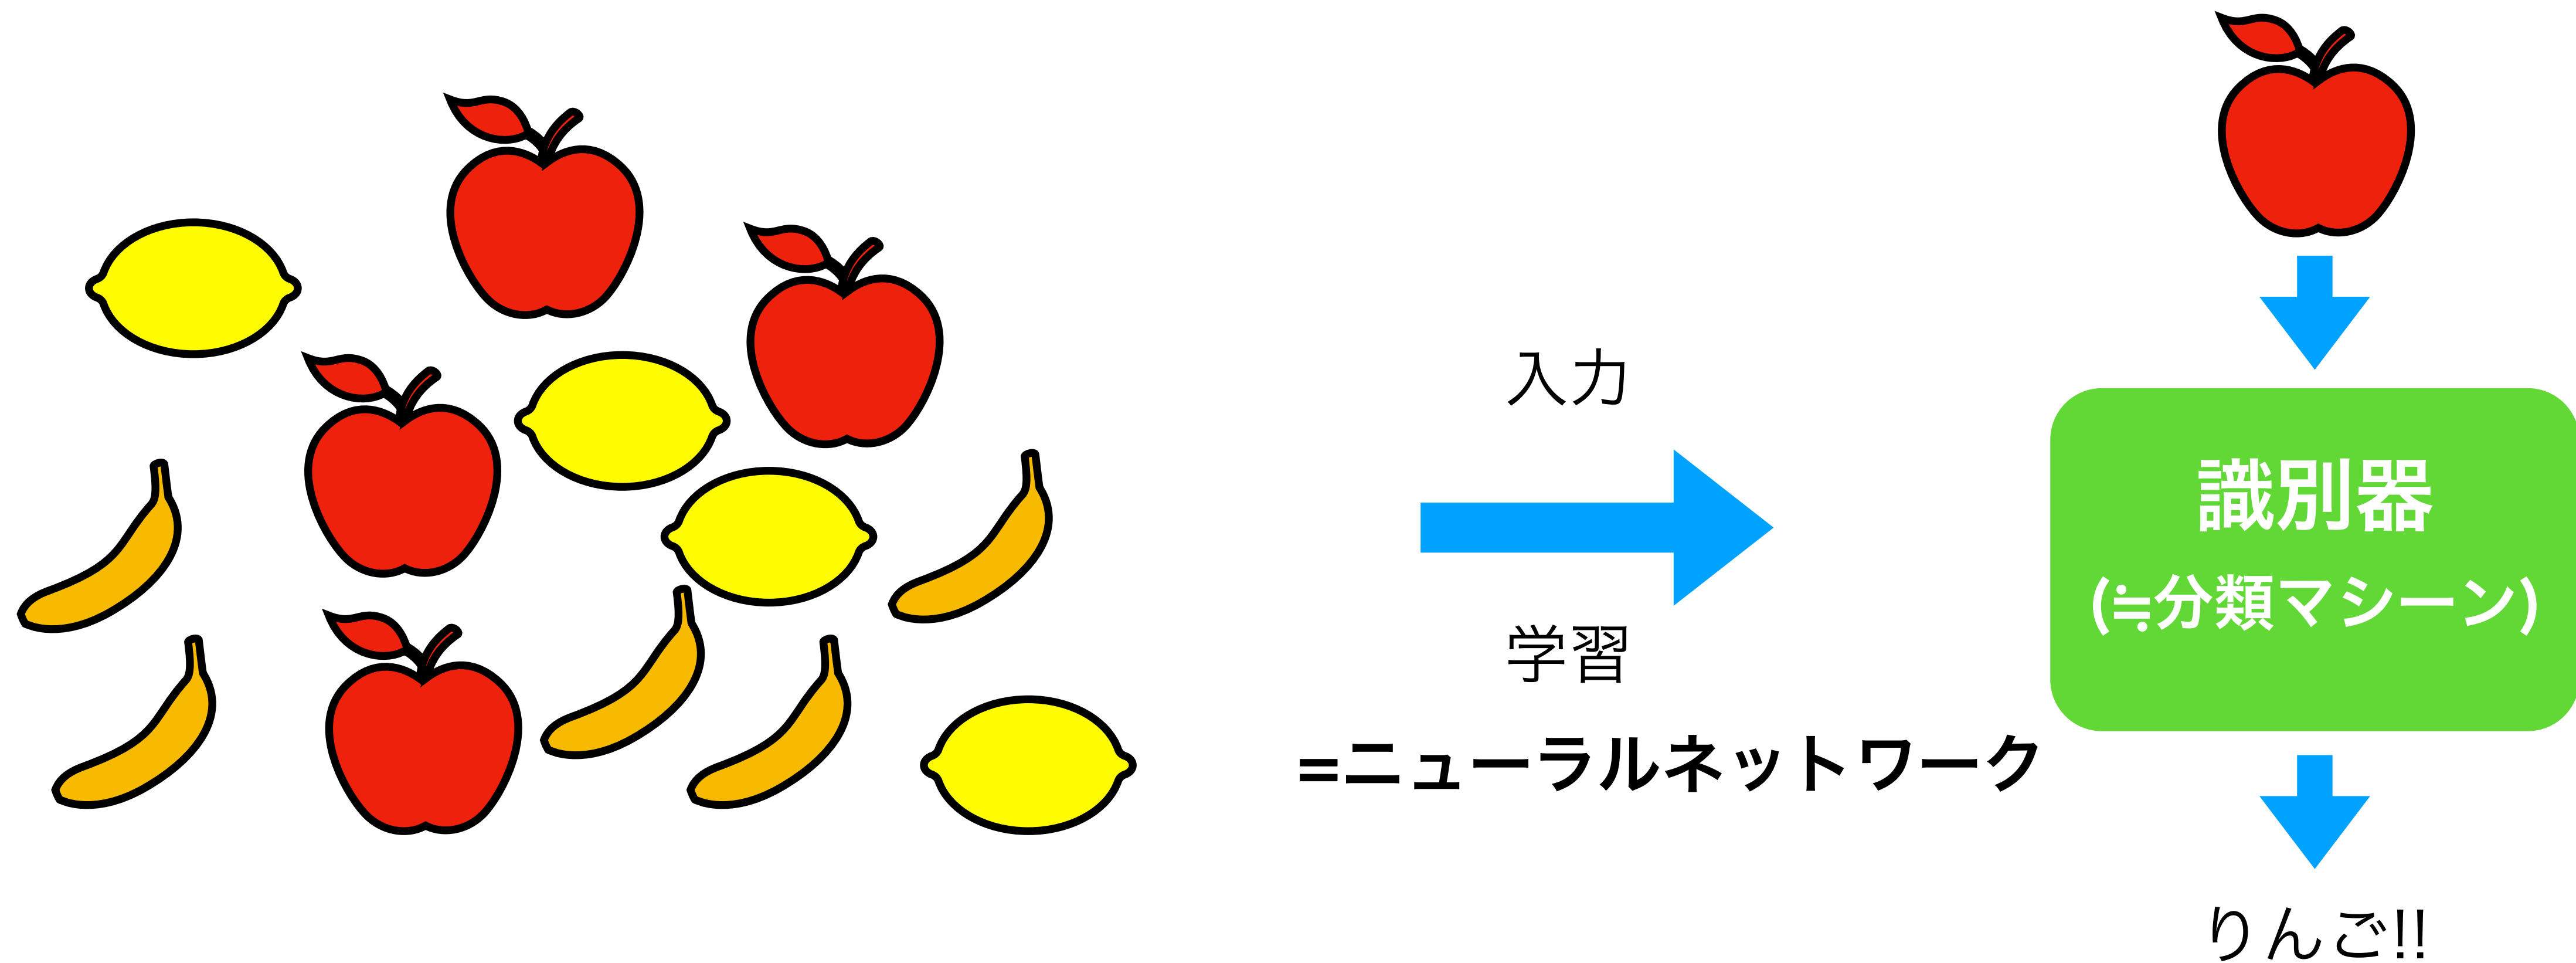


深層学習にふれてみよう

統合教育機構
須藤 毅頭

深層学習を実践してみよう！！

基本的な全体の流れは前回の機械学習と同様



深層学習では、学習モデルにニューラルネットワークを用いる

深層学習の流れ

学習モデルの選定

x(特徴量データ)

