-learn matplotlib

import torch
import torch.nn as nn
import torch.optim as optim
from sklearn import datasets
from sklearn.model_selection import train_test_split
from sklearn.preprocessing import StandardScaler
import matplotlib.pyplot as plt

# データの取得と前処理
iris = datasets.load_iris()
X = iris.data
y = iris.target

# データの標準化
scaler = StandardScaler()
X = scaler.fit_transform(X)

# 訓練データとテストデータの分割
X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=0.2, random_state=42)


X_train = torch.tensor(X_train, dtype=torch.float32)
y_train = torch.tensor(y_train, dtype=torch.long)
X_test = torch.tensor(X_test, dtype=torch.float32)
y_test = torch.tensor(y_test, dtype=torch.long)

# ニューラルネットワークの定義
class Net(nn.Module):
    def __init__(self):
        super(Net, self).__init__()
        self.fc1 = nn.Linear(4, 10) # 入力4次元 (Irisの特徴量)
        self.fc2 = nn.Linear(10, 3) # 出力は3クラス

    def forward(self, x):
        x = torch.relu(self.fc1(x))
        x = self.fc2(x)
        return x

net = Net()
criterion = nn.CrossEntropyLoss()
optimizer = optim.SGD(net.parameters(), lr=0.01)
```

学習の結果、文字認識の能力を獲得



機械学習まとめ

機械学習の特徴

- データを用いて知的能力を向上
- 自動でデータのパターンを抽出
- さまざまなタスクを自動実行

応用事例

画像理解、自然言語処理、予測
など多数

機械学習の定義：

- **訓練データ**を用いて**学習**し、その結果として知的能力が向上
- 訓練データの追加により、さらに知的能力が向上する可能性



一般のプログラミング



データ
(入力)



プログラム

コンピュータ




処理結果

入力
9
1 0
1 1
1 2
1 3
1 4

入力	処理結果
9	5 0 0
1 0	5 0 0
1 1	5 0 0
1 2	1 0 0 0
1 3	1 0 0 0
1 4	1 0 0 0

あらゆる入力について
正しい処理結果が得られるように、
プログラムを作成し、テストする

機械学習での予測



訓練データにより，学習が行われる。

新しいデータに対しては、自動で処理が行われる。

① 一般のプログラミング

- ・ プログラムは人間が作成し、テストし、調整する。

データ
(入力)



プログラム

コンピュータ



処理結果

② 機械学習

- ・ データを利用して知的能力を向上させる

データ
(入力)



プログラム

コンピュータ



処理結果

訓練データ



4-2 機械学習の現状

- **能力の多様性:**

分類、検出、識別、認識（文字認識、画像の認識、音声認識）、予測、合成、翻訳、特徴抽出、ランク付け、情報推薦など、**さまざまな能力を持つ**

- **応用範囲の広さ:**

経済、金融、ロボット、医療、医学研究（遺伝子解析）など、様々な分野で問題解決に活用

機械学習は多様な能力を持ち、経済や金融から医療やロボットまで広範な応用が可能

人工知能の宿泊サイトでの応用



• 宿泊予約サイト Booking.com

情報推薦, 表示の改良, 好みの予測