y(正解データ)

x_train

y_train

学習

=ニューラル
ネットワーク

学習済み
モデル

学習済み
モデル


正解の予測

正解との比較・評価

x_test

y_test


ニューラルネットワークとは(軽く復習)



○が全てニューロン、繋がった線の数だけ数式(関数)が存在する。

使いたい変数の数を入力層のニューロンの数、出したい答えの数を出力層のニューロンの数にする

ニューラルネットワークとは(軽く復習)



○が全てニューロン、繋がった線の数だけ数式(関数)が存在する。

使いたい変数の数を入力層のニューロンの数、出したい答えの数を出力層のニューロンの数にする

アヤメのデータでの深層学習の実践

あやめのデータ



Iris Versicolor

ブルーフラッグ

Iris Setosa


ヒオウギアヤメ

変数4つ

がく片の長さ
がく片の幅
花びらの長さ
花びらの幅

あやめのデータは100個、正解が2種類

ニューラルネットワーク

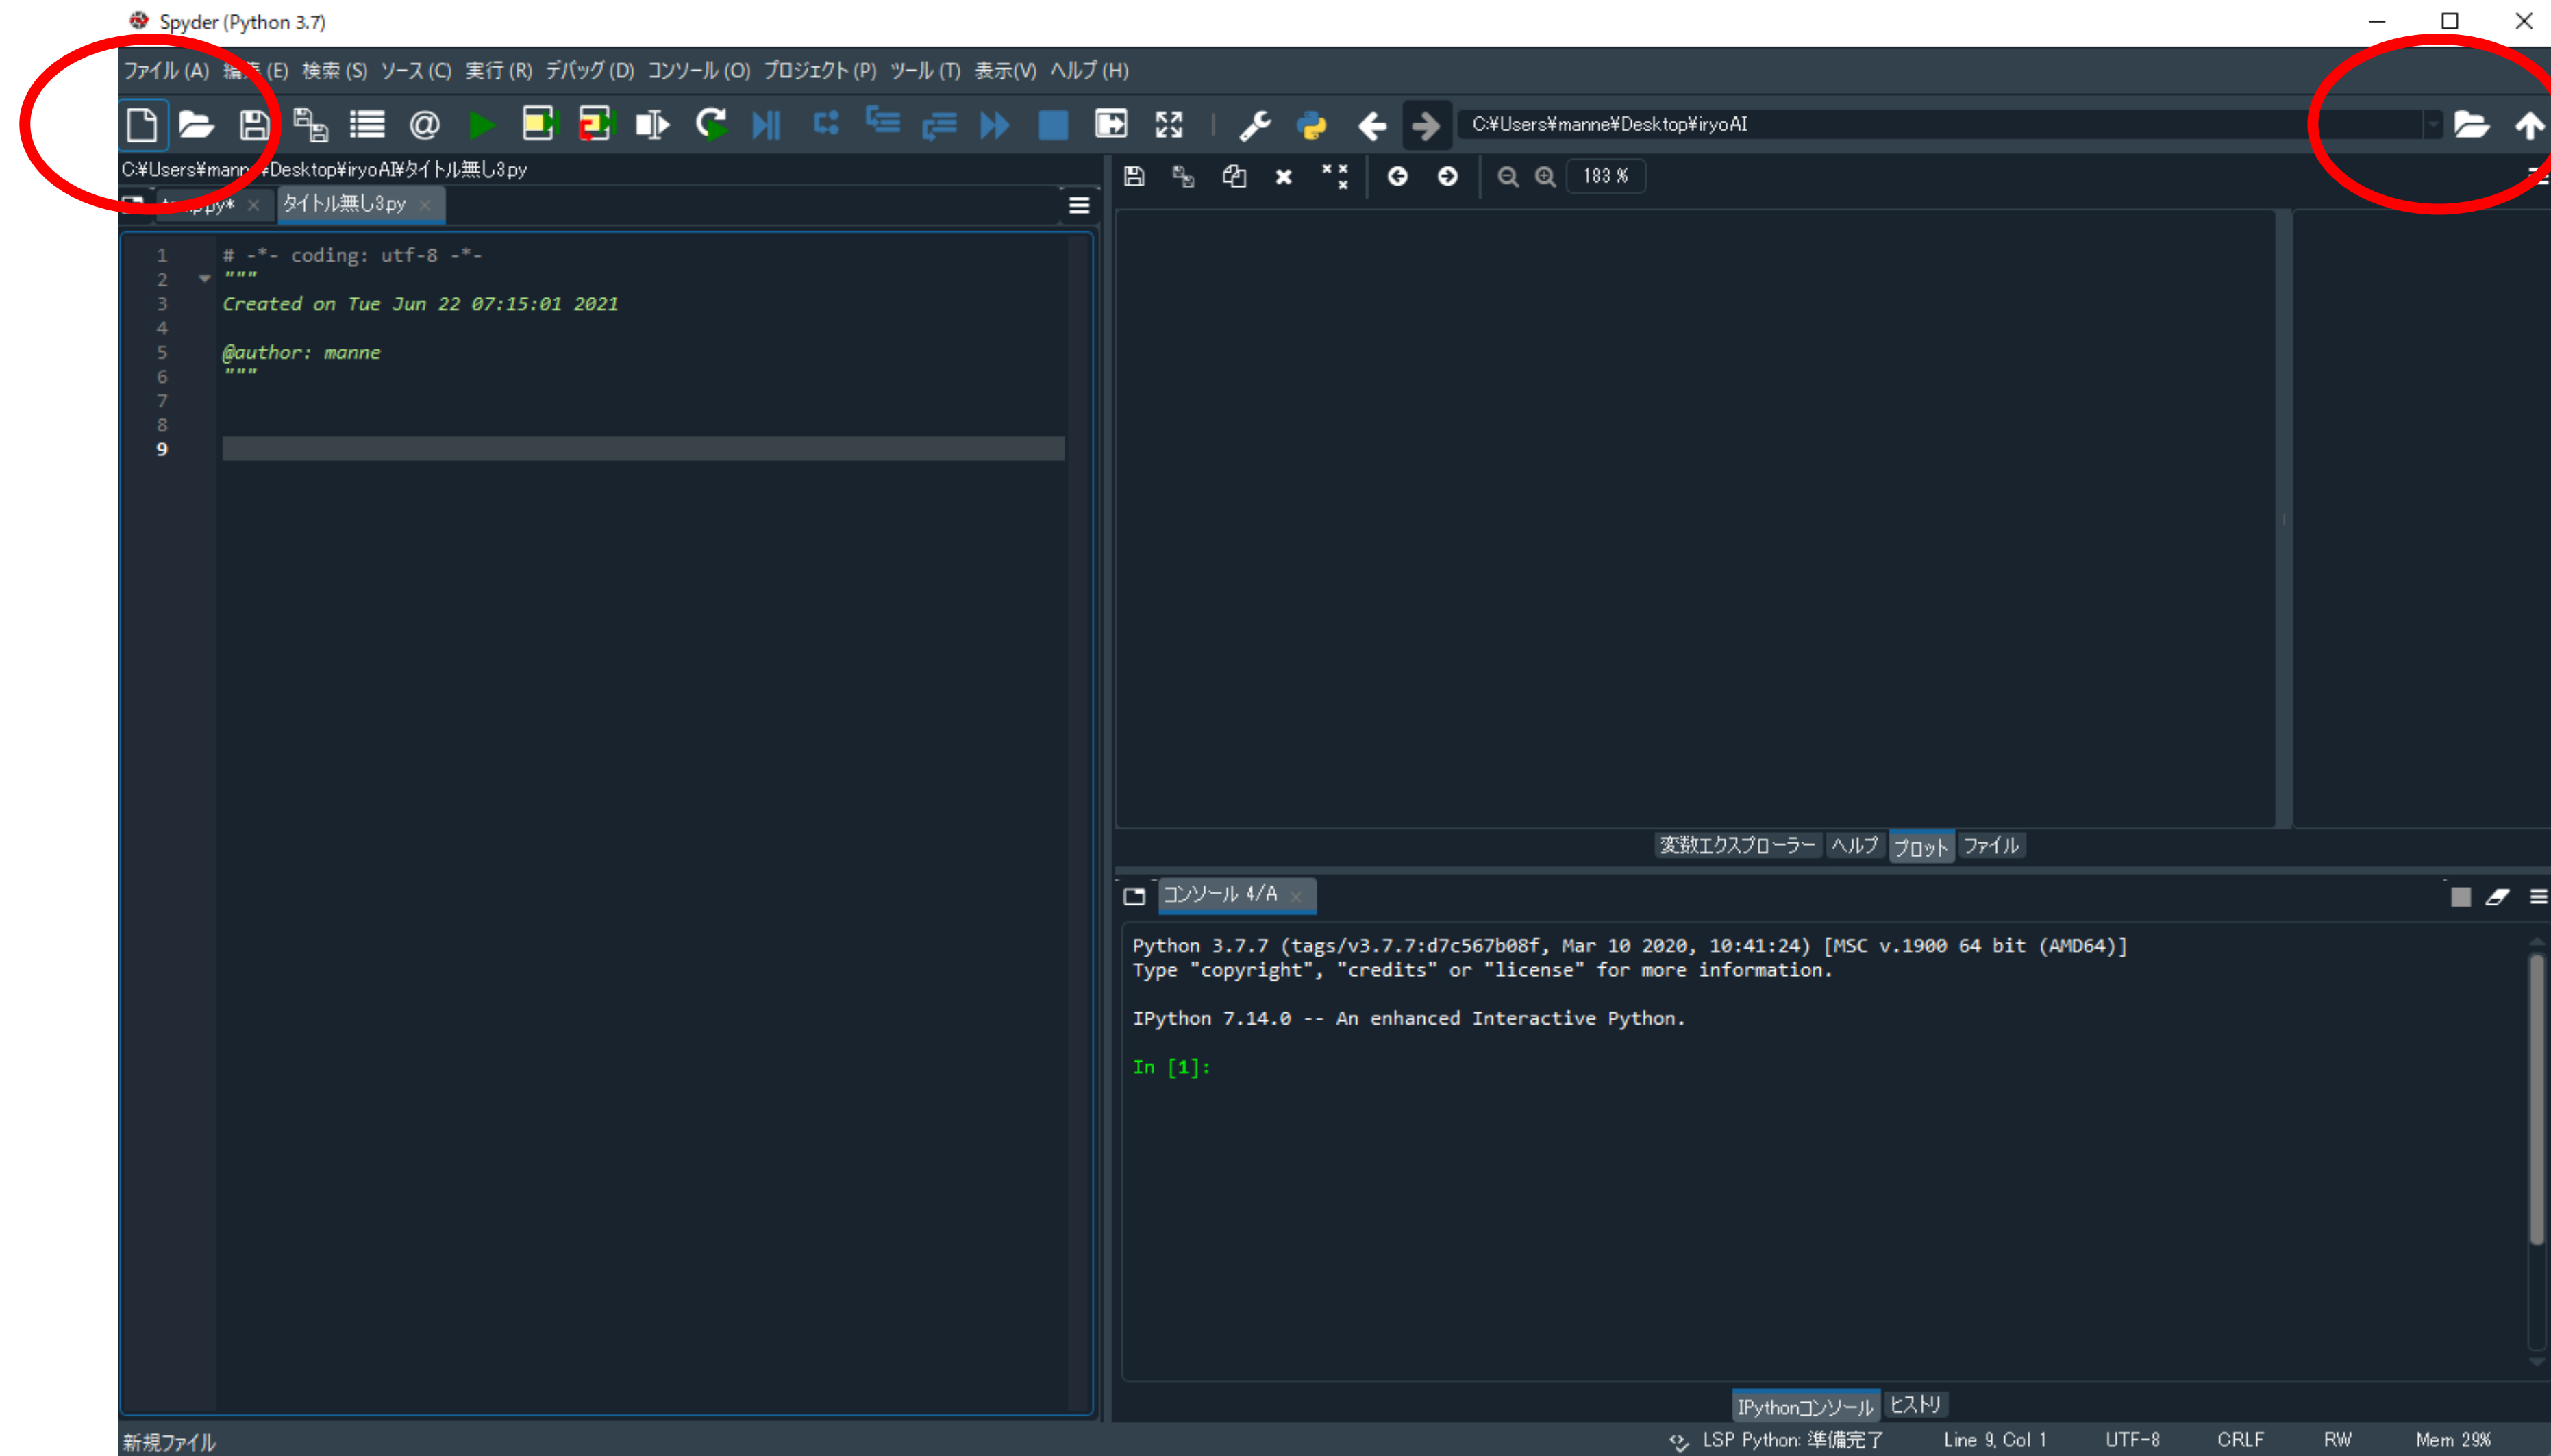


分類

ヒオウギアヤメorブルーフラッグ

まず演習の準備をしましょう

- ・新規ファイル作成→**iryoiAI**のディレクトリで”**enshu4.py**”
- ・作業場所を**iryoiAI**に設定



ライブラリのインストールとデータの読み込み・加工

4.txtの "1)アイリスデータを読み込む"の前半部分をコピーする

```
# 前半部分
```

```
import pandas as pd
import matplotlib.pyplot as plt
from matplotlib import rcParams
Params['font.family']='sans-serif'
rcParams['font.sans-serif'] = ['Hiragino Maru Gothic Pro', 'Yu Gothic', 'Meirio']
```

```
from tensorflow.python.keras.models import Sequential
from tensorflow.python.keras.layers import Dense
```

```
import osos.environ['KMP_DUPLICATE_LIB_OK']='True'
```

```
# 後半部分
```

```
iris_train2 = pd.read_csv('4-1.csv')
print(iris_train2)
iris_train = pd.read_csv('4-1.csv').to_numpy()
print(iris_train)
x_train = iris_train[:, 0:4].astype('float')
y_train = iris_train[:, 4:5].astype('int')
iris_test = pd.read_csv('4-2.csv').to_numpy()
x_test = iris_test[:, 0:4].astype('float')
y_test = iris_test[:, 4:5].astype('int')
```

ライブラリのインストールとデータの読み込み・加工

4.txtの”1)アイリスデータを読み込む”の前半部分

```
# 1)アイリスデータを読み込む
# 必要なライブラリのインポート
import pandas as pd
import matplotlib.pyplot as plt
from matplotlib import rcParams
rcParams['font.family']='sans-serif'
rcParams['font.sans-serif']=['Hiragino Maru Gothic Pro', 'Yu Gothic', 'Meirio']

# 深層学習用のライブラリを取り込む
from tensorflow.python.keras.models import Sequential
from tensorflow.python.keras.layers import Dense

# 以下のコード2行は本来必要ないが、anacondaでのOMP Abort エラーを防ぐために入れた
import os
os.environ['KMP_DUPLICATE_LIB_OK']='True'
```

tensorflowおよびkerasという深層学習ライブラリを使用

ライブラリのインストールとデータの読み込み・加工

4.txtの "1)アイリスデータを読み込む"の後半部分をコピーする

```
# 前半部分
```

```
import pandas as pd
import matplotlib.pyplot as plt
from matplotlib import rcParams
Params['font.family']='sans-serif'
rcParams['font.sans-serif'] = ['Hiragino Maru Gothic Pro', 'Yu Gothic', 'Meirio']
```

```
from tensorflow.python.keras.models import Sequential
from tensorflow.python.keras.layers import Dense
```

```
import osos.environ['KMP_DUPLICATE_LIB_OK']='True'
```

```
# 後半部分
```

```
iris_train2 = pd.read_csv('4-1.csv')
print(iris_train2)
iris_train = pd.read_csv('4-1.csv').to_numpy()
print(iris_train)
x_train = iris_train[:, 0:4].astype('float')
y_train = iris_train[:, 4:5].astype('int')
iris_test = pd.read_csv('4-2.csv').to_numpy()
x_test = iris_test[:, 0:4].astype('float')
y_test = iris_test[:, 4:5].astype('int')
```

ライブラリのインストールとデータの読み込み・加工

今回は学習用(4-1.csv)と検証用データ(4-2.csv)に分けて準備しています。
順に読み込んで、特徴量(説明変数)と正解データ(目的変数)に分けます。

4-1.CSV

	A	B	C	D	E	F
1	がく片の長さ	がく片の幅	花びらの長さ	花びらの幅	教師データ	アヤメの種類
2	5.1	3.5	1.4	0.2	0	ヒオウギアヤメ
3	4.9	3	1.4	0.2	0	ヒオウギアヤメ
4	4.7	3.2	1.3	0.2	0	ヒオウギアヤメ
5	4.6	3.1	1.5	0.2	0	ヒオウギアヤメ
6	5	3.6	1.4	0.2	0	ヒオウギアヤメ
7	5.4	3.9	1.7	0.4	0	ヒオウギアヤメ
8	4.6	3.4	1.4	0.3	0	ヒオウギアヤメ
9	5	3.4	1.5	0.2	0	ヒオウギアヤメ
10	4.4	2.9	1.4	0.2	0	ヒオウギアヤメ
11	4.9	3.1	1.5	0.1	0	ヒオウギアヤメ
12	5.4	3.7	1.5	0.2	0	ヒオウギアヤメ
13	4.8	3.4	1.6	0.2	0	ヒオウギアヤメ
14	4.8	3	1.4	0.1	0	ヒオウギアヤメ
15	4.3	3	1.1	0.1	0	ヒオウギアヤメ
16	5.8	4	1.2	0.2	0	ヒオウギアヤメ
17	5.7	4.4	1.5	0.4	0	ヒオウギアヤメ
18	5.4	3.9	1.3	0.4	0	ヒオウギアヤメ

4-2.CSV

	A	B	C	D	E	F
1	がく片の長さ	がく片の幅	花びらの長さ	花びらの幅	教師データ	アヤメの種類
2	5	3.5	1.3	0.3	0	ヒオウギアヤメ
3	4.5	2.3	1.3	0.3	0	ヒオウギアヤメ
4	4.4	3.2	1.3	0.2	0	ヒオウギアヤメ
5	5	3.5	1.6	0.6	0	ヒオウギアヤメ
6	5.1	3.8	1.9	0.4	0	ヒオウギアヤメ
7	4.8	3	1.4	0.3	0	ヒオウギアヤメ
8	5.1	3.8	1.6	0.2	0	ヒオウギアヤメ
9	4.6	3.2	1.4	0.2	0	ヒオウギアヤメ
10	5.3	3.7	1.5	0.2	0	ヒオウギアヤメ
11	5	3.3	1.4	0.2	0	ヒオウギアヤメ
12	5.5	2.6	4.4	1.2	1	ブルーフラッグ
13	6.1	3	4.6	1.4	1	ブルーフラッグ
14	5.8	2.6	4	1.2	1	ブルーフラッグ
15	5	2.3	3.3	1	1	ブルーフラッグ
16	5.6	2.7	4.2	1.3	1	ブルーフラッグ

学習用データが80行、検証用データが20行
アヤメの種類をヒオウギアヤメが0、ブルーフラッグが1と数値化している

ライブラリのインストールとデータの読み込み・加工(1の後半部分)

```
iris_train = pd.read_csv('4-1.csv').to_numpy()
```

```
pd.read_csv('csvファイル').to_numpy()
```


→pandasのデータフレームをnumpy配列に変換する

```
iris_train2 = pd.read_csv('4-1.csv')  
print(iris_train2)
```

```
iris_train = pd.read_csv('4-1.csv').to_numpy()  
print(iris_train)
```

	がく片の長さ	がく片の幅	花びらの長さ	花びらの幅	教師データ	アヤメの種類
0	5.1	3.5	1.4	0.2	0	ヒオウギアヤメ
1	4.9	3.0	1.4	0.2	0	ヒオウギアヤメ
2	4.7	3.2	1.3	0.2	0	ヒオウギアヤメ
3	4.6	3.1	1.5	0.2	0	ヒオウギアヤメ
4	5.0	3.6	1.4	0.2	0	ヒオウギアヤメ
...
75	6.0	3.4	4.5	1.6	1	ブルーフラッグ
76	6.7	3.1	4.7	1.5	1	ブルーフラッグ
77	6.3	2.3	4.4	1.3	1	ブルーフラッグ
78	5.6	3.0	4.1	1.3	1	ブルーフラッグ
79	5.5	2.5	4.0	1.3	1	ブルーフラッグ