The screenshot displays the Booking.com homepage with a search bar at the top. The search criteria are set to '目的地' (Destination), 'チェックイン - チェックアウト' (Check-in - Check-out), and '大人2名・子供0名・1部屋' (2 adults, 0 children, 1 room). The search results are filtered by '出張・ビジネスでの利用' (Business travel). A calendar overlay shows the dates for May and June 2022. Below the calendar, a list of hotels is displayed, including 'ダイワロイネットホテル福岡駅前' (Daiwa Roynet Hotel Fukuoka Ekimae), 'リッチモンドホテル福岡駅前' (Richmond Hotel Fukuoka Ekimae), 'Hotel Trend Fukuoka Ekimae', 'カンデオホテルズ福岡' (Candoh Hotels Fukuoka), and '福山 プラザホテル' (Fukuyama Plaza Hotel). Each hotel listing includes a photo, name, address, rating, and price.


ホテル名	住所	評価	料金 (1泊)
ダイワロイネットホテル福岡駅前	福岡市, 三之丸町	8.6	¥9,600
リッチモンドホテル福岡駅前	福岡市, 東区町1-1	8.2	¥8,000
Hotel Trend Fukuoka Ekimae	福岡市	7.9	¥7,500
カンデオホテルズ福岡	福岡市, 御船町2-8-20	7.8	¥8,500
福山 プラザホテル	福岡市, 住吉町 1-40	7.4	¥6,800

医療での人工知能の応用のニュース



- 画像診断について，さまざまなニュースがインターネットで公開されている。

胸部のX線画像について，自分自身で，人工知能アプリを動かし，ヒントを得る




MAMMOSCREEN社のニュース

<https://www.mammoscreen.com/how-it-works>

医学での人工知能の応用のニュース



血液検査による癌の検査（人間の免疫機能によって破壊されたがん細胞の検出）に関するニュース



<https://www.theguardian.com/science/2020/mar/31/new-blood-test-can-detect-50-types-of-cancer>

能力の向上が続いている.



- 1997年：ディープ・ブルーがチェスの世界チャンピオンに勝利
- 2017年：自己対戦による学習能力を持つ AlphaZeroが登場
- 2017年5月：AlphaZeroが囲碁で世界レベルの選手に対して3戦全勝

機械学習が、複雑なゲームでも、知的な戦略や判断を行う能力を持っている

自動運転のニュース



- 自動運転について、さまざまなニュースがインターネットで公開されている。



6 Autonomous Vehicles & Companies to watch in 2021-2022 | Self Driving Cars

<https://www.youtube.com/watch?v=bdFi3RToOBk>

人工知能による画像の合成



さまざまな種類の画像を，安定して，高精細に生成することが可能に


Large Scale GAN Training for High Fidelity Natural Image Synthesis

[Andrew Brock](#), [Jeff Donahue](#), [Karen Simonyan](#), <https://arxiv.org/abs/1809.11096v2>

4-3. ニューロンと脳の構造

ニューロン

ニューロンは、脳や神経系において、情報伝達、記憶、情報処理を行う基本要素。



脳のニューロン



脳のニューロンの数（推定値）

- カタツムリ 11,000
- ロブスター 100,000
- アリ 250,000
- カエル 16,000,000
- ハツカネズミ 71,000,000
- タコ 500,000,000
- ネコ 760,000,000
- ヒト 86,000,000,000
～ 100,000,000,000
- アフリカゾウ 257,000,000,000

- 生物の種によって数が異なる
- 人間の脳には**約860億～1000億個**のニューロンが存在
- 複雑なネットワークを形成

Wikipedia の記事:

<https://ja.wikipedia.org/wiki/%E5%8B%95%E7%89%A9%E3%81%AE%E3%83%8B%E3%83%A5%E3%83%BC%E3%83%AD%E3%83%B3%E3%81%AE%E6%95%B0%E3%81%AE%E4%B8%80%E8%A6%A7> より

脳や神経系の研究の進展



1900年頃: **脳や神経系**は, **ニューロンの集まり**と考えられるようになった. ニューロンが情報伝達を行うことも分かってきた.

1980年頃: **脳機能マッピングによる脳の解明** (どの部分がどの機能を持つか) が進んだ. 生きた脳を対象とした測定が行われるようになってきた.

2010年頃: **異なる脳領域の連携**が観察されるようになった.