[80 rows x 6 columns]



```
[[5.1 3.5 1.4 0.2 0 'ヒオウギアヤメ']  
 [4.9 3.0 1.4 0.2 0 'ヒオウギアヤメ']  
 [4.7 3.2 1.3 0.2 0 'ヒオウギアヤメ']  
 [4.6 3.1 1.5 0.2 0 'ヒオウギアヤメ']  
 [5.0 3.6 1.4 0.2 0 'ヒオウギアヤメ']  
 [5.4 3.9 1.7 0.4 0 'ヒオウギアヤメ']  
 [4.6 3.4 1.4 0.3 0 'ヒオウギアヤメ']  
 [5.0 3.4 1.5 0.2 0 'ヒオウギアヤメ']  
 [4.4 2.9 1.4 0.2 0 'ヒオウギアヤメ']  
 [4.9 3.1 1.5 0.1 0 'ヒオウギアヤメ']  
 [5.4 3.7 1.5 0.2 0 'ヒオウギアヤメ']  
 [4.8 3.4 1.6 0.2 0 'ヒオウギアヤメ']  
 [4.8 3.0 1.4 0.1 0 'ヒオウギアヤメ']
```

numpy配列の2次元配列

ライブラリのインストールとデータの読み込み・加工(1の後半部分)

```
iris_train = pd.read_csv('4-1.csv').to_numpy()
```


```
pd.read_csv('csvファイル').to_numpy()
```

→pandasのデータフレームをnumpy配列に変換する

```
iris_train2 = pd.read_csv('4-1.csv')  
print(iris_train2)
```

```
iris_train = pd.read_csv('4-1.csv').to_numpy()  
print(iris_train)
```

```
iris_train2  DataFrame      (80, 6)  Column names: がく片の長さ, がく片の幅, 花びらの長さ, 花びらの幅, 教師データ, アヤメの種類
```



```
iris_train  Array of object  (80, 6)  ndarray object of numpy module
```

ライブラリのインストールとデータの読み込み・加工(1の後半部分)

```
x_train = iris_train[:, 0:4]  
y_train = iris_train[:, 4:5]
```

特定の行、列を抜き出す

(numpy配列)[○○:○○, ○○:○○]

(numpy配列)[行の始まり:行の終わり(-1) , 列の始まり:列の終わり(-1)]

1列目は0から数えるので、0:4は1列目から4列目になります。

“:”だけで数字がない場合は全ての行もしくは列を意味します

ライブラリのインストールとデータの読み込み・加工(1の後半部分)

例)

```
data =  
np.array([[1,2,3],[4,5,6],[7,8,9]])  
print(data)
```

```
      0 1 2  
0 [[1 2 3]  
1  [4 5 6]  
2  [7 8 9]]
```

3 × 3の二次元配列を作成

```
x = data[0:2,0:2]  
print(x)
```

```
      0 1  
0 [[1 2]  
1  [4 5]]
```

1次元目(=行)も2次元目(=列)も"0:2"なので
0番目から1番目の行と列を取り出す

```
x2 = data[1:3,1:2]  
print(x2)
```

```
      1  
1 [[5]  
2  [8]]
```

行が1番目から2番目まで、
列が1番目から1番目までを取り出す

```
x3 = data[1:2,:]  
print(x3)
```

```
      0 1 2  
1 [[4 5 6]]
```

行が1番目から1番目まで、
列は全ての列を取り出す


ライブラリのインストールとデータの読み込み・加工(1の後半部分)

```
x_train = iris_train[:, 0:4]
y_train = iris_train[:, 4:5]
```

全ての行と1列目から4列目

全ての行と5列目から5列目

	0	1	2	3	4	5
0	5.1	3.5	1.4	0.2	0	'ヒオウギアヤメ'
1	4.9	3.0	1.4	0.2	0	'ヒオウギアヤメ'
2	4.7	3.2	1.3	0.2	0	'ヒオウギアヤメ'
3	4.6	3.1	1.5	0.2	0	'ヒオウギアヤメ'
4	5.0	3.6	1.4	0.2	0	'ヒオウギアヤメ'
5	5.4	3.9	1.7	0.4	0	'ヒオウギアヤメ'
⋮						
⋮						
⋮						
	4.6	3.4	1.4	0.3	0	'ヒオウギアヤメ'
	5.0	3.4	1.5	0.2	0	'ヒオウギアヤメ'
	4.4	2.9	1.4	0.2	0	'ヒオウギアヤメ'
	4.9	3.1	1.5	0.1	0	'ヒオウギアヤメ'
	5.4	3.7	1.5	0.2	0	'ヒオウギアヤメ'
	4.8	3.4	1.6	0.2	0	'ヒオウギアヤメ'
	4.8	3.0	1.4	0.1	0	'ヒオウギアヤメ'



5.1	3.5	1.4	0.2
4.9	3.0	1.4	0.2
4.7	3.2	1.3	0.2
4.6	3.1	1.5	0.2
5.0	3.6	1.4	0.2
5.4	3.9	1.7	0.4
4.6	3.4	1.4	0.3
5.0	3.4	1.5	0.2
4.4	2.9	1.4	0.2
4.9	3.1	1.5	0.1
5.4	3.7	1.5	0.2
4.8	3.4	1.6	0.2
4.8	3.0	1.4	0.1

0
0
0
0
0
0
0
0
0
0
0
0
0
0
0

iris_train(学習用の説明変数+目的変数)

x_train(学習用の説明変数)

y_train(学習用の目的変数)

ライブラリのインストールとデータの読み込み・加工(1の後半部分)

```
x_train = iris_train[:, 0:4].astype('float')
y_train = iris_train[:, 4:5].astype('int')
```


numpy配列.astype('型')

→配列の型を指定する

.astype('float')は中身を小数、.astype('int')は中身を整数に指定する指示です

print(iris_train)

```
[[5.1 3.5 1.4 0.2 0 'ヒオウギアヤメ']
 [4.9 3.0 1.4 0.2 0 'ヒオウギアヤメ']
 [4.7 3.2 1.3 0.2 0 'ヒオウギアヤメ']
 [4.6 3.1 1.5 0.2 0 'ヒオウギアヤメ']
 [5.0 3.6 1.4 0.2 0 'ヒオウギアヤメ']
 [5.4 3.9 1.7 0.4 0 'ヒオウギアヤメ']
 [4.6 3.4 1.4 0.3 0 'ヒオウギアヤメ']
 [5.0 3.4 1.5 0.2 0 'ヒオウギアヤメ']
 [4.4 2.9 1.4 0.2 0 'ヒオウギアヤメ']
 [4.9 3.1 1.5 0.1 0 'ヒオウギアヤメ']
 [5.4 3.7 1.5 0.2 0 'ヒオウギアヤメ']
 [4.8 3.4 1.6 0.2 0 'ヒオウギアヤメ']
 [4.8 3.0 1.4 0.1 0 'ヒオウギアヤメ']]
```



print(x_train)

```
[[5.1 3.5 1.4 0.2]
 [4.9 3.  1.4 0.2]
 [4.7 3.2 1.3 0.2]
 [4.6 3.1 1.5 0.2]
 [5.  3.6 1.4 0.2]
 [5.4 3.9 1.7 0.4]
 [4.6 3.4 1.4 0.3]
 [5.  3.4 1.5 0.2]
 [4.4 2.9 1.4 0.2]
 [4.9 3.1 1.5 0.1]
 [5.4 3.7 1.5 0.2]
 [4.8 3.4 1.6 0.2]
 [4.8 3.  1.4 0.1]]
```

データに小数も含まれている

print(y_train)

```
[[0]
 [0]
 [0]
 [0]
 [0]
 [0]
 [0]
 [0]
 [0]
 [0]
 [0]
 [0]
 [0]]
```


データは全て整数

ライブラリのインストールとデータの読み込み・加工(1の後半部分)

```
x_train = iris_train[:, 0:4].astype('float')
y_train = iris_train[:, 4:5].astype('int')
```

astype()がない場合

iris_train	Array of object	(80, 6)	ndarray object of numpy module
x_train	Array of object	(80, 4)	ndarray object of numpy module
y_train	Array of object	(80, 1)	ndarray object of numpy module



astype()がある場合

iris_train	Array of object	(80, 6)	ndarray object of numpy module
x_train	Array of float64	(80, 4)	<pre>[[5.1 3.5 1.4 0.2] [4.9 3. 1.4 0.2]</pre>
y_train	Array of int32	(80, 1)	<pre>[[0] [0]</pre>

加工したデータの確認

“2) 加工したデータの確認”を実行して中身を見てみよう

```
# 2) 加工したデータの確認
print(iris_train)
print(x_train)
print(y_train)
print(iris_test)
print(x_test)
print(y_test)
print(x_train.shape)
print(y_train.shape)
print(x_test.shape)
print(y_test.shape)
```

全て 2 次元配列

```
In [7]: print(x_test)
[[5.  3.5 1.3 0.3]
 [4.5 2.3 1.3 0.3]
 [4.4 3.2 1.3 0.2]
 [5.  3.5 1.6 0.6]
 [5.1 3.8 1.9 0.4]
 [4.8 3.  1.4 0.3]
 [5.1 3.8 1.6 0.2]
 [4.6 3.2 1.4 0.2]
 [5.3 3.7 1.5 0.2]
 [5.  3.3 1.4 0.2]
 [5.5 2.6 4.4 1.2]
 [6.1 3.  4.6 1.4]
 [5.8 2.6 4.  1.2]
 [5.  2.3 3.3 1. ]
 [5.6 2.7 4.2 1.3]
 [5.7 3.  4.2 1.2]
 [5.7 2.9 4.2 1.3]
 [6.2 2.9 4.3 1.3]
 [5.1 2.5 3.  1.1]
 [5.7 2.8 4.1 1.3]]
```

```
In [8]: print(y_test)
[[0]
 [0]
 [0]
 [0]
 [0]
 [0]
 [0]
 [0]
 [0]
 [0]
 [1]
 [1]
 [1]
 [1]
 [1]
 [1]
 [1]
 [1]
 [1]
 [1]]
```

```
In [9]: print(x_train.shape)
(80, 4)
```

```
In [10]: print(y_train.shape)
(80, 1)
```

```
In [11]: print(x_test.shape)
(20, 4)
```

```
In [12]: print(y_test.shape)
(20, 1)
```

学習用データは80行 4 列
検証用データは20行 1 列

加工したデータの確認

名前 ▲	型	サイズ	値
iris_test	Array of object	(20, 6)	ndarray object of numpy module
iris_train	Array of object	(80, 6)	ndarray object of numpy module
x_test	Array of float64	(20, 4)	[[5. 3.5 1.3 0.3] [4.5 2.3 1.3 0.3]
x_train	Array of float64	(80, 4)	[[5.1 3.5 1.4 0.2] [4.9 3. 1.4 0.2]
y_test	Array of int32	(20, 1)	[[0] [0]
y_train	Array of int32	(80, 1)	[[0] [0]


x_train - NumPy オブジェクト配列

	0	1	2	3
0	5.1	3.5	1.4	0.2
1	4.9	3	1.4	0.2
2	4.7	3.2	1.3	0.2
3	4.6	3.1	1.5	0.2
4	5	3.6	1.4	0.2


y_train - NumPy オブジェクト配列

	0
0	0
1	0
2	0
3	0
4	0

3) 学習モデルの作成(ニューラルネットワーク)



今回作成する学習モデル



今回はシンプルなネットワークにするため、出力層は1つにしています。
(2値分類の場合、最後に出る値を確率 p が出ると自動的にもう1つの確率は $1-p$ になります。)

3) 学習モデルの作成(ニューラルネットワーク)

ニューラルネットワークを作成していく

モデル名 = Sequential()

ニューラルネットワークを作るモデルも沢山ある中で、
今回はKeras(ケラス)のSequentialモデルを使用します


```
dl_model = Sequential()  
dl_model.add(Dense(4, activation='relu', input_shape=(4,)))  
dl_model.add(Dense(4, activation='relu'))  
dl_model.add(Dense(4, activation='relu'))  
dl_model.add(Dense(1, activation='sigmoid'))  
dl_model.compile(loss='binary_crossentropy', optimizer='Adam', metrics=["accuracy"])  
dl_model.summary()
```

今回はモデル名を”dl_model”とする

3) 学習モデルの作成(ニューラルネットワーク)

モデル名.add()で層の追加を行う



Denseは全ての入力が全てのニューロンと結合している状態(=全結合層という)



```
dl_model = Sequential()  
dl_model.add(Dense(4, activation='relu', input_shape=(4,)))  
dl_model.add(Dense(4, activation='relu'))  
dl_model.add(Dense(4, activation='relu'))  
dl_model.add(Dense(1, activation='sigmoid'))  
dl_model.compile(loss='binary_crossentropy', optimizer='Adam', metrics=["accuracy"])  
dl_model.summary()
```

3) 学習モデルの作成(ニューラルネットワーク)

`model.add(Dense(出力の変数の数, activation='活性化関数', input_shape=(入力の変数の数,)))`




入力の変数4つ、出力の変数4つ
活性化関数はReLUを選択(全結合層)

(入力の4つの変数は、がく片の
長さ、幅、花びらの長さ、幅)

```
dl_model = Sequential()  
dl_model.add(Dense(4, activation='relu', input_shape=(4,)))  
dl_model.add(Dense(4, activation='relu'))  
dl_model.add(Dense(4, activation='relu'))  
dl_model.add(Dense(1, activation='sigmoid'))  
dl_model.compile(loss='binary_crossentropy', optimizer='Adam', metrics=["accuracy"])  
dl_model.summary()
```

3) 学習モデルの作成(ニューラルネットワーク)




`model.add()`でさらに層の追加

2回目以降は入力の変数はそのまま(4つ)、出力の変数4つ
ReLUという(活性化)関数を選択

```
dl_model = Sequential()  
dl_model.add(Dense(4, activation='relu', input_shape=(4,)))  
dl_model.add(Dense(4, activation='relu'))  
dl_model.add(Dense(1, activation='sigmoid'))  
dl_model.compile(loss='binary_crossentropy', optimizer='Adam', metrics=["accuracy"])  
dl_model.summary()
```


3) 学習モデルの作成(ニューラルネットワーク)




入力の変数はそのまま(4つ)、出力の変数4つ
ReLUという(活性化)関数を選択

```
dl_model = Sequential()
dl_model.add(Dense(4, activation='relu', input_shape=(4,)))
dl_model.add(Dense(4, activation='relu'))
dl_model.add(Dense(4, activation='relu'))
dl_model.add(Dense(1, activation='sigmoid'))
dl_model.compile(loss='binary_crossentropy', optimizer='Adam', metrics=["accuracy"])
dl_model.summary()
```