脳の仕組みと機能について深い洞察が得られるように

ニューラルネットワーク



- コンピュータを使用
- 生物の脳の働きを模倣することを目指した, 人工知能の一種
- すでに広く普及している
- 仕組み: 入力の重みづけ, 合計とバイアス, 活性化関数の適用を行うニューロンがネットワークを形成



ニューラルネットワークの歴史



1940年代：ニューラルネットワークの誕生

1960年代：バックプロパゲーションの誕生（ニューラルネットワークの学習の基本的な仕組み）（1986年にRumelhartらによって再発見）

2010年代：多層化, 正規化, ReLU, ドロップアウト
など, ニューラルネットワークの新技术

ニューラルネットワークの進展傾向

年	コンピュータで扱えるニューロン数の規模
2010年	100,000個
2020年	2,000,000個
2030年	50,000,000個
2040年	1,000,000,000個
2050年	20,000,000,000個

所説あります

2055年ごろには1000億を超えるかも？

【将来傾向】


- **規模は増加傾向**
- GPU（プロセッサの一種）、クラウドコンピューティング（大規模計算の基盤）の**発展**
- 人間の脳の**約860～1000億個**のニューロンを模倣することも、あながち不可能ではないかも

4-3. ニューラルネット ワークの基本構造

ニューラルネットワークの仕組み



入力の重みづけ, 合計とバイアス, 活性化関数の適用を行う
ニューロンがネットワークを形成



入力の重みづけ，合計とバイアス，活性化関数の適用



1. 入力の重みづけ: 各入力値に対して，それぞれの対応する重みを掛ける．例： 0.3×0.1 -0.5×0.8 0.2×-0.5
2. 合計とバイアス: 合計を計算し，バイアス（数値）を加える．例 0.03 -0.4 -0.1 の合計は -0.47 ．これに 0.2 を加える
3. 活性化関数の適用: 結果に，活性化関数を適用．ニューロンの活性度を得る（→次のニューロンの入力になる）

バイアス 0.2

$$0.3 \times 0.1 \Rightarrow 0.03$$

$$-0.5 \times 0.8 \Rightarrow -0.4$$


$$0.2 \times -0.5 \Rightarrow -0.1$$

入力 重み

合計
 -0.47



-0.27 に
活性化関数
を適用



前処理

(データが青い部分にあれば活性化)

データが中央にあれば活性化

→結合→ 1 層目 →結合→ 2 層目

ニューラルネットワーク

ニューロンの活性化と非活性化

ニューロンの出力が、プラスの大きな値
→ **活性化**している

ニューロンの出力が、0に近い値
→ **活性化**していない

4-4. ニューラルネットワーク の種類、応用分野

ニューラルネットワークの種類



① オートエンコーダ（オートエンコーダ）
データを低次元の符号にマッピング


② 分類や予測
データから分類結果，予測結果を導く

データを用いて学習を行うことは共通している

オートエンコーダでの符号化と再構築



- **元データを圧縮してエンコード表現を得る**
- **エンコード表現から再構成し，元データを再現**
- **元のデータの最も重要な特徴を自動的に学習**



オートエンコーダの応用例



画像復元



写真からの顔の3次元化

- **特徴抽出**

オートエンコーダは、データを低次元の符号にマッピングするので、特徴抽出に活用できる

- **データ圧縮**

低次元の符号化表現は元のデータよりも効率的な表現となる

- **ノイズ除去**

ノイズのあるデータを与え、ノイズのないデータを復元できる

- **異常検出**

正常なデータのパターンを学習し、異常なデータを検出するために使用できる

オートエンコーダの例



元のデータ

2 5 画素の白黒画像

11111

10001

10001

10001

11111

オートエンコーダの圧縮と再構成



元のデータ
8 個の数値

1 0 1 0 1 0 1 0

エンコード表現
元のデータを**圧縮**

0.993 0.838 0.995



再構成データ
8 個の数値を再構成可
能（完ぺきではない）

0.104 0.997 0.999,
0.968 0.997 0.945,
0.975 0.000

オートエンコーダの圧縮と再構成



1. データの圧縮と再構成

- 入力: [1, 0, 1, 0, 1, 0, 1, 0]
- 再構成: [0.998, 0.028, 0.979, 0.016, 0.985, 0.017, 0.975, 0.004]
- 高精度な再現: $1 \rightarrow 0.9$ 以上, $0 \rightarrow 0.03$ 未満


2. エンコード表現によるサイズ削減

- 元データは8つの数値 $\rightarrow$ エンコード表現は3つの数値