3) 学習モデルの作成(ニューラルネットワーク)



```
dl_model = Sequential()  
dl_model.add(Dense(4, activation='relu', input_shape=(4,)))  
dl_model.add(Dense(4, activation='relu'))  
dl_model.add(Dense(4, activation='relu'))  
dl_model.add(Dense(1, activation='sigmoid'))  
dl_model.compile(loss='binary_crossentropy', optimizer='Adam', metrics=["accuracy"])  
dl_model.summary()
```



出力の変数1つ
シグモイド(活性化)関数を選択


3) 学習モデルの作成(ニューラルネットワーク)

`model.compile()`で、学習時の評価方法の選択をする

`loss = “損失関数”, optimizer = ‘最適化関数’, metrics=[“評価指標”]`

今回は2クラス分類なので**binary_crossentropy**を選択
評価指標は正解率を示す**accuracy**を選択

```
dl_model = Sequential()  
dl_model.add(Dense(4, activation='relu', input_shape=(4,)))  
dl_model.add(Dense(4, activation='relu'))  
dl_model.add(Dense(4, activation='relu'))  
dl_model.add(Dense(1, activation='sigmoid'))  
dl_model.compile(loss='binary_crossentropy', optimizer='Adam', metrics=["accuracy"])  
dl_model.summary()
```



この誤差を0に近づけるように、
誤差逆伝播を行い各パラメーターを調整

(今回はAdamという最適化アルゴリズムを使用)

3) 学習モデルの作成(ニューラルネットワーク)

`dl_model.summary()`は、
作成した学習モデルを要約する

Model: "sequential"		
Layer (type)	Output Shape	Param #
dense (Dense)	(None, 4)	20
dense_1 (Dense)	(None, 4)	20
dense_2 (Dense)	(None, 4)	20
dense_3 (Dense)	(None, 1)	5
Total params: 65		
Trainable params: 65		
Non-trainable params: 0		

```
dl_model = Sequential()
dl_model.add(Dense(4, activation='relu', input_shape=(4,)))
dl_model.add(Dense(4, activation='relu'))
dl_model.add(Dense(4, activation='relu'))
dl_model.add(Dense(1, activation='sigmoid'))
dl_model.compile(loss='binary_crossentropy', optimizer='Adam', metrics=["accuracy"])
dl_model.summary()
```

3) 学習モデルの作成(ニューラルネットワーク)

“ 3)神経回路の作成をコピーして実行してみよう

```
# 3)神経回路の作成
dl_model = Sequential()
dl_model.add(Dense(4, activation='relu', input_shape=(4,)))
dl_model.add(Dense(4, activation='relu'))
dl_model.add(Dense(4, activation='relu'))
dl_model.add(Dense(1, activation='sigmoid'))
dl_model.compile(loss='binary_crossentropy', optimizer='Adam', metrics=["accuracy"])
dl_model.summary()
```

Layer (type)	Output Shape	Param #
dense (Dense)	(None, 4)	20
dense_1 (Dense)	(None, 4)	20
dense_2 (Dense)	(None, 4)	20
dense_3 (Dense)	(None, 1)	5

=====
Total params: 65
Trainable params: 65
Non-trainable params: 0
=====

4) 学習用データでの学習

```
history = dl_model.fit(x_train, y_train, epochs=300)
```

historyに学習過程を記録する。 300回学習させる

epochs

1エポックは1試行のことで、学習用データを1通り使って1エポックと数える
ここでは300回学習させている。

4) 学習用データでの学習

```
history = dl_model.fit(x_train, y_train, epochs=300)
```

historyに学習過程を記録する。 300回学習させる

epochs

1エポックは1試行のことで、学習用データを1通り使って1エポックと数える
ここでは300回学習させている。

```
80/80 [=====] - 0s 76us/sample - loss: 0.0231 - accuracy: 1.0000
Epoch 290/300
80/80 [=====] - 0s 69us/sample - loss: 0.0228 - accuracy: 1.0000
Epoch 291/300
80/80 [=====] - 0s 66us/sample - loss: 0.0225 - accuracy: 1.0000
Epoch 292/300
80/80 [=====] - 0s 66us/sample - loss: 0.0222 - accuracy: 1.0000
Epoch 293/300
80/80 [=====] - 0s 76us/sample - loss: 0.0219 - accuracy: 1.0000
Epoch 294/300
80/80 [=====] - 0s 66us/sample - loss: 0.0216 - accuracy: 1.0000
Epoch 295/300
80/80 [=====] - 0s 60us/sample - loss: 0.0214 - accuracy: 1.0000
Epoch 296/300
80/80 [=====] - 0s 64us/sample - loss: 0.0211 - accuracy: 1.0000
Epoch 297/300
80/80 [=====] - 0s 66us/sample - loss: 0.0208 - accuracy: 1.0000
Epoch 298/300
80/80 [=====] - 0s 74us/sample - loss: 0.0206 - accuracy: 1.0000
Epoch 299/300
80/80 [=====] - 0s 82us/sample - loss: 0.0203 - accuracy: 1.0000
Epoch 300/300
80/80 [=====] - 0s 90us/sample - loss: 0.0201 - accuracy: 1.0000
```

実行するとコンソール画面に学習過程が出力される
loss: 学習用データの誤差、0に近いほどよい
acc: 学習用データの正解率、1に近いほどよい

5) テスト用データでの検証

```
score = dl_model.evaluate(x_test, y_test)
print("Test loss:", score[0])
print("Test accuracy:", score[1])
```

(変数名) = dl_model.evaluate(x_test, y_test) →誤差と正解率が算出される
--

誤差→(変数名)[0]、正解率→(変数名)[1]

```
print("Test loss:", score[0])
Test loss: 0.009264961816370487
```

```
print("Test accuracy:", score[1])
Test accuracy: 1.0
```

誤差0.9%、正解率100%という結果

結果の可視化

“6) 学習過程をグラフ表示する”を実行しよう

```
# Loss(正解との誤差)をloss_valuesに入れる
loss_values = history.history['loss']


# 正確度をaccに入れる
acc = history.history['accuracy']

# 1からepoch数までのリストを作る
epochlist = range(1, len(loss_values) + 1)

# Loss(正解との誤差)のグラフを作る
# 'bo'は青点
plt.plot(epochlist, loss_values, 'bo', label='Training loss')

# 正確率のグラフを作る
# 'b'は青い線
plt.plot(epochlist, acc, 'b', label='Training accuracy')

plt.title('学習回数と正確度')
plt.ylabel('青線は正解率、青点は誤差')
plt.xlabel('学習回数(epoch数)')
plt.legend()
plt.show()
```



学習する度に正解率が上がって誤差が下がっていることが分かる

結果の可視化(補足)