- エンコード例: [1, 0, 1, 0, 1, 0, 1, 0] $\rightarrow$ [0.993, 0.838, 0.995]
- 本質的特徴を保持しつつデータ圧縮

オートエンコーダによるデータ生成



オートエンコーダの結果として、**再構成（エンコード表現からの元データの再構成）**ができることから、「**現実**にあり得るデータを生成できる能力を獲得」と考えることもできる



- **オートエンコーダの基本**

- データ圧縮と再構成: データの重要な特徴を保持し、効率的に再構成。
- 教師なし学習の一種: ラベルなしで特徴抽出を行う。


- **オートエンコーダの機能**

- ノイズ除去: データからノイズを削減し、元のパターンに近づける。
- データ生成: ランダムな潜在表現から新しいデータを作成可能。

- **応用例:** ノイズ除去、異常検知、情報検索、画像生成。

- **オートエンコーダの種類:** 通常型、変分(VAE)、積層型、畳み込み型。

分類の応用例




物体検知、セグメンテーションなどの画像認識

機械学習における分類


分類：データを，あらかじめ分かっている種類
(例：自動車，人間，自転車) に分類すること

主要プロセス① 訓練データからのモデル構築

訓練データ



構築されたモデル



分類や予測の応用分野



人工知能による**分類や予測の応用分野**は**多岐にわたる**

- **画像認識と画像理解**

道路標識の認識や顔認識、物体検出、画像セグメンテーションなど。自動運転技術や監視カメラの映像解析などに応用。

- **自然言語処理**

要約、校正、質問応答、翻訳、音声認識、音声合成、感情分析、文書分類、アイデア出しなど。

- **バイオインフォマティクス**

遺伝子解析やタンパク質構造の予測、薬剤の設計など。

- **金融と経済予測**

市場のトレンド分析やリスク評価、予測モデルの構築、意思決定のサポートなど。

- **医療診断と予測**


疾患の診断や予測、画像診断（MRIやCTスキャン）、病気の予後予測、薬物副作用の予測など。

4-5 線形近似（学習の例）

線形近似




- 線形近似は、データを直線で近似する手法
- データ点が多いほど、より正確な近似結果
- 線形近似はデータの特徴を捉える一種の学習手法としても考えることができる



散布図 + 線形近似

Excel での線形近似

年次	出生数 (千人)	死亡数 (千人)
1985	1432	752
1990	1222	820
1995	1187	922
2000	1191	962
2005	1063	1084
2010	1071	1197



散布図＋線形近似


入力

出力

出生数，死亡数の推移

出典：総務省「第63回 日本統計年鑑 平成26年」

線形近似の例



線形近似とは、データの分布を近似した補助線


Excel での散布図 + 線形近似の作成手順 (1 / 3)

	A	B	C
1	年次	出生数	死亡数
2	1985	1432	752
3	1990	1222	820
4	1995	1187	922
5	2000	1191	962
6	2005	1063	1084
7	2010	1071	1197


元データ

	A	B	C
1	年次	出生数	死亡数
2	1985	1432	752
3	1990	1222	820
4	1995	1187	922
5	2000	1191	962
6	2005	1063	1084
7	2010	1071	1197

① データ部分を範囲選択




② リボンで「挿入」→散布図の選択




③ 散布図を確認




Excel での散布図 + 線形近似の作成手順 (2 / 3)




④ グラフメニューを出す



⑤ 「+」のボタンをクリックしたのちに、「近似曲線」をクリック




⑥ 「系列1」をクリックして「OK」




⑦ 補助線が1つ出るので確認




Excel での散布図 + 線形近似の作成手順 (3 / 3)




⑧ もう1度、グラフメニューを出し、近似曲線の右横の「▶」を展開



⑨ 「線形」を選ぶ



⑩ 「系列2」をクリックして「OK」



完成

4-6 最適化

- **最適化**は、与えられた問題に対して**最適な解を求めるプロセス**
- 最適化は、**パラメータや変数の値などを調整**して、目的関数（ゴールともいう）と呼ばれるものを**最小化または最大化**する

ゴールの例： 誤差の最小化

パラメータの例： 直線の上下の位置と、
直線の傾き

最適化により方程式を解く



- 次の式の値が最小になるように, $\mathbf{x}$ の値を定めたい. 但し, $N = 5$ とする.

$$f(\mathbf{x}) = \sum_{i=2}^N 100(x_{i+1} - x_i^2)^2 + (1 - x_i)^2.$$

- <https://docs.scipy.org/doc/scipy/reference/tutorial/optimize.html>

① 最適化により方程式を解く Python プログラム