“6) 学習過程をグラフ表示する”を実行しよう

```
# Loss(正解との誤差)をloss_valuesに入れる
loss_values = history.history['loss']

# 正確度をaccに入れる
acc = history.history['accuracy']

# 1からepoch数までのリストを作る
epochlist = range(1, len(loss_values) + 1)

# Loss(正解との誤差)のグラフを作る
# 'bo'は青点
plt.plot(epochlist, loss_values, 'bo', label='Training loss')

# 正確率のグラフを作る
# 'b'は青い線
plt.plot(epochlist, acc, 'b', label='Training accuracy')

plt.title('学習回数と正確度')
plt.ylabel('青線は正解率、青点は誤差')
plt.xlabel('学習回数(epoch数)')
plt.legend()
plt.show()
```

```
history = model.fit(x_train, y_train, epochs=300)
```

kerasのfit()は各エポック毎の正解率、誤差を保存出来る

history.history["accuracy"]が正解率のリスト

history.history[["loss"]]が誤差のリスト


```
loss_values = history.history['loss']
acc = history.history['accuracy']

epochlist = range(1, len(loss_values) + 1)
→range(1, 301) : 1から300までの範囲を指定

plt.plot(epochlist, loss_values, 'bo', label='Training loss')
→X軸が1から300(学習回数)、Y軸が各回の誤差で直線で結ぶ
```


自分たちで実践してみよう


1層目から3層目のニューロンを1つ増やして、
学習の回数を500回にして実践してみよう



自分たちで実践してみよう

このサマリーと学習過程が表示されていれば正しく実行出来ています。

```
3/3 [=====] - 0s 912us/step - loss: 0.0013 - accuracy: 1.0000
Epoch 480/500
3/3 [=====] - 0s 1ms/step - loss: 0.0014 - accuracy: 1.0000
Epoch 481/500
3/3 [=====] - 0s 1ms/step - loss: 0.0013 - accuracy: 1.0000
Epoch 482/500
3/3 [=====] - 0s 1ms/step - loss: 0.0012 - accuracy: 1.0000
Epoch 483/500
3/3 [=====] - 0s 959us/step - loss: 0.0012 - accuracy: 1.0000
Epoch 484/500
3/3 [=====] - 0s 1ms/step - loss: 0.0014 - accuracy: 1.0000
Epoch 485/500
3/3 [=====] - 0s 955us/step - loss: 0.0012 - accuracy: 1.0000
Epoch 486/500
3/3 [=====] - 0s 995us/step - loss: 0.0012 - accuracy: 1.0000
Epoch 487/500
3/3 [=====] - 0s 1ms/step - loss: 0.0014 - accuracy: 1.0000
Epoch 488/500
3/3 [=====] - 0s 1ms/step - loss: 0.0012 - accuracy: 1.0000
Epoch 489/500
3/3 [=====] - 0s 1ms/step - loss: 0.0012 - accuracy: 1.0000
Epoch 490/500
3/3 [=====] - 0s 1ms/step - loss: 0.0012 - accuracy: 1.0000
Epoch 491/500
3/3 [=====] - 0s 1ms/step - loss: 0.0013 - accuracy: 1.0000
Epoch 492/500
3/3 [=====] - 0s 1ms/step - loss: 0.0012 - accuracy: 1.0000
Epoch 493/500
3/3 [=====] - 0s 1ms/step - loss: 0.0013 - accuracy: 1.0000
Epoch 494/500
3/3 [=====] - 0s 1ms/step - loss: 0.0011 - accuracy: 1.0000
Epoch 495/500
3/3 [=====] - 0s 905us/step - loss: 0.0012 - accuracy: 1.0000
Epoch 496/500
3/3 [=====] - 0s 952us/step - loss: 0.0013 - accuracy: 1.0000
Epoch 497/500
3/3 [=====] - 0s 991us/step - loss: 0.0013 - accuracy: 1.0000
Epoch 498/500
3/3 [=====] - 0s 1ms/step - loss: 0.0012 - accuracy: 1.0000
Epoch 499/500
3/3 [=====] - 0s 900us/step - loss: 0.0012 - accuracy: 1.0000
Epoch 500/500
3/3 [=====] - 0s 933us/step - loss: 0.0013 - accuracy: 1.0000
WARNING:tensorflow:5 out of the last 5 calls to <function Model.make_test_function.<locals>.test_function
at 0x7fb95879dcb0> triggered tf.function retracing. Tracing is expensive and the excessive number of
tracings could be due to (1) creating @tf.function repeatedly in a loop, (2) passing tensors with different
shapes, (3) passing Python objects instead of tensors. For (1), please define your @tf.function outside of
the loop. For (2), @tf.function has experimental_relax_shapes=True option that relaxes argument shapes that
can avoid unnecessary retracing. For (3), please refer to https://www.tensorflow.org/guide/
function#controlling_retracing and https://www.tensorflow.org/api_docs/python/tf/function for more
details.
Test loss: 0.003523191437125206
Test accuracy: 1.0
```



課題

- ・ 中間層の2層目をニューロン6個、3層目をニューロン3個にして実行しなさい
(モデル名).summary()の出力結果と図を提出して下さい。(エポック数300)
- ・ (余力がある人は)
上のモデルを使って新たなアヤメのデータでブルーフラッグである確率を算出しなさい

No.	がく片の長さ	がく片の幅	花びらの長さ	花びらの幅
1	5.3	2.4	4.8	1.5
2	4.4	2.5	1.8	0.4

ヒント: `import numpy as np`
`(変数) = model.predict((調べたいNumpy配列))`
`print(変数) = [[(1つ目の確率)], [(2つ目の確率)], […] , […], …]`

課題の提出方法

The image shows a web application interface for submitting homework and a Jupyter Notebook environment. A red box with the text "コピー&ペースト" (Copy & Paste) and an arrow points to the model summary table in the Jupyter Notebook.

Web Application Interface:

- URL: https://lib02.tmd.ac.jp/webclass/qstn_frame.php?set_contents_id=c269ef0b64260be14ba3b2a80ef9a6c1&language=JAPANESE&rnd=884cb&content_m...
- Buttons: 教材, 終了
- Header: > FMD21064 医療とAI・ビッグデータ入門(追加選択) 2021, 7/19 演習課題, 須藤 毅頭 さんがログイン中
- Question 1: 中間層の2層目をニューロン6個、3層目をニューロン3個にして実行しなさい (モデル名).summary()の出力結果をコピーして提出して下さい。(エポック数300)
字数制限: 上限 20000 字まで
- Model: "sequential_2"
- Table:

Layer (type)	Output Shape	Param #
dense_8 (Dense)	(None, 4)	20
dense_9 (Dense)	(None, 4)	

- Buttons: 回答を保存, レポート提出
- Question 2: 中間層の2層目をニューロン6個、3層目をニューロン3個にして実行しなさい
学習過程のグラフを提出して下さい。(エポック数300)
- Buttons: ファイルの選択, レポート提出
- Text: 最大アップロードファイルサイズ: 10 MB
- Buttons: 終了

Jupyter Notebook Environment:

- Console: プロジェクト (P) ツール (T) 表示 (V) ヘルプ (H)
- File Explorer: s#manne\Desktop#iryoAI
- Variable Explorer: 変数エクスプローラー ヘルプ プロット ファイル
- Console 1/A:

```
In [5]: dl_model.summary()
Model: "sequential_2"

Layer (type)                 Output Shape              Param #
-----
dense_8 (Dense)              (None, 4)                 20
dense_9 (Dense)              (None, 4)                 20
dense_10 (Dense)             (None, 4)                 20
dense_11 (Dense)             (None, 1)                 5
Total params: 65
Trainable params: 65
Non-trainable params: 0
```

- IPython Console: ヒストリ
- Status: LSP Python: 準備完了 Line 65, Col 1 UTF-8 CRLF RW Mem 36%