```
import numpy as np
```

```
from scipy.optimize import minimize
```

```
def rosen(x):
```

```
    """The Rosenbrock function"""
```

```
    return sum(100.0*(x[1:]-x[:-1]**2.0)**2.0 + (1-x[:-1])**2.0)
```

```
x0 = np.array([1.3, 0.7, 0.8, 1.9, 1.2])
```

```
res = minimize(rosen, x0, method='nelder-mead',
```

```
    options={'xtol': 1e-8, 'disp': True})
```

```
print(res.x)
```

① 最適化により方程式を解く Python プログラム



```
import numpy as np
from scipy.optimize import minimize
def rosen(x):
    """The Rosenbrock function"""
    return sum(100.0*(x[1:]-x[:-1]**2.0)**2.0 + (1-x[:-1])**2.0)

x0 = np.array([1.3, 0.7, 0.8, 1.9, 1.2])
res = minimize(rosen, x0, method='nelder-mead',
               options={'xtol': 1e-8, 'disp': True})
print(res.x)
```


```
↳ Optimization terminated successfully.
      Current function value: 0.000000
      Iterations: 339
      Function evaluations: 571
[1.  1.  1.  1.  1.]
```

$x = [1 \ 1 \ 1 \ 1 \ 1]$ のとき（すべての値が 1 のとき）
最適であると求まった。

線形近似では最適化が行われ、最適な直線の探索が行われる


- 線形近似は、**データを直線で近似**することを目指す
- **最適な直線**を探索するために、**最適化**の手法を使用
- 直線を適切に調整することで、**データに最もよくフィットする直線**を見つける

データの例




- 多数のデータの集まり
- 上の図では, 点1つで, 1つのデータ


直線による近似の例



最適でない近似
(誤差大)



最適な近似
(誤差小)




赤点：元データ


直線の上下移動による誤差の変化



誤差大



誤差小




赤点：元データ


直線の傾きの変化による誤差の変化



誤差大



誤差小







赤点：元データ

誤差の変化



- 直線の上下移動や，傾きの変化により，**誤差**が変化




最適化は機械学習でも重要



- ニューラルネットワークは、**学習**の過程で、**最適な状態**になるように**調整**される
- **最適化**は、**ニューラルネットワークの学習**で、**重要な役割**を果たす
- **ニューラルネットワーク**のパラメータ（**重み**や**バイアス**）を**最適化**することで、**性能を向上**させる

全体まとめ ①機械学習

- **機械学習**は、**コンピュータ**が**データ**を使用して**学習**することにより**知的能力を向上**させる技術
- 情報の抽出能力，ルールや知識のプログラム化不要などの**特徴**を持つ
- 他の方法では**解決が難しかった問題に取り組むことが可能**に



全体まとめ ②ニューラルネットワーク



- ニューラルネットワークは、**機械学習**の一種
- 生物の脳の働きを模倣することを目指す
- **数理に基づいた原理**に基づいて動作
- ニューラルネットワークは**機械学習**に広く活用されており、**性能や学習の効率が向上**している